

Implementacija prediktivne analitike i „what if“ simulacije u ERP sustavu

Masnec, Lea

Master's thesis / Diplomski rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics / Sveučilište u Zagrebu, Fakultet organizacije i informatike**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:211:318160>

Rights / Prava: [Attribution 3.0 Unported/Imenovanje 3.0](#)

Download date / Datum preuzimanja: **2024-07-14**



Repository / Repozitorij:

[Faculty of Organization and Informatics - Digital Repository](#)



**SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN**

Lea Masnec

**IMPLEMENTACIJA PREDIKTIVNE
ANALITIKE I „WHAT IF“ SIMULACIJE U
ERP SUSTAVU**

DIPLOMSKI RAD

Varaždin, 2023.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Lea Masnec

Matični broj: 0016138246–R

Studij: Organizacija poslovnih sustava

**IMPLEMENTACIJA PREDIKTIVNE ANALITIKE I „WHAT IF“
SIMULACIJE U ERP SUSTAVU**

DIPLOMSKI RAD

Mentor:

prof. dr. sc. Ruben Picek

Varaždin, lipanj 2023.

Lea Masnec

Izjava o izvornosti

Izjavljujem da je moj diplomski rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristila drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autorica potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

Rad se fokusira se na implementaciju prediktivne analitike i "what if" simulacije u kontekstu poslovne inteligencije u ERP sustavu. Rad ponajprije obrađuje teorijski aspekt poslovne inteligencije u vidu današnjih trendova, njene važnosti i tehnika. Drugo poglavlje se bavi prediktivnom analitikom gdje se predstavljaju različiti alati za izvještavanje te se prelazi na prediktivne scenarije i planiranje. Praktični dio diplomskog rada vezan je uz izradu modela korištenjem SAP Analytics Cloud alata. temelju dinamičkog izvještavanja kroz korištenje predikcije i simulacije. U praktičnom djelu rada prikazuju se podaci vezani uz istraživanje na vlastitom primjeru. Kroz diplomski rad će se istražiti i analizirati različiti alati i tehnike za implementaciju prediktivne analitike te naposljetku "what if" simulacije. Ponajprije se podaci obrađuju i strukturiraju, a zatim koriste za „what if“ simulaciju. Nakon provedbe simulacije obrađuje se primjena izrađenog modela u poslovanju. Na kraju rada navode se vlastiti zaključci vezani za proveden model te se diskutiraju moguće prilike za poslovanje poduzeća korištenjem dobivenih podataka. Cilj ovog rada je analizirati sposobnost ERP sustava da predviđa buduće rezultate i omogućí korisnicima da testiraju različite scenarije kako bi vidjeli kako bi to utjecalo na poslovanje.

Ključne riječi: ERP sustavi, poslovna inteligencija, prediktivna analitika, proširena analitika, SAP Analytics Cloud, what if simulacija

Summary

This thesis focuses on the implementation of predictive analytics and "what if" simulation in the context of business intelligence in an ERP system. The paper primarily deals with the theoretical aspect of business intelligence in the form of today's trends, its importance and techniques. The second chapter deals with predictive analytics, where different reporting tools are presented, and it moves on to predictive scenarios and planning. The practical part of the thesis is related to the creation of models using SAP Analytics Cloud tools based on dynamic reporting through the use of prediction and simulation. In the practical part of the paper, data related to the research are presented using an example. The thesis will explore and analyze various tools and techniques for the implementation of predictive analytics and finally "what if" simulations. First of all, the data is processed and structured, and then used for what if simulation. After the implementation of the simulation, the application of the created model in business is processed. At the end of the paper, one's own conclusions related to the implemented model are stated and possible business opportunities for the company using the obtained data are discussed. The goal of this paper is to improve the ERP system's ability to predict future results and allow users to test different scenarios to see how it would affect the business.

Keywords: business intelligence, ERP systems, extended analytics, predictive analytics, SAP Analytics Cloud, what if simulati

Sadržaj

Sadržaj.....	iv
1. Uvod.....	1
1.1. Predmet istraživanja.....	1
1.2. Ciljevi istraživanja.....	1
1.3. Istraživačka pitanja.....	2
1.4. Struktura rada	2
2. Metodologija	3
3. Primjena poslovne inteligencije.....	4
3.1. Primjena poslovne inteligencije u ERP sustavima.....	6
3.1.1. SAP ERP	7
3.1.2. Microsoft Dynamics NAV	9
3.1.3. Oracle Netsuite	10
3.2. Integracija poslovne inteligencije u ERP sustave: Pregled funkcionalnosti i modula .	11
4. Korištenje prediktivne analitike	14
4.1. Korist prediktivne analitike u poslovanju	14
4.2. Alati za izvještavanje	15
4.2.1. Trendovi u korištenju naprednih analitičkih funkcionalnosti	16
4.2.2. Korištenje prediktivne analize u poslovanju.....	18
4.3. Prediktivni scenariji	18
4.3.1. Vremenska serija predviđanja	20
4.3.2. Regresija.....	21
4.3.2.1. Linearna regresija	21
4.3.2.2. Nelinearna regresija	22
4.3.3. Klasifikacija	22
4.4. Strukture podataka za proširenu analitiku	23
4.4.1. Relacijska baza podataka	23
4.4.2. NoSQL baze podataka.....	24
4.4.3. Dinamička veza s podacima.....	24
4.5. Dinamičko izvještavanje kroz predikcije i simulacije.....	26
4.5. Primjeri primjene u industriji.....	27
4.5.1. Primjena prediktivne analitike u proizvodnji.....	27
4.5.2. Primjena prediktivne analitike u logistici	29
4.5.3. Primjena prediktivne analitike u financijama	29
4.5.4. Primjena prediktivne analitike u marketingu	30
4.6. Izazovi i ograničenja implementacije.....	32
4.6.1. Ograničenja ERP sustava u integraciji s prediktivnom analitikom.....	32
4.6.2. Etička pitanja u korištenju prediktivne analitike	33

4.7. Budući razvoj i trendovi.....	34
4.7.2. Razvoj ERP sustava i integracija s analitičkim alatima.....	35
4.7.3. Potencijalne primjene umjetne inteligencije u ERP sustavima.....	35
5. Praktična primjena.....	37
5.1. Definiranje modela.....	37
5.1.1. Skup podataka i postavljanje modela.....	38
5.1.2. Izrada finalnog modela u SAP Analytics Cloudu.....	44
5.2. Pregled poslovanja.....	50
5.3. Prediktivna analitika.....	51
5.3.1. Klasifikacija.....	52
5.3.2. Regresija.....	56
5.3.3. Vremenske serije predviđanja.....	60
5.4. „What if“ simulacija.....	63
5.4.1. Definiranje cilja.....	64
5.4.2. Izrada kalkulacija ovisnih o 2021. godini.....	64
5.4.3. Kreiranje analitičke aplikacije.....	70
5.4.4. Kreiranje stabla pokretača vrijednosti.....	78
5.4.5. Rezultati.....	80
6. Zaključak.....	83
Popis literature.....	85
Kratice.....	88
Popis slika.....	89
Popis tablica.....	91
Popis isječaka kôda.....	92
Korišteni alati.....	93

1. Uvod

U diplomskom radu fokusira se na implementaciju prediktivne analitike i "what if" simulacije u ERP sustavu, točnije SAP Analytics Cloudu. Istraživanje se usredotočuje na teorijski aspekt poslovne inteligencije, današnje trendove te različite tehnike koje se koriste u poslovnoj inteligenciji. Također se proučava prediktivna analitika i različiti alati koji se koriste u izvještavanju, a zatim prelazi na prediktivne scenarije i simulaciju. Praktični dio rada uključuje izradu modela korištenjem alata SAP Analytics Cloud-a, koji se temelji na dinamičkom izvještavanju i koristi predikciju i simulaciju kroz primjer vlastitog istraživanja farmaceutskog poduzeća koji se temelji na obrađenim i strukturiranim podacima, te se kroz diplomski rad analiziraju i istražuju različiti alati i tehnike za implementaciju prediktivne analitike te "what if" simulacije. Nakon provedbe simulacije, obrađuje se primjena izrađenog modela u poslovanju i navode vlastiti zaključci vezane za proveden model te diskutira moguće prilike za poslovanje poduzeća korištenjem dobivenih podataka.

1.1. Predmet istraživanja

Predmet istraživanja rada je implementacija prediktivne analitike i "what if" simulacije u ERP sustavu u svrhu poboljšanja sposobnosti sustava da predviđa buduće rezultate i omogućiti korisnicima da testiraju različite scenarije te vidjeti kako bi to utjecalo na poslovanje. Rad se fokusira na teorijski aspekt poslovne inteligencije, današnje trendove, tehnike koje se koriste u poslovnoj inteligenciji te prediktivnu analitiku. Praktični dio rada uključuje izradu modela korištenjem alata SAP Analytics Cloud-a te analiziranje i istraživanje različitih alata i tehnika za implementaciju prediktivne analitike i "what if" simulacije.

1.2. Ciljevi istraživanja

Cilj istraživanja je analizirati sposobnost ERP sustava da predviđa buduće rezultate i omogućiti korisnicima da testiraju različite scenarije kako bi vidjeli kako bi to utjecalo na poslovanje. Za postizanje ovog cilja, istraživanje će se provoditi kroz teorijski i praktični dio rada.

Praktični dio rada će se fokusirati na izradu modela korištenjem alata SAP Analytics Cloud-a na temelju dinamičkog izvještavanja kroz korištenje predikcije i simulacije. U praktičnom djelu rada prikazat će se podaci vezani uz istraživanje na vlastitom primjeru.

1.3. Istraživačka pitanja

Kako bi se konkretizirali ciljevi istraživanja postavljena su sljedeća israživačka pitanja, koja će naposljetku biti odgovorena u zaključku:

1. Kako prediktivna analitika može poboljšati učinkovitost ERP sustava?
2. Koje su glavne prednosti implementacije "what-if" simulacija u ERP sustavu?
3. Kako se prediktivna analitika i "what-if" simulacije mogu koristiti u planiranju poslovanja?
4. Koje su mogućnosti za implementaciju prediktivne analitike u ERP sustavu?

1.4. Struktura rada

Rad se sastoji od sljedećih poglavlja:

1. Uvod: U uvodnom djelu rada prikazuju se predmet, cilj istraživanja te struktura rada. U uvodu se također i ukratko opisuje o čemu govori diplomski rad.
2. Metodologija: Prikazuju se znanstvene metode koje su korištene u svrhu izrade diplomskog rada u pogledu teorijskog i praktičnog djela rada.
3. Poslovna inteligencija: U ovom poglavlju prikazuju se trendovi u poslovnoj inteligenciji, njena važnost te opće odrednice koje su važne za ostatak rada.
4. Prediktivna analitika: Poglavlje prediktivne analitike prikazuje pregled alata za izvještavanje, dinamičko izvještavanje te prediktivnu analizu koja će se naposljetku obrađivati u praktičnog djelu rada.
5. Praktična primjena: Praktična primjena obuhvaća prediktivnu analitiku i „what if“ simulaciju koje su izrađene u alatu SAP Analytics Cloud.
6. Zaključak: Navode se glavne misli rada te objašnjava važnost tematike na poslovanje i budućnost. Naposljetku je odgovoreno na istraživačka pitanja.

2. Metodologija

U ovom radu korištene su različite metode za istraživanje i pisanje teorijskog aspekta. Prije svega, korištena je deskriptivna metoda istraživanja koja se koristi za opisivanje i analizu. Koristila se kvalitativna analiza literature kako bi se utvrdili trendovi i tehnike koje se koriste u poslovnoj inteligenciji, prediktivnoj analitici i "what if" simulaciji.

U praktičnom dijelu rada korištena je eksperimentalna metoda istraživanja kako bi se izradio model korištenjem alata SAP Analytics Cloud-a i testirale različite scenarije kroz prediktivnu analitiku i "what if" simulaciju. Također je korištena kvalitativna analiza podataka kako bi se izvršila analiza rezultata i donijeli zaključci. Konačno, korištena je i metoda statističke analize podataka kako bi se utvrdile povezanosti i korelacije između različitih faktora i njihov utjecaj na poslovanje.

3. Primjena poslovne inteligencije

Varga (2004, str. 13-14) navodi da današnja poslovna okolina zahtijeva od poduzeća suočavanje s nizom izazova, uključujući povećanu tržišnu konkurenciju, zahtjevnije kupce te nužnost ostvarenja različitih poslovnih ciljeva poput smanjenja troškova, povećanja dobiti i upravljanja poslovnim sustavom. U tom kontekstu, velika količina poslovnih podataka se pohranjuje u digitalnom obliku, ali se često ne koristi ili se gubi u mnoštvu informacija. Stoga se postavlja pitanje kako iskoristiti te podatke te ostvariti povrat od ulaganja u IT.

Poslovna inteligencija, kako ističe Varga (2004, str. 14), ima za cilj pomoći u rješavanju ovih problema kroz omogućavanje brzog i preciznog pribavljanja potpunih i pouzdanih informacija relevantnih za poslovno odlučivanje. U tu svrhu, aplikacije poslovne inteligencije pružaju korisnicima prave informacije u pravo vrijeme, omogućujući im da donose dobre poslovne odluke. Korištenjem poslovne inteligencije, poduzeća mogu pretvoriti svoje podatke u vrijedne informacije koje će im omogućiti da postignu svoje ciljeve te ostvare profit.

Današnji trendovi u poslovnoj inteligenciji su sljedeći (Nazarov i sur., 2021) te su procesi prikazani na slici 1:

1. Umjetna inteligencija i strojno učenje: Poslovna inteligencija sve više koristi tehnologije umjetne inteligencije i strojnog učenja kako bi se postigla bolja analitika podataka i predikcija.
2. Cloud-based BI: Poslovna inteligencija sve više se prebacuje na cloud-based sustave kako bi se pojednostavio pristup podacima i smanjili troškovi održavanja infrastrukture.
3. Integracija s Big Data: Kako se količina podataka koje tvrtke prikupljaju povećava, poslovna inteligencija se sve više integrira s velikim količinama podataka kako bi se dobila bolja analitika i spoznaje.
4. Self-Service BI: Kao i kod drugih tehnologija, trend samostalne poslovne inteligencije (Self-Service BI) je u porastu. Korisnici mogu sami pristupiti i analizirati podatke kako bi donijeli poslovne odluke bez pomoći stručnjaka za analitiku.
5. Mobilni BI: Mobilna poslovna inteligencija je sve popularnija, jer korisnici žele pristupiti podacima i analizama na svojim mobilnim uređajima. Ovo zahtijeva od tvrtki da osiguraju da njihovi sustavi BI budu prilagođeni mobilnom pristupu.

Slika 1. Poslovna inteligencija kroz procese i aktivnosti



Izvor: Inpro (2020)

Poslovna inteligencija (engl. *Business Intelligence*) je ključna za uspješno upravljanje podacima i informacijama u poslovnom okruženju. To je proces prikupljanja, analiziranja i pretvaranja podataka u korisne informacije koje se mogu koristiti za donošenje poslovnih odluka. Poslovna inteligencija može pomoći tvrtkama da (Nazarov i sur., 2021):

- Poboljšaju poslovne procese analizirajući podatke o poslovanju, tvrtka može identificirati područja koja se mogu poboljšati i optimizirati poslovne procese kako bi se smanjili troškovi, povećala produktivnost i poboljšala kvaliteta proizvoda ili usluga.
- Donose informirane poslovne odluke; poslovna inteligencija pruža tvrtkama korisne informacije o poslovanju, što im omogućuje donošenje boljih i informiranih poslovnih odluka.
- Predviđaju buduće trendove; analizom podataka o poslovanju, tvrtke mogu prepoznati trendove i predvidjeti buduće potrebe tržišta, što im omogućuje planiranje budućih poslovnih strategija.
- Povećavaju konkurentsku prednost; korištenje poslovne inteligencije može tvrtkama pomoći u razumijevanju tržišta i konkurentskog okruženja, što im omogućuje da se bolje prilagode i poboljšaju svoju konkurentsku prednost.

3.1. Primjena poslovne inteligencije u ERP sustavima

Primjena poslovne inteligencije (BI) u modernom poslovanju postala je neizostavna za unapređivanje odluka temeljenih na podacima. BI omogućuje organizacijama da prikupe, analiziraju i interpretiraju podatke iz različitih izvora kako bi donijele informirane poslovne odluke (Radmilović, 2012, str. 23).

U današnjem poslovnom okruženju, s porastom količine podataka koji se generiraju iz različitih izvora poput društvenih mreža, IoT (Internet of Things) uređaja i drugih aplikacija, sve veća je potreba za razvojem alata za analizu velikih količina podataka. Prema DeKa (2014, str. 370), analitika velikih podataka (Big Data) koristi se za prediktivnu analizu, omogućujući organizacijama da predvide buduće događaje i preporuče primjene odgovarajućih strategija. Upravljanje podacima ključan je dio procesa poslovne inteligencije. Razvoj BI alata koji su sposobni prikupiti, obrađivati i analizirati velike količine podataka postaje ključan za postizanje poslovnih ciljeva. U tom smislu, BI alati pomažu organizacijama da prikupe i obrade velike količine podataka te ih pretvore u korisne informacije koje će poduzeću omogućiti donošenje informiranih poslovnih odluka.

Poslovna inteligencija obuhvaća različite tehnike, metode i alate za prikupljanje, obradu i analizu podataka. Ovi alati omogućuju organizacijama da izvlače vrijednost iz svojih podataka i dobiju dublje razumijevanje svojih poslovnih procesa, performansi i trendova. Na primjer, BI alati mogu generirati različite vrste izvještaja, nadzornih ploča i prekretnica (pivot table) koje vizualno prikazuju ključne pokazatelje performansi. Ovi vizualni prikazi olakšavaju donositeljima odluka da identificiraju obrasce, trendove i anomalije te donesu informirane poslovne odluke.

ERP sustavi (Enterprise Resource Planning) su informacijski sustavi koji integriraju sve ključne poslovne procese i informacije unutar organizacije. To uključuje financije, upravljanje ljudskim resursima, proizvodnju, nabavu, prodaju, marketing i druge poslovne procese. Implementacija ERP sustava pruža organizaciji mogućnost boljeg upravljanja njezinim resursima, povećanja efikasnosti poslovanja, poboljšanja kvalitete proizvoda i usluga te optimizaciju troškova. Jedna od ključnih mogućnosti poslovne inteligencije u ERP sustavima je prediktivna analitika. To je proces korištenja statističkih metoda i algoritama strojnog učenja za predviđanje budućih događaja i trendova na temelju postojećih podataka. Primjena prediktivne analitike u ERP sustavima omogućuje organizacijama da predvide buduću potražnju, optimiziraju zalihe, unaprijede proizvodne procese i smanje troškove, kako navode Park i Kim (2017, str. 6).

Važna mogućnost poslovne inteligencije u ERP sustavima je "what if" simulacija. Ova tehnika omogućuje organizacijama da simuliraju različite scenarije na temelju različitih varijabli i

parametara, kako bi se predvidjeli potencijalni rezultati i utjecaji na poslovanje. Primjena ove tehnike omogućuje organizacijama da procijene utjecaj promjena u proizvodnji, promjena cijena, različitih marketinških strategija, i drugih faktora na njihovu poslovnu učinkovitost.

U procesu implementacije prediktivne analitike, važno je osigurati da sustav ima dovoljno podataka, dobro definirane modele i algoritme te adekvatnu infrastrukturu za analizu i prikaz podataka. Također je potrebno educirati zaposlenike o tome kako koristiti ove tehnike kako bi se postigle najbolje rezultate.

Navest će se nekoliko različitih ERP sustava kako bi se shvatio način poslovanja ERP sustava, koji će se naposljetku povezati s prediktivnom analitikom.

3.1.1. SAP ERP

Prema Čuljak (2018, str. 24) SAP ERP pokriva četiri glavna područja (SAP ERP financije, SAP ERP upravljanje ljudskim kapitalom, SAP ERP operacije: nabava, logistika, razvoj proizvoda, proizvodnja, prodaja i servis, SAP ERP usluge za poduzeća: administracija). S obzirom da paket standardizira osnovne sustave, poslovne prakse i upravljanje unutar organizacije, često se koristi kao učinkovit alat za pokretanje i potrebu redizajniranja poslovnih procesa, te omogućuje jednokratni unos podataka i brzo dijeljenje, kao i informacije unutar uz visoku integraciju i opsežne funkcije, SAP ERP rješenja mogu se brzo prilagoditi tržišnim promjenama, razumjeti i odgovoriti na potrebe korisnika te uključiti korisnike, dobavljače i poslovne partnere u poslovne procese, čime se poboljšava produktivnost i uvid u poslovanje.

Tablica 1 prikazuje module koje nudi SAP ERP. SAP je kroz godine razradio mnoge odjele koji su personalizirani ovisno o potrebama klijenta.

Tablica 1. Prikaz modula koje nudi SAP ERP

Modul	Opis
Ugovaranje, prodaja i distribucija	Planiranje prodaje, ugovaranje, upravljanje narudžbenicama kupaca, izdavanje računa, oprema

Robno, materijalno i skladišno poslovanje	Robni i materijalni tokovi nabava, odobrenje ulaznog računa, upravljanje zalihama, skladišno poslovanje
Praćenje proizvodnje	Upravljanje materijalima, planiranje potreba za materijalima, određivanje rokova i planiranje kapaciteta, upravljanje proizvodnim aktivnostima u pojedinačnoj ili serijskoj proizvodnji
Upravljanje kvalitetom	Planiranje i provjera kvalitete, nadzor, kontrola, revizija
Tehničko održavanje imovine	Modeliranje objekata, modeliranje povezivanja objekata, radni nalozi za tražene usluge i održavanje
Planiranje, praćenje i upravljanje ljudskim resursima	Odabir kvalificiranih kadrova, stručno profiliranje i procjenu njihovih kvalifikacija, učinkovito upravljanje radnim vremenom, planiranje rada i dodjelu radnih naloga prema normama, kvalifikacijama i raspoloživosti radne snage
Financije i računovodstvo	Glavna knjiga, bilanca dobiti, saldakonti kupaca, putni nalozi, blagajna, žiroračun, nalog za plaćanje financijske kontrole, zakonsko izvješćivanje, obračun PDV-a
Kontroling	Računovodstvo troškovnih centara, analiza profitabilnosti, analiza troškova usluga, analiza troškova prema aktivnostima
Upravljanje osnovnim sredstvima	Računovodstvo imovine, obračun amortizacije po različitim metodama
Tijek poslova	Praćenje tijeka poslovanja i procesa

Industrijska rješenja	moduli i rješenja za industrijska poduzeća
-----------------------	--

Izvor: prema Čuljak (2018, str. 25)

3.1.2. Microsoft Dynamics NAV

Microsoft Dynamics NAV jedan je od vodećih informacijskih ERP sustava za upravljanje poslovanjem malih, srednjih i velikih tvrtki. Neke od ključnih značajki koje čine Microsoft Dynamics NAV uspješnim poslovnim programom za vodeće tvrtke su fleksibilnost, pouzdanost, stabilnost, jednostavna nadogradnja i jednostavan za korištenje, navodi Komorčec (2018). Radu u NAV-u može lako pristupiti netko tko je upoznat s poslovnim procesima, pod uvjetom da poznaje rad u Microsoftovim operativnim sustavima. NAV osim svojih osnovnih funkcija podržava i izradu i analizu različitih izvještaja i često se koristi za Hvaljen zbog sveobuhvatne integracije s financijskim granulama. Microsoft Dynamics NAV pruža učinkovit način usmjeravanja poslovanja i povećanja produktivnosti. Omogućuje zamjenu postojećih sustava s potpuno integriranim novim sustavom.

Microsoft Dynamics NAV, isto kao i SAP ERP sustav, nudi mogućnost izrade izvještaja unutar modula svog sustava, što prikazuje slika 2. U današnje vrijeme za poslovanje je neophodno vršiti izvještavanje kako bi zaposlenici i klijenti imali što bolji uvod u trenutno stanje poduzeća te planirali buduće pothvate. Slika 2 prikazuje prikaz NAV sučelja za izvještavanje, na kojem su vidljivi razni trendovi i praćenje poslovanja.

Slika 2. Prikaz sučelja u NAV-u za izvještavanje



Izvor: <https://www.zapbi.com/solution/microsoft-dynamics-nav-reporting-solution/>

3.1.3. Oracle Netsuite

Oracle Netsuite dopire do više od 40.000 organizacija, 10 puta veće od najbližeg ekvivalentnog pružatelja usluga. Opsežna funkcionalnost i podrška u cijeloj industriji znači da Netsuite radi onako kako svako poduzeće želi da posluje, smanjujući troškove i jedinstveni podatkovni model koji obuhvaća back-office financija do evidencije o klijentima do profesionalnih usluga pruža sveobuhvatnu vidljivost i pojednostavljenu integraciju. Oracle Netsuite prema Čuljaku (2018, str. 29) karakterizira sljedeće:

- Izgrađen je na fleksibilnosti, odnosno fleksibilnost Netsuitea omogućuje brze i jednostavne promjene, a svaka nadogradnja, konfiguracija i podešavanje rješavaju se bez problema
- Analitika u stvarnom vremenu. Oracle Netsuite, korisnici znaju što trebaju učiniti kako bi poboljšali poslovanje putem lako dostupnih podataka, izvješća i metrike, važni poslovni podaci se analiziraju i prikazuju u sustavu, MICROSOFT DYNAMICS AX GP NAV SL CRM RMS 29
- ERP spreman za trgovinu; poslovni sustav postaje sustav koji komunicira s klijentima, s prilagođenim performansama,
- Dizajniran za modernu tvrtku - Netsuite pomaže tvrtkama da se odmaknu od starog načina poslovanja, na društveno, mobilno i online poslovanje"

3.2. Integracija poslovne inteligencije u ERP sustave: Pregled funkcionalnosti i modula

U ovoj cjelini istražuju se način kako se poslovna inteligencija integrira u različite module ERP sustave te se analiziraju različite funkcionalnosti koje BI pruža u svakom modulu kako bi korisnici imali pristup relevantnim informacijama za donošenje boljih poslovnih odluka.

Tablica 2 prikazuje različite module ERP sustava i pripadajuće poslovne inteligencije (BI) opcije koje su dostupne u tim modulima. Svrha ove tablice je pružiti cjelovit pregled mogućnosti analize podataka i vizualizacije u ERP sustavima kako bi korisnici mogli donositi informirane poslovne odluke. Ova pruža sveobuhvatan pregled opcija poslovne inteligencije u svakom modulu ERP sustava, uključujući vrstu analize koja se provodi i alate za vizualizaciju podataka koji se koriste. Opisati će se svi moduli prema Chou i sur. (2005):

- U modulu Financije, korisnici imaju pristup izvještajima o financijskom stanju koji pružaju dublji uvid u poslovne rezultate. Također, mogu se provoditi analize troškova kako bi se identificirali ključni aspekti trošenja i optimizirali poslovni procesi. Dodatno, prediktivna analitika za financijsko planiranje omogućuje korisnicima da predvide buduće financijske trendove i planiraju svoje poslovne strategije.
- U modulu Prodaja, korisnici mogu analizirati prodajne rezultate kako bi identificirali uspješne prodajne kanale i proizvode. Praćenje prodajnih performansi omogućuje bolje razumijevanje uspjeha prodaje, dok segmentacija kupaca omogućuje prilagođavanje marketinških strategija prema različitim segmentima kupaca.
- Modul Nabava pruža mogućnosti analize dobavljača kako bi se ocijenili njihovi performansi i odabrali najbolji dobavljači za organizaciju. Optimizacija nabavnih procesa pomaže u smanjenju troškova i poboljšanju efikasnosti. Također, predviđanje potreba za zalihama omogućuje organizaciji da planira svoje zalihe i izbjegne neželjene nestašice ili viškove.
- U modulu Proizvodnja, korisnici mogu pratiti performanse proizvodnje kako bi identificirali područja za poboljšanje. Analiza troškova proizvodnje omogućuje bolje razumijevanje troškova proizvodnih procesa i identifikaciju potencijalnih ušteda. Planiranje kapaciteta omogućuje organizaciji da optimalno iskoristi svoje resurse i optimizira proizvodne procese.
- Modul Ljudski resursi pruža analizu radne snage kako bi se bolje razumjela struktura i performanse zaposlenika. Praćenje produktivnosti omogućuje praćenje i usporedbu radne učinkovitosti. Planiranje potreba za zapošljavanjem pomaže organizaciji u predviđanju budućih potreba za radnom snagom i planiranju zapošljavanja.

- U modulu Logistika, korisnici mogu pratiti lanac opskrbe i analizirati isporuke kako bi se poboljšala efikasnost. Optimizacija rute dostave omogućuje pronalaženje najefikasnijih ruta dostave, smanjenje troškova i povećanje zadovoljstva kupaca.

Tablica 2. Pregled BI opcija po modulima ERP sustava

Modul ERP sustava	BI Opcije	Vrsta analize	Alati za vizualizaciju
Financije	Izveštaji o financijskom stanju	Financijska analiza	Tablica, grafikon
	Analiza troškova	Analiza troškova	Grafikon, tortni dijagram
	Prediktivna analitika za financijsko planiranje	Prediktivna analiza	Prognozne metode (npr. vremenska serija predviđanja)
Prodaja	Analiza prodajnih rezultata	Prodajna analiza	Grafikon, tablica
	Praćenje prodajnih performansi	Performansi prodaje	KPI mjerači, grafikon
	Segmentacija kupaca	Analiza segmenata kupaca	Kružni dijagram
Nabava	Analiza dobavljača	Analiza dobavljača	Tablica, grafikon
	Optimizacija nabavnih procesa	Procesna analiza	BPMN dijagram
	Predviđanje potreba za zalihama	Prediktivna analiza zaliha	Prognoza, trendovi
Proizvodnja	Praćenje proizvodnih performansi	Performansi proizvodnje	Ganttov dijagram
	Analiza troškova proizvodnje	Analiza troškova proizvodnje	Tablica, grafikon
	Planiranje kapaciteta	Kapacitetska analiza	Planovi, simulacije
Ljudski resursi	Analiza radne snage	Analiza radne snage	Grafikon, tablica
	Praćenje produktivnosti	Performansi zaposlenika	KPI mjerači, grafikon
	Planiranje potreba za zapošljavanjem	Planiranje radne snage	Planovi, projekcije
Logistika	Praćenje lanca opskrbe	Analiza lanca opskrbe	Flowchart, mrežni dijagram

	Analiza isporuka	Analiza isporuka	Mapa, grafikon
	Optimizacija rute dostave	Analiza logistike	Heatmap, planiranje rute

Izvor: vlastita izrada; prema Chou i sur. (2005)

4. Korištenje prediktivne analitike

Prediktivna analitika je tehnologija koja koristi statističke metode i metode strojnog učenja kako bi analizirala podatke i predvidjela buduće događaje. To je proces prikupljanja podataka, njihove obrade, analize i donošenja predviđanja koja će pomoći organizacijama da donose bolje poslovne odluke. Primjene prediktivne analitike su raznolike, od financija do zdravstva, a njihovi rezultati mogu pomoći u poboljšanju učinkovitosti, smanjenju rizika i povećanju produktivnosti (Bashki i Bates, str. 2).

Prema Bakhshi i Bates (2018, str. 2), prediktivna analitika je postala neophodna u današnjem poslovnom svijetu jer organizacije žele predvidjeti budućnost i donositi bolje poslovne odluke. Uz to, autori tvrde da je prediktivna analitika korisna jer može pomoći u otkrivanju obrazaca koji nisu očiti pri tradicionalnoj analizi podataka.

4.1. Korist prediktivne analitike u poslovanju

U današnje vrijeme, poslovna inteligencija i Big Data su postali neizostavni dijelovi moderne poslovne prakse. Pavlović i Dejanović (2014, str. 758) ukazuju na to da poduzeća posjeduju ogromne količine podataka, koji se skupljaju iz različitih izvora, kao što su web stranice, društvene mreže, senzori, transakcije i mnogi drugi. No, ovi podaci su uglavnom neobrađeni i njihova vrijednost ostaje neiskorištena. U tom smislu, prediktivna analitika postaje sve važniji alat u poslovnoj inteligenciji. Kako navode Pavlović i Dejanović (2014), prediktivna analitika se temelji na tehnologijama poput strojnog učenja, statistike i obrade prirodnog jezika, koje su usmjerene na analizu podataka s ciljem predviđanja budućih događaja. U poslovnom kontekstu, prediktivna analitika može pomoći poduzećima u predviđanju trendova, identificiranju rizika, optimiziranju poslovnih procesa te unaprjeđenju odnosa s klijentima.

Uz pomoć prediktivne analitike, poduzeća mogu razviti preciznije modele za predviđanje tržišnih trendova, potrošačkih preferencija i konkurencije. Modeli mogu pomoći poduzećima da unaprijede svoju strategiju marketinga, prodaje i poslovanja. Također, prediktivna analitika može pomoći poduzećima da prepoznaju i upravljaju rizicima, čime se može smanjiti šteta koja nastaje uslijed neplaniranih događaja. Uz sve ove koristi, Pavlović i Dejanović (2014, str. 761) upozoravaju da se prediktivna analitika ne smije koristiti samo zbog nje same. Umjesto toga, poduzeća bi trebala pažljivo procijeniti kako prediktivna analitika može unaprijediti njihovo poslovanje i donositi odluke na temelju rezultata analize podataka. U konačnici, uspješno korištenje prediktivne analitike zahtijeva suradnju između analitičara podataka i poslovnih

stručnjaka, kako bi se osigurao maksimalni učinak i povrat na ulaganje u tehnologiju poslovne inteligencije.

4.2. Alati za izvještavanje

Alati za izvještavanje u današnje vrijeme su veliki trend u poslovanju u pogledu različitih tržišta. Kroz alate za izvještavanje može se doći do raznih predikcija i rezultata koji mogu pridonijeti poslovanju poduzeća.


Rašetina (2017, str. 14) navodi da je primjenom web analitike moguće dobiti uvid u mnoge osnovne informacije, poput broja dnevnih posjetitelja, stopa konverzije, najposjećenijih stranica, prosječnog vremena koje korisnici provode na stranicama, geografske distribucije posjetitelja i drugih sličnih podataka. Naprednije analize omogućuju saznanja o složenijim informacijama, kao što su vrijednost posjetitelja i distribucija vrijednosti po lokacijama, vrijednost stranice, ponašanje novih posjetitelja u odnosu na postojeće, ili informacije o tome koliko vremena i posjeta je potrebno prosječnom posjetitelju da postane kupac. Sve te informacije mogu biti od velike koristi u procesu donošenja odluka koje se odnose na poboljšanje online strategije, što je zapravo i glavni cilj web analitike.

Alati za izvještavanje nisu samo tehnologija za izradu izvještaja, već predstavljaju ciklički proces usmjeren na poboljšanje korisničkog iskustva i optimizaciju web stranice s ciljem povećanja profitabilnosti. Waisberg i Kaushik (2009) razvili su okvir za proces web analitike temeljen na najboljim praksama koji uključuje sljedeće korake:

- 1) Definiranje ciljeva,
- 2) Određivanje ključnih pokazatelja uspješnosti (KPI),
- 3) Prikupljanje podataka,
- 4) Analiza podataka,
- 5) Implementacija promjena.

Slika 3 prikazuje proces web analitike. Web analitika se ponajprije treba zasnivati na određenom cilju prema kojemu će se izrađivati daljnje metrike i prikupljati podaci. Alati za izvještavanje se koriste za analizu podataka pomoću koje se može dobiti jasniji uvid u željene promjene, predviđanja, moguće ishode i slično.

Slika 3. Proces web analitike



Izvor: vlastita izrada; prema Waisberg i Kaushik (2009)

Postoje mnogi alati za izvještavanje dostupni na tržištu, a popularnost alata varira ovisno o industriji, regiji i specifičnim potrebama korisnika. Međutim, neki od najpopularnijih alata za izvještavanje uključuju sljedeće (Rašetina, 2017):

1. Microsoft Excel - alat za izvještavanje koji se koristi u mnogim industrijama i organizacijama.
2. Tableau - Tableau je vrlo popularan alat za vizualizaciju podataka i izvještavanje, a koristi se u različitim industrijama poput poslovnih, financijskih i zdravstvenih usluga.
3. Power BI - Power BI je još jedan popularan alat za vizualizaciju podataka i izvještavanje koji se koristi u poslovnim i financijskim industrijama.
4. SAP Analytics Cloud - SAP Analytics Cloud jedan je od SAP-ovih alata za izvještavanje, o kojem govori praktični dio diplomskog rada.
5. Google Data Studio - Google Data Studio je besplatni alat za vizualizaciju podataka i izvještavanje koji se koristi u digitalnom marketingu i oglašavanju.
6. QlikView - QlikView je alat za izvještavanje i poslovnu inteligenciju koji se koristi u različitim industrijama poput financijskih usluga, proizvodnje i zdravstvene skrbi.

4.2.1. Trendovi u korištenju naprednih analitičkih funkcionalnosti

Uvođenje naprednih analitičkih funkcionalnosti poput prediktivne analitike i what-if simulacije u ERP sustavima postalo je sve popularnije u posljednje vrijeme. Napredne analitičke funkcionalnosti omogućuju organizacijama da rade analizu podataka na višoj razini i da dobiju dublji uvid u svoje poslovanje. Kao takve, ove funkcionalnosti mogu biti ključne u poboljšanju performansi poslovanja, smanjenju troškova i povećanju prihoda.

Tablica 3 prikazuje neke od glavnih trendova u korištenju naprednih analitičkih funkcionalnosti koji se trenutno primjenjuju u poslovnom svijetu.

Tablica 3. Trendovi u korištenju naprednih analitičkih funkcionalnosti

Trendovi u korištenju naprednih analitičkih funkcionalnosti	Opis trenda
Povećana integracija analitike u poslovne procese	Integracija analitičkih alata u ERP sustave kako bi se omogućilo brže i preciznije donošenje poslovnih odluka.
Korištenje strojnog učenja i umjetne inteligencije	Korištenje naprednih analitičkih tehnika za automatsko donošenje odluka, predviđanje trendova i identifikaciju skrivenih uzoraka u velikim skupovima podataka.
Veliki naglasak na vizualizaciju podataka	Korištenje naprednih alata za vizualizaciju podataka kako bi se omogućila brza i lako razumljiva interpretacija velikih skupova podataka.
Povećanje korištenja mobilnih aplikacija	Korištenje mobilnih aplikacija koje omogućuju pristup i analizu podataka u realnom vremenu, neovisno o lokaciji.
Korištenje analitike u oblaku	Korištenje cloud-based analitičkih alata koji omogućuju brzi pristup podacima i njihovu analizu bez potrebe za instaliranjem lokalnog softvera.

Izvor: vlastita izrada; prema Soldić-Aleksić i sur. (2020)

Kako navode Soldić-Aleksić i sur. (2020), postoji nekoliko trendova u korištenju naprednih analitičkih funkcionalnosti u ERP sustavima koji su se pojavili u posljednjih nekoliko godina. Jedan od glavnih trendova je uvođenje strojnog učenja u ERP sustave. Strojno učenje omogućuje ERP sustavima da se automatski prilagođavaju promjenama u poslovanju i da donose bolje odluke u realnom vremenu. Ova tehnologija također može biti korištena za prediktivnu analitiku, što omogućuje organizacijama da predvide buduće trendove i izazove te da na njih odgovore na vrijeme. Još jedan trend je korištenje velikih podataka (engl. big data) u ERP sustavima. ERP sustavi skupljaju velike količine podataka, a korištenje naprednih analitičkih funkcionalnosti može pomoći organizacijama da izvuku vrijednost iz tih podataka. Primjerice, organizacije mogu koristiti algoritme strojnog učenja kako bi pronašle skrivene uzorke u podacima i otkrile nove prilike za poslovanje. Također se primjećuje sve veće korištenje cloud tehnologije u ERP sustavima. Cloud tehnologija omogućuje organizacijama da svoje podatke i aplikacije pohranjuju na udaljenim serverima i pristupaju im putem interneta. Ova tehnologija također omogućuje organizacijama da koriste napredne analitičke funkcionalnosti bez potrebe za skupom hardverskom opremom ili stručnjacima za IT.

Prema Soldić-Aleksić i sur. (2020) napredne analitičke funkcionalnosti također se koriste u svrhu poboljšanja korisničkog iskustva. ERP sustavi mogu koristiti napredne analitičke funkcionalnosti kako bi se unaprijed predvidjela potražnja za proizvodima ili kako bi se

personaliziralo iskustvo korisnika, to može biti posebno važno u industrijama gdje je korisničko iskustvo ključno, poput maloprodaje.

4.2.2. Korištenje prediktivne analize u poslovanju

Zbog obilja podataka koje poduzeća danas posjeduju, primjena prediktivne analitike u kontekstu raznih ključnih pitanja vezanih uz poslovanje postaje sve značajnija. Prediktivna analitika predstavlja nadogradnju poslovne analitike koja primjenjuje statističke i matematičke metode na strukturirane i nestrukturirane podatke kako bi se dobili uvidi u uzorke i odnose među podacima, te kako bi se procijenila vjerojatnost da se u budućnosti dogodi određeni događaj. Primjena prediktivne analitike omogućuje organizacijama da odgovore na ključna pitanja vezana uz klijente, poslovanje, kapital i prijevare (Bokulić, 2021, str. 9).

Kako bi se povećala uspješnost prodaje, organizacije pokušavaju "dekodirati" prošle kupovne navike potrošača i projicirati njihove buduće kupovne navike kako bi mogle donijeti odluke na temelju tih spoznaja. Stvaranjem baza podataka kupaca otvara se mogućnost predviđanja njihovog budućeg ponašanja. Modeli predviđanja temelje se na korelaciji između prošlih i budućih događanja te pomažu u provjeri točnosti predviđanja. Ovi rezultati se nazivaju prediktivni modeli, a mogu se postići s 90-95% točnosti u slučaju da se u odnosu na podatke iz prošlosti nije ništa značajno promijenilo (Bokulić, 2021, str. 9).

Prediktivna analitika bavi se segmentacijom, asocijacijom, klasifikacijom, regresijskom analizom i prognoziranjem. Segmentacija se odnosi na grupiranje analiziranih objekata na temelju sličnosti, dok asocijacija identificira učestalost pojavljivanja određenog događaja i donosi zaključke "A i B vode prema C". Klasifikacija predviđa pripadnost pojedinom elementu grupi, dok regresijska analiza identificira veze među pojedinim elementima. Prognoziranje predviđa buduće iznose. Primjena prediktivne analitike omogućuje organizacijama da uoče uzorke i odnose među podacima kako bi mogli donositi odluke na temelju njihovih spoznaja. Korištenje prediktivnih modela pomaže u predviđanju budućih događaja te omogućuje organizacijama da uspješnije planiraju i strategiziraju svoje poslovanje (Bokulić, 2021, str. 10).

4.3. Prediktivni scenariji

Prediktivna analitika u ERP sustavima omogućuje organizacijama da koriste svoje poslovne podatke kako bi predvidjele buduće trendove, situacije i događaje. Na primjer, moguće je predvidjeti buduće prodajne trendove na temelju trenutnih podataka o prodaji i informacija o

tržištu, to znanje može pomoći tvrtkama u donošenju boljih odluka, optimizaciji poslovnih procesa i povećanju prihoda.

U literaturi postoje različiti pristupi prediktivnoj analitici. Prema Gartneru (Harris, 2019), najčešće korišteni pristupi su strojno učenje, statistička analiza i dubinsko učenje. Strojno učenje je tehnika koja omogućuje računalima da nauče iz podataka bez da ih je netko izričito programirao. Statistička analiza se koristi za identificiranje statističkih veza između podataka. Dubinsko učenje je tehnika koja koristi umjetne neuronske mreže kako bi pronašla obrasce u podacima. U kontekstu diplomskog rada, primjenom prediktivne analitike na poslovne podatke o prodaji možemo predvidjeti buduće prodajne trendove te na temelju toga optimizirati procese nabave, proizvodnje i distribucije. Također, implementacijom "what-if" simulacija možemo testirati različite scenarije u simuliranim uvjetima te donijeti bolje odluke o poslovanju.

U literaturi se navodi da je implementacija prediktivne analitike u ERP sustavima složen proces koji zahtijeva dobro razumijevanje poslovnih procesa i veliku količinu kvalitetnih podataka (Davenport i Harris, 2007). Uz to, nužno je razumijevanje statističkih i strojno-učenih tehnika koje će biti primijenjene te razumijevanje softverskih rješenja koja se koriste za implementaciju.

Uz korištenje prediktivne analitike u ERP sustavu, moguće je razviti prediktivne scenarije koji se temelje na predviđanju budućih događaja i trendova. Prema Shrouf et al. (2018, str. 267), prediktivna analitika u ERP sustavima koristi različite algoritme strojnog učenja kako bi se analizirali podaci i stvorili prediktivni modeli. Ti modeli omogućuju tvrtkama da predvide buduće trendove, što im pomaže u donošenju boljih poslovnih odluka.

Primjena prediktivne analitike u ERP sustavima može pomoći tvrtkama u predviđanju potražnje za proizvodima ili uslugama, optimizaciji inventara i praćenju kretanja cijena.

Prediktivna analitika također omogućuje i korištenje različitih tehnika predviđanja kako bi se predvidjeli budući poslovni rezultati. Prema Davenportu i Harrisu (2007, str. 1), prediktivna analitika može se koristiti za predviđanje budućih financijskih rezultata tvrtke, što omogućuje tvrtkama da unaprijed planiraju svoje poslovne strategije i donose bolje poslovne odluke. U kontekstu ovog diplomskog rada, primjena prediktivne analitike za predviđanje budućih financijskih rezultata tvrtke može se primijeniti na primjeru prodaje lijekova, gdje bi se na temelju analize prodajnih podataka i drugih čimbenika, mogli razviti prediktivni scenariji o budućim financijskim rezultatima tvrtke.

Važan korak je odabrati odgovarajući prediktivni model. Jedna popularna metoda za predviđanje budućih ishoda je analiza regresije, koja se koristi za modeliranje odnosa između ovisne varijable i jedne ili više nezavisnih varijabli. Druge metode uključuju stabla odlučivanja, neuronske mreže i analizu vremenskih nizova (Gartner, 2018, str. 5).

Nakon odabira modela, on se može trenirati pomoću povijesnih podataka. To uključuje davanje modelu skupa podataka koji uključuje vrijednosti nezavisnih varijabli i odgovarajuće vrijednosti ovisne varijable. Model tada koristi ove podatke za identificiranje obrazaca i odnosa koji se mogu koristiti za predviđanje budućih vrijednosti ovisne varijable.

4.3.1. Vremenska serija predviđanja

Vremenska serija predviđanja je ključni alat u poslovnoj analitici koji se koristi za predviđanje budućih vrijednosti na temelju povijesnih podataka. U ovom poglavlju će se pružiti uvod u vremenske serije, istražiti metode analize vremenskih serija te istaknuti primjene ovog koncepta u poslovnoj analitici. Vremenska serija predstavlja niz podataka prikupljenih tijekom određenog vremenskog razdoblja. Ti podaci su zabilježeni u redoslijedu prema vremenskim točkama ili intervalima, što omogućuje analizu promjena tijekom vremena. Primjeri vremenskih serija u poslovnom kontekstu mogu obuhvaćati prodaju proizvoda tijekom mjeseci, dnevne temperaturne podatke ili broj posjetitelja web stranice po satu (Radmilović, 2012). Primjena vremenskih serija u poslovnoj analitici je široka i obuhvaća različite industrije i sektore. Neki primjeri primjene vremenskih serija uključuju predviđanje prodaje proizvoda, upravljanje zalihama, planiranje proizvodnje, optimizaciju resursa i donošenje odluka temeljenih na sezonskim ili cikličkim promjenama. Analiza vremenskih serija omogućuje organizacijama da steknu dublje uvide u svoje poslovanje, prepoznaju uzorke i trendove te donose informirane odluke za budući uspjeh.

Metode vremenskih serija su sljedeće (Radmilović, 2012):

1. Trend analiza

Trend analiza je tehnika koja se koristi za identifikaciju dugoročnih trendova ili promjena u vremenskim serijama. Ova analiza omogućuje identifikaciju općeg smjera kretanja podataka, kao što je rast, pad ili stagnacija. Trend analiza može biti korisna u predviđanju budućih vrijednosti i donošenju strateških odluka temeljenih na promjenama u trendu.

2. Sezonska analiza

Sezonska analiza se fokusira na identifikaciju periodičnih uzoraka u vremenskim serijama. Ova tehnika otkriva ponavljajuće obrasce koji se javljaju unutar određenih razdoblja, kao što su sezonske promjene tijekom godine, tjedna ili dana. Sezonska analiza omogućuje organizacijama da pravovremeno reagiraju na sezonske fluktuacije i optimiziraju svoje poslovanje.

3. Ciklička analiza

Ciklička analiza prepoznaje dulje cikličke obrasce koji nisu vezani za sezonalnost, već su rezultat drugih ekonomskih, socijalnih ili tehničkih faktora. Ova analiza identificira trendove koji se ponavljaju u dužem vremenskom razdoblju, poput ekonomskih ciklusa ili trendova u industriji. Razumijevanje cikličkih uzoraka može pomoći organizacijama da se prilagode promjenjivim uvjetima tržišta i iskoriste povoljne faze ciklusa.

4. Slučajne fluktuacije

Slučajne fluktuacije predstavljaju neregularne promjene u vremenskim serijama koje nisu povezane s trendovima, sezonskim ili cikličkim uzorcima. Ove fluktuacije često predstavljaju slučajne i nepredvidive događaje ili greške u podacima. Analiza slučajnih fluktuacija može pomoći u prepoznavanju iznimnih situacija ili odstupanja od očekivanih vrijednosti.

4.3.2. Regresija

Regresija je statistička tehnika koja se koristi u poslovnoj analitici za predviđanje vrijednosti kontinuirane varijable temeljem njezine veze s drugim varijablama. Ova tehnika omogućuje razumijevanje veza između varijabli i identifikaciju faktora koji najviše utječu na ciljanu varijablu. Regresija ima široku primjenu u poslovnoj analitici. Njena primjena obuhvaća predviđanje prodaje, optimizaciju cijena, upravljanje rizicima, analizu tržišta i mnoge druge poslovne scenarije. Korištenje regresijskih modela pomaže organizacijama u donošenju informiranih odluka temeljenih na kvantitativnim podacima (Montgomery i sur., 2012).

4.3.2.1. Linearna regresija

Razlikuju se sljedeće linearne regresije (Montgomery i sur., 2012):

1. Jedna nezavisna varijabla

Linearna regresija s jednom nezavisnom varijablom koristi se za predviđanje vrijednosti ovisne varijable temeljem samo jedne varijable. Ova tehnika pretpostavlja linearnu vezu između varijabli i koristi se za identifikaciju najbolje prilagođene linije podacima.

2. Više nezavisnih varijabli

Kada postoje više nezavisnih varijabli, koristi se višestruka linearna regresija. Ova tehnika omogućuje predviđanje vrijednosti ovisne varijable uzimajući u obzir više faktora. Regresijski koeficijenti pružaju informacije o utjecaju svake nezavisne varijable na ovisnu varijablu. Regresijski koeficijenti su mjerne vrijednosti koje opisuju vezu između nezavisnih i ovisne

varijable u linearnoj regresiji. Interpretacija ovih koeficijenata pomaže razumjeti koliko svaka nezavisna varijabla doprinosi promjeni ovisne varijable.

4.3.2.2. Nelinearna regresija

Razlikuju se sljedeće nelinearne regresije (Montgomery i sur., 2012):

1. Polinomijalna regresija

Polinomijalna regresija koristi se kada postoji nelinearna veza između varijabli. Ova tehnika modelira krivulje koje najbolje odgovaraju podacima korištenjem polinomijalnih funkcija. Polinomijalna regresija omogućuje modeliranje složenijih veza i prilagodbu podacima koji ne slijede linearni obrazac.

2. Logistička regresija

Logistička regresija koristi se kada želimo predviđati binarnu ovisnu varijablu. Ova tehnika se primjenjuje u situacijama gdje želimo klasificirati podatke u dvije kategorije temeljem nezavisnih varijabli. Logistička regresija pruža vjerojatnosti pripadnosti određenoj kategoriji.

4.3.3. Klasifikacija

Prema Hastelu i sur. (2009) klasifikacija je tehnika strojnog učenja koja se koristi za kategorizaciju podataka u određene klase ili kategorije. Cilj klasifikacije je naučiti model koji može automatski dodijeliti ispravnu klasu novim, neviđenim primjerima na temelju njihovih karakteristika. Klasifikacija je široko primijenjena tehnika u poslovnoj analitici za donošenje informiranih odluka i predviđanje budućih događaja. Za razliku od regresije, kod klasifikacije se ne predviđa kontinuirano vrijednost, već se ulaz x svrstava u jednu od klasa y . Ako se za primjer uzme binarna klasifikacija, tada vrijednost y može biti samo 0 ili 1. Klasifikacija se široko primjenjuje u poslovnoj analitici za različite svrhe. Primjeri primjene uključuju klasifikaciju kupaca prema njihovim preferencijama, predviđanje korisničkog churninga, detekciju prijevara, segmentaciju tržišta i personalizaciju marketinških kampanja. Korištenje klasifikacijskih algoritama omogućuje organizacijama da donose informirane odluke i prilagođavaju svoje strategije temeljem analize podataka o klasifikaciji.

Najpoznatiji algoritmi strojnog učenja za klasifikaciju su (Hastle i sur., 2009):

1. Stabla odlučivanja

Stabla odlučivanja su grafički prikazi koji pomažu u donošenju odluka na temelju skupa uvjeta ili atributa. Ovi algoritmi koriste hijerarhijsku strukturu stabla kako bi klasificirali podatke prema

određenim pravilima. Stabla odlučivanja su interpretabilna i mogu se koristiti za pronalaženje ključnih značajki koje utječu na klasifikaciju.

2. K najbližih susjeda (KNN)

Algoritam K najbližih susjeda (KNN) klasificira nove primjere na temelju sličnosti s poznatim primjerima u skupu podataka. KNN koristi udaljenost između primjera i pronalazi K najbližih susjeda kako bi odredio klasu novog primjera. Ovaj algoritam je jednostavan za razumijevanje i može se koristiti za probleme s klasifikacijom s kontinuiranim ili kategoričkim značajkama.

3. Logistička regresija

Logistička regresija je algoritam klasifikacije koji se koristi za predviđanje vjerojatnosti pripadnosti nekoj klasi. Ovaj algoritam modelira logističku funkciju kako bi predvidio vjerojatnost da primjer pripada određenoj klasi. Logistička regresija je popularna tehnika u poslovnoj analitici zbog svoje jednostavnosti i interpretabilnosti rezultata.

4. Klasifikacijske neuronske mreže

Klasifikacijske neuronske mreže su složeni modeli koji koriste neuronske mreže za klasifikaciju podataka. Ovi algoritmi koriste skup slojeva neurona koji obrađuju i transformiraju ulazne podatke kako bi dobili klasifikacijski rezultat. Klasifikacijske neuronske mreže mogu modelirati složene veze između značajki i klasa te se često koriste za probleme s velikim skupom podataka.

4.4. Strukture podataka za proširenu analitiku

Analitika podataka postaje sve složenija i sofisticiranija kako se organizacije susreću s velikim količinama podataka. Za kvalitetnu i učinkovitu analizu podataka, ključno je imati dobro strukturirane i organizirane podatke. U ovom poglavlju razmatraju se neke od struktura podataka koje se koriste u proširenoj analitici.

4.4.1. Relacijska baza podataka

Varga (2020) navodi da je relacijska baza podataka jedna od najčešće korištenih struktura podataka za organiziranje podataka u proširenoj analitici. Relacijska baza podataka sastoji se od skupa tablica koje su povezane prema određenim pravilima. Tablice sadrže podatke koji se organiziraju u retke i stupce. Svaki redak u tablici predstavlja jedan zapis, dok stupci predstavljaju attribute ili karakteristike zapisa. Relacijska baza podataka omogućuje korisnicima da brzo i lako pretražuju i organiziraju podatke.

4.4.2. NoSQL baze podataka

NoSQL baze podataka su relativno nova tehnologija koja se koristi za pohranjivanje velikih količina nestrukturiranih podataka. NoSQL baze podataka koriste različite strukture podataka, poput hijerarhijskih baza podataka, grafičkih baza podataka i ključ-vrijednost baza podataka. Ove baze podataka nude brži pristup podacima u odnosu na relacijske baze podataka, posebno kada je riječ o velikim količinama podataka (MongoDB, 2022).

Prema MongoDB (2022) NoSQL (eng. *Not Only SQL*) baze podataka su nastale kao alternativa tradicionalnim relacijskim bazama podataka, s ciljem rješavanja izazova vezanih za rukovanje velikim količinama podataka, brze promjene strukture podataka i potrebu za horizontalnom skalabilnošću. One su posebno korisne u situacijama kada je potrebno pohraniti i obraditi nestrukturirane ili polustrukturirane podatke, kao što su tekstualni dokumenti, senzorski podaci, log datoteke, društveni mediji i slično. Jedna od ključnih karakteristika NoSQL baza podataka je fleksibilna shema. To znači da nema unaprijed definirane tablice ili stupci kao u relacijskim bazama podataka. Umjesto toga, podaci se organiziraju u kolekcije, dokumente, grafove ili ključ-vrijednost parove, ovisno o vrsti NoSQL baze podataka koja se koristi. Ova fleksibilnost omogućuje brže prilagođavanje promjenama u strukturi podataka i pojednostavljuje rukovanje raznolikim tipovima podataka.

NoSQL baze podataka nude i horizontalnu skalabilnost, što znači da se mogu lako proširivati na više servera kako bi se nosile s velikim opterećenjem i zahtjevima za obradu podataka. Ovo je osobito važno u scenarijima gdje su potrebne visoke performanse i brzi odziv. Primjena NoSQL baza podataka je raznolika. Na primjer, u web aplikacijama se često koriste za pohranu i obradu korisničkih profila, logova, preporuka, kao i podataka iz društvenih mreža. U području velikih podataka (Big Data), NoSQL baze podataka se često koriste za brzo pohranjivanje i obradu ogromnih količina podataka. Iako NoSQL baze podataka pružaju brojne prednosti, važno je imati na umu da su one namijenjene za specifične scenarije i ne zamjenjuju relacijske baze podataka u svim situacijama. Izbor između NoSQL i relacijskih baza podataka ovisi o specifičnim zahtjevima projekta, tipu podataka i očekivanim performansama (MongoDB, 2022).


4.4.3. Dinamička veza s podacima

Dinamička veza s podacima je tehnologija koja omogućuje izravan pristup i korištenje stvarnih podataka iz izvora u stvarnom vremenu. Ova tehnologija ima sve veći značaj u području poslovne analitike i omogućuje organizacijama da donose informirane odluke temeljene na najnovijim i ažuriranim podacima. Live veza s podacima omogućuje direktnu vezu između analitičkih alata i izvora podataka, što eliminira potrebu za prethodnim izvlačenjem,

transformiranjem i učitavanjem podataka (ETL proces). Umjesto toga, podaci se mogu prikazivati i analizirati u stvarnom vremenu, što rezultira bržim pristupom informacijama i mogućnošću trenutnog reagiranja na promjene (SAP, 2020).

Za SAP Analytics Cloud, koji se obrađuje u praktičnom djelu ovog diplomskog rada, se koristi struktura podataka nazvana "live data connection". To je vrsta strukture podataka koja omogućuje povezivanje izvora podataka u stvarnom vremenu, omogućujući korisnicima da vide najnovije podatke i donose odluke temeljene na ažuriranim podacima. Live data connection također omogućuje korisnicima da rade s velikim skupovima podataka koji se mogu dinamički filtrirati i agregirati, a istovremeno zadržavajući brzinu i performanse. SAP Analytics Cloud podržava brojne vrste live data connection izvora podataka, uključujući SAP HANA, SAP BW/4HANA, SAP S/4HANA, SQL baze podataka, Excel i druge. Povezivanje s izvorom podataka ostvaruje se putem odgovarajućeg konektora za svaki izvor podataka (SAP, 2020). Slika 4 prikazuje način dinamičke veze s podacima u kontekstu SAP Analytics Clouda.

Slika 4. Dinamička veza s podacima



Izvor: <https://www.trugua.com/sap-analytics-cloud-live-connections-first-step/>

Live data connection omogućuje i "smart data discovery" funkcionalnost, koja korisnicima omogućuje automatsko otkrivanje veza i uzoraka u podacima. Također podržava "what-if" analize i simulacije, omogućujući korisnicima da naprave različite scenarije i procjene kako bi donijeli najbolje odluke. Uz live data connection, SAP Analytics Cloud također podržava i "import data" opciju, koja omogućuje korisnicima da uvoze podatke iz različitih izvora, poput

CSV datoteka ili Excel tablica, i stvore "dataset" strukture podataka. Ove dataset strukture podataka se mogu koristiti za kreiranje vizualizacija i izvještaja u SAP Analytics Cloud (SAP, 2022).

4.5. Dinamičko izvještavanje kroz predikcije i simulacije

Dinamičko izvještavanje je proces koji se koristi za stvaranje izvještaja koji se ažuriraju u stvarnom vremenu kako bi odražavali najnovije podatke. Dinamičko izvještavanje postalo je ključno u proširenoj analitici jer korisnicima omogućuje da brzo i lako pristupe najnovijim informacijama. Jedna od metoda dinamičkog izvještavanja je korištenje predikcija i simulacija za stvaranje projekcija budućih trendova.

Predikcije se koriste za predviđanje budućih događaja na temelju prethodnih podataka. Predikcije se mogu koristiti za stvaranje izvještaja o budućim trendovima u prodaji, proizvodnji ili financijama. Simulacije, s druge strane, simuliraju buduće scenarije na temelju prethodnih podataka kako bi se procijenio učinak određenih strategija. Primjerice, simulacije se mogu koristiti za procjenu učinka različitih marketinških strategija ili za određivanje najbolje lokacije za otvaranje nove prodavaonice (Varga, 2020).

Prediktivna analitika i what-if simulacija su dvije različite metode analize podataka koje se koriste u poslovnom okruženju. Prediktivna analitika se bavi predviđanjem budućih događaja ili trendova temeljem povijesnih podataka i statističkih metoda. To uključuje primjenu različitih algoritama strojnog učenja, statističkih modela i drugih tehnika za izradu predikcija o tome što će se dogoditi u budućnosti (Budgaga i sur, 2016, str. 368). S druge strane, what-if simulacije se bave testiranjem različitih scenarija i situacija kako bi se vidjelo kako bi se mogli promijeniti određeni ishodi. To uključuje promjenu ulaznih parametara i analizu njihovog utjecaja na izlazne vrijednosti. What-if simulacije se najčešće koriste u planiranju i odlučivanju o strategijama, a mogu se koristiti za testiranje različitih mogućnosti i pronalaženje najboljeg puta prema cilju.

Prediktivna analitika se bavi predviđanjem onoga što će se dogoditi u budućnosti, dok se what-if simulacije bave testiranjem mogućih scenarija i njihovih posljedica. U mnogim slučajevima, ta dva pristupa se mogu koristiti zajedno kako bi se izradile najbolje poslovne strategije i odluke, što će se vidjeti u praktičnom djelu diplomskog rada.

4.5. Primjeri primjene u industriji

Industrijski sektor predstavlja jedno od ključnih područja primjene poslovne analitike. Kroz analizu podataka i primjenu naprednih analitičkih tehnika, organizacije u industriji mogu ostvariti značajne prednosti u poboljšanju efikasnosti, optimizaciji procesa te donošenju informiranih poslovnih odluka. U ovom potpoglavlju pružit ćemo pregled nekoliko primjera primjene poslovne analitike u industriji, s naglaskom na prediktivnu analitiku (Chen i sur., 2012, str. 1165-1188).

Prediktivna analitika, kao jedna od ključnih grana poslovne analitike, omogućuje organizacijama da predvide buduće događaje, identificiraju trendove, modeliraju rizike i donose informirane odluke. U industrijskom kontekstu, primjena prediktivne analitike donosi brojne mogućnosti za optimizaciju poslovnih procesa i povećanje konkurentnosti. U ovom potpoglavlju detaljnije će se istražiti primjere primjene prediktivne analitike u nekoliko ključnih područja industrije. Fokusirat će se na primjenu u proizvodnji, logistici, financijama i marketingu. Kroz ove primjere, bit će ilustrirane konkretne situacije u kojima organizacije koriste prediktivnu analitiku kako bi ostvarile bolje rezultate i ostvarile prednosti na tržištu. Ovaj pregled primjene poslovne analitike u industriji pružit će uvid u širinu mogućnosti koje ova disciplina nudi te naglasiti važnost korištenja analitičkih alata i tehnika za ostvarivanje poslovnog uspjeha u industrijskom sektoru.

4.5.1. Primjena prediktivne analitike u proizvodnji

U proizvodnoj industriji, primjena prediktivne analitike ima značajnu ulogu u optimizaciji procesa proizvodnje i poboljšanju ukupne učinkovitosti. Korištenjem prediktivnih modela, organizacije mogu predvidjeti potrebe za resursima, optimizirati planiranje proizvodnje, identificirati potencijalne kvarove opreme te donositi informirane odluke o održavanju i nadogradnji. Ovi modeli koriste podatke o proizvodnji, sensorima, kvaliteti i drugim relevantnim faktorima kako bi predvidjeli performanse proizvodnje i pružili smjernice za poboljšanja.

U proizvodnji, primjena prediktivne analitike omogućuje organizacijama da optimiziraju proizvodne kapacitete, upravljaju zalihama, predvide potrebe za održavanjem i poboljšaju kvalitetu proizvoda. Kroz analizu velikih količina podataka o proizvodnim linijama, sirovinama, radnim uvjetima i drugim faktorima, mogu se identificirati ključni pokazatelji performansi i donijeti informirane odluke koje vode povećanju učinkovitosti i smanjenju troškova (Chen i sur., 2012). U tablici 4 su prikazani primjeri primjene prediktivne analitike u proizvodnji, zajedno s opisom svakog primjera i istaknutim prednostima koje organizacije mogu ostvariti korištenjem prediktivne analitike. Ovi primjeri ilustriraju konkretne situacije u kojima se prediktivna analitika

koristi za unaprjeđenje proizvodnih procesa, optimizaciju planiranja i održavanje opreme te poboljšanje kvalitete proizvoda.

Tablica 4. Primjeri primjene prediktivne analitike u proizvodnji

Primjer	Opis	Prednosti
Planiranje proizvodnje	Korištenje prediktivne analitike za procjenu potražnje, optimizaciju proizvodnih kapaciteta i planiranje proizvodnih redova.	Smanjenje zaliha i troškova
		Povećanje točnosti planiranja
		Optimizacija resursa
Prediktivno održavanje	Upotreba analitike za praćenje stanja opreme i predviđanje potrebe za održavanjem kako bi se spriječili kvarovi i smanjili zastoji proizvodnje.	Smanjenje troškova održavanja
		Povećanje raspoloživosti opreme
		Poboljšanje produktivnosti
Kvaliteta proizvoda	Primjena analitike za praćenje kvalitete proizvoda i identifikaciju faktora koji utječu na kvalitet radi poboljšanja procesa proizvodnje.	Smanjenje nekvalitetnih proizvoda
		Poboljšanje zadovoljstva kupaca
		Povećanje učinkovitosti procesa
Proaktivno upravljanje zastojima	Korištenje analitike za praćenje parametara opreme i prepoznavanje uzoraka koji ukazuju na moguće zastoje u proizvodnji te poduzimanje preventivnih mjera.	Smanjenje vremena zastoja
		Povećanje dostupnosti opreme
		Optimizacija rasporeda održavanja

Izvor: vlastita izrada; prema Chen i sur. (2012)

4.5.2. Primjena prediktivne analitike u logistici

Kako navode Chen i sur. (2012), u području logistike, prediktivna analitika igra važnu ulogu u optimizaciji lanca opskrbe i poboljšanju operativne učinkovitosti. Korištenjem analize podataka, organizacije mogu predvidjeti potražnju, optimizirati rute i planiranje dostave, upravljati zalihama i smanjiti troškove transporta. Primjena prediktivnih modela omogućuje organizacijama da donose informirane odluke o logističkim procesima, minimiziraju kašnjenja i poboljšaju cjelokupnu kvalitetu usluge.

U logistici, prediktivna analitika omogućuje optimizaciju lanca opskrbe, upravljanje zalihama i predviđanje potreba za transportom. Kroz analizu podataka o potražnji, vremenskim uvjetima, prometu i drugim relevantnim faktorima, organizacije mogu usmjeriti svoje resurse na najučinkovitije načine isporuke proizvoda, smanjiti vrijeme isporuke i troškove transporta te poboljšati ukupnu logističku operativu (Chen i sur., 2012).

4.5.3. Primjena prediktivne analitike u financijama

U financijskom sektoru, prediktivna analitika ima široku primjenu u predviđanju financijskih performansi, upravljanju rizicima i prevenciji prijevara. Korištenjem naprednih modela, organizacije mogu predvidjeti buduće trendove tržišta, analizirati kreditni rizik, optimizirati portfelje investicija te otkrivati nepravilnosti i sumnjive aktivnosti. Ovi modeli koriste podatke o financijskim transakcijama, povijesnim podacima, ekonomskim indikatorima i drugim relevantnim faktorima kako bi pružili informacije za donošenje financijskih odluka (Chen i sur., 2012).

U financijama, prediktivna analitika igra ključnu ulogu u predviđanju financijskih trendova, upravljanju rizicima i identifikaciji mogućnosti za povećanje prihoda. Kroz analizu financijskih podataka, tržišnih pokazatelja, makroekonomskih faktora i drugih informacija, organizacije mogu donijeti informirane odluke o investicijama, upravljanju portfeljima, procjeni kreditnog rizika i optimizaciji financijskih rezultata. Tablica 5 prikazuje primjere primjene prediktivne analitike u financijama.

Tablica 5. Primjeri primjene prediktivne analitike u financijama

Primjer	Opis	Prednosti
Predviđanje trendova na tržištu dionica	Korištenje prediktivne analitike za predviđanje budućih trendova na tržištu dionica.	Identifikacija povoljnih trenutaka za kupnju ili prodaju dionica

		Optimizacija ulaganja i smanjenje rizika
		Poboljšanje odluka temeljenih na informacijama
Kreditno ocjenjivanje	Analiza podataka o klijentima i financijskim transakcijama radi procjene kreditne sposobnosti.	Brže donošenje odluka o kreditiranju
		Smanjenje rizika od neizvršenja plaćanja
		Personalizirani pristup prema klijentima
Analiza prevare	Otkrivanje potencijalnih prijevara u financijskim transakcijama i aktivnostima.	Smanjenje gubitaka zbog prijevara
		Brže otkrivanje i reagiranje na sumnjive aktivnosti
		Poboljšanje sigurnosti financijskih sustava
Predviđanje trendova potrošnje	Predviđanje budućih trendova potrošnje temeljeno na analizi podataka o prethodnim potrošačkim obrascima.	Planiranje zaliha i opskrbe
		Personalizacija marketinških kampanja
		Poboljšanje korisničkog iskustva i zadovoljstva

4.5.4. Primjena prediktivne analitike u marketingu


U području marketinga, prediktivna analitika omogućuje organizacijama da bolje razumiju svoje ciljno tržište, personaliziraju marketinške kampanje i poboljšaju stope konverzije. Korištenjem prediktivnih modela, organizacije mogu predvidjeti potencijalne kupce, segmentirati tržište, prepoznati preferencije i potrebe kupaca te optimizirati marketinške napore. Ovi modeli koriste podatke o kupovnom ponašanju, demografskim informacijama, digitalnim tragovima i drugim relevantnim faktorima kako bi pružili smjernice za kreiranje učinkovitih marketinških strategija (Chen i sur., 2012)

U marketingu, prediktivna analitika pruža mogućnost ciljanja prave publike, personalizaciju marketinških kampanja i optimizaciju marketinških resursa. Analizom podataka o ponašanju potrošača, demografskim informacijama, preferencijama i drugim relevantnim faktorima, organizacije mogu identificirati potencijalne kupce, predvidjeti njihove potrebe i preferencije te prilagoditi marketinške aktivnosti kako bi ostvarile bolje rezultate i povećale povrat ulaganja.

Prema Golubić (2018, str. 23), u posljednjim godinama sve veći broj poduzeća prepoznaje ključnu važnost kupaca u svom poslovanju. Fokusiranje na kupca postavlja upravljanje odnosima s kupcima kao jedan od najznačajnijih projekata mnogih poduzeća. Tom Peters, renomirani američki stručnjak za upravljanje i poslovnu izvrsnost, ističe potpunu orijentaciju prema bliskosti s kupcima kao jedno od osam temeljnih načela za postizanje izvrsnosti u poslovanju. U svakom poduzeću postoje različite informacije o kupcima koje su raspršene na različitim mjestima, stoga je ključno objediniti ove informacije prikupljene kroz kontakte poduzeća i kupaca na jednom mjestu. Upravljanje odnosima s kupcima zahtijeva složen pristup koji počinje s misijom, vizijom, kulturom i strategijom poduzeća. Ove elemente je potrebno preispitati i promijeniti kako bi se postiglo pozicioniranje kupca u središtu razmišljanja i djelovanja poduzeća. Prije nego što poduzeće implementira sustav upravljanja odnosima s kupcima (CRM), važno je temeljito razmotriti prednosti i nedostatke ove marketinške strategije te procijeniti koliko je ona prikladna za specifično poslovanje poduzeća. Promjena paradigme od masovne proizvodnje i prodaje do direktnog kontakta s kupcima rezultirala je potrebom za obnovom dugoročnih odnosa s kupcima. Marketing se transformirao od masovnog marketinga do ciljanog marketinga i direktnog marketinga, koji karakterizira interaktivna segmentacija tržišta, zadovoljavanje trenutnih potreba potrošača i interakcija između poduzeća i kupaca. Alat koji omogućava direktni marketing je upravo CRM sustav.

Slika 5 prikazuje kombinaciju različitih mehanizama marketinške automatizacije, iz koje je trenutno neizostavan dio alati za predviđanje i CRM.

Slika 5. Marketinška automatizacija



Izvor: Perkuto (2023)

4.6. Izazovi i ograničenja implementacije

Implementacija prediktivne analitike u poslovnom okruženju donosi brojne izazove i ograničenja koji mogu utjecati na uspješnost projekta. U ovom poglavlju razmotrit će se neki od ključnih izazova i ograničenja s kojima se organizacije suočavaju prilikom implementacije prediktivne analitike.

4.6.1. Ograničenja ERP sustava u integraciji s prediktivnom analitikom

ERP predstavljaju temeljnu infrastrukturu za upravljanje poslovnim procesima u organizacijama. Unatoč svojoj važnosti, ERP sustavi često imaju ograničenja u integraciji s prediktivnom analitikom. Ovi sustavi su obično dizajnirani za transakcijske procese i prikupljanje podataka, dok je analiza i predikcija podataka složenija zadaća koja zahtijeva specifične alate i tehnike. Integracija ERP sustava s prediktivnom analitikom može biti izazovna jer zahtijeva prilagodbu postojeće infrastrukture, uključujući strukturu podataka, modele i algoritme za analizu podataka (Davenport i sur., 2004, str. 17).

Jedno od glavnih ograničenja je nedostatak podrške za naprednu analitiku unutar samog ERP sustava. Tradicionalno, ERP sustavi su dizajnirani za prikupljanje, pohranu i obradu operativnih podataka, ali nisu bili prilagođeni za napredne analitičke funkcionalnosti poput prediktivne analitike. To može predstavljati izazov za organizacije koje žele iskoristiti potencijal prediktivne analitike u svom ERP okruženju. Drugo ograničenje je vezano uz kompleksnost i statičnost ERP sustava. ERP sustavi često imaju složenu strukturu i teško se prilagođavaju promjenama i inovacijama. To može otežati integraciju novih tehnologija i modela prediktivne analitike u postojeći ERP okvir. Potrebno je dodatno prilagođavanje i konfiguracija ERP sustava kako bi se omogućila integracija s naprednim analitičkim rješenjima (Davenport i sur., 2004, str. 18).

Također, prema Devenportu i sur. (2004) ograničenja u vezi s kvalitetom podataka mogu predstavljati izazov pri integraciji prediktivne analitike u ERP sustav. To uključuje nedostatke u strukturi podataka, nekonzistentnost, nedostatak relevantnih ili dovoljno detaljnih podataka potrebnih za izgradnju i validaciju modela prediktivne analitike. Održavanje visoke kvalitete podataka u ERP sustavu ključno je za uspješnu primjenu prediktivne analitike. Da bi se prevladala ta ograničenja, organizacije mogu razmotriti dodatne alate i platforme za analitiku koji se mogu integrirati s njihovim ERP sustavom. Također, važno je uložiti napore u poboljšanje kvalitete podataka unutar ERP sustava i uspostaviti jasne procese za prikupljanje, pohranu i upravljanje podacima potrebnim za prediktivnu analitiku.

4.6.2. Etička pitanja u korištenju prediktivne analitike

Primjena prediktivne analitike može se suočiti s raznim etičkim pitanjima koja proizlaze iz prikupljanja, analize i korištenja podataka. Kao što prediktivna analitika koristi podatke o korisnicima, postavlja se pitanje privatnosti i sigurnosti podataka. Organizacije moraju biti svjesne i poštivati zakonske i regulatorne zahtjeve vezane uz zaštitu podataka i privatnost korisnika. Također, postoji rizik od pristranosti i diskriminacije u analizi podataka, posebno u kontekstu zapošljavanja, kreditiranja ili profiliranja korisnika. Etičko korištenje prediktivne analitike zahtijeva transparentnost, odgovornost i pažljivo upravljanje podacima kako bi se osiguralo pravedno i pravilno korištenje tehnologije.

Navest će se neki od primjera etičkih pitanja koja su obuhvaćena u Okviru etičkih aspekata umjetne inteligencije, robotike i s njima povezanih tehnologija Europskog parlamenta (2020):

1. Transparentnost i odgovornost: Kako osigurati transparentnost i objašnjivost algoritama koji koriste prediktivnu analitiku? Tko je odgovoran za rezultate i posljedice njihove primjene?

2. Diskriminacija i pristranost: Kako spriječiti diskriminaciju i pristranost u algoritmima prediktivne analitike? Jesu li kriteriji i podaci na kojima se temelje modeli dovoljno raznoliki i reprezentativni?
3. Privatnost i sigurnost podataka: Kako osigurati zaštitu privatnosti i sigurnost podataka koji se koriste u prediktivnoj analitici? Koji su mehanizmi za sprječavanje neovlaštenog pristupa ili zloupotrebe podataka?
4. Ljudska autonomija i nadzor: Kako osigurati da algoritmi prediktivne analitike ne ograničavaju ljudsku autonomiju i donošenje slobodnih odluka? Kako se osigurava nadzor nad primjenom tehnologije?
5. Etička upotreba: Kako osigurati da se prediktivna analitika primjenjuje na etičan način? Jesu li definirani jasni etički okviri i smjernice za korištenje te tehnologije?

Kroz razumijevanje i adresiranje ovih izazova i ograničenja, organizacije mogu bolje pripremiti se za uspješnu implementaciju prediktivne analitike i ERP sustava te iskoristiti njezine potencijale za unaprjeđenje poslovnih procesa i donošenje informiranih odluka.

4.7. Budući razvoj i trendovi

Prediktivna analitika je područje koje se kontinuirano razvija i donosi nove trendove i inovacije. U budućnosti, možemo očekivati sljedeće trendove u prediktivnoj analitici (Hsieh, 2017, str. 35-40):

1. Povećana primjena strojnog učenja i dubokog učenja: Napredak u tehnologijama strojnog učenja, posebno dubokog učenja, otvara nove mogućnosti za analizu i predviđanje složenih uzoraka u podacima. Ovi algoritmi mogu donijeti dublje uvide i poboljšati prediktivne modele.
2. Integracija s velikim podacima: Kako se količina dostupnih podataka stalno povećava, integracija prediktivne analitike s analizom velikih podataka postaje sve važnija. Kombinacija prediktivne analitike i analize velikih podataka omogućuje organizacijama da pronađu skrivene uzorke i donesu informirane odluke.
3. Automatizacija i autonomija: U budućnosti, prediktivna analitika će se sve više koristiti za automatizaciju procesa i donošenje autonomnih odluka. Napredni algoritmi mogu prepoznati uzorke, predvidjeti buduće događaje i samostalno poduzeti odgovarajuće akcije.

4.7.2. Razvoj ERP sustava i integracija s analitičkim alatima

ERP sustavi su vitalni dio poslovnih organizacija, a budući razvoj ovih sustava obuhvaća integraciju s analitičkim alatima radi poboljšanja njihove funkcionalnosti. Neki od budućih trendova u razvoju ERP sustava i integraciji s analitičkim alatima uključuju ugrađenu analitiku. Budući ERP sustavi će sve više imati ugrađene analitičke mogućnosti koje će omogućiti organizacijama da izravno pristupaju i analiziraju svoje poslovne podatke unutar ERP sustava. To će smanjiti potrebu za izvozom podataka u zasebne analitičke alate (Hsieh, 2017). Također je važno spomenuti i naprednu vizualizaciju podataka. Vizualizacija podataka postaje sve važnija za razumijevanje i prezentaciju rezultata analize. Budući ERP sustavi će podržavati napredne vizualizacijske alate koji će omogućiti korisnicima da intuitivno istražuju i prikazuju rezultate analize.

Budući razvoj ERP sustava i integracija s analitičkim alatima ide u smjeru povećane automatizacije i umjetne inteligencije. Očekuje se da će ERP sustavi koristiti napredne algoritme strojnog učenja i tehnike obrade prirodnog jezika kako bi analizirali i interpretirali velike količine podataka te donosili prediktivne i automatizirane odluke. Integracija umjetne inteligencije omogućit će sustavima da prepoznaju obrasce, identificiraju trendove i pruže korisne uvide koji će podržati donošenje odluka na višoj razini (Hsieh, 2017).

4.7.3. Potencijalne primjene umjetne inteligencije u ERP sustavima

Umjetna inteligencija (*eng. artificial intelligence*) ima veliki potencijal za transformaciju ERP sustava i unapređenje njihove funkcionalnosti. Neki od potencijalnih primjena AI u ERP sustavima uključuju (Hsieh, 2017):

1. Automatizacija rutinskih zadataka: AI tehnike poput robotskog procesnog automatizma (RPA) mogu automatizirati rutinske zadatke unutar ERP sustava, oslobađajući ljudske resurse za složenije i kreativnije poslove.
2. Poboljšana prediktivna analitika: Primjena AI u prediktivnoj analitici može rezultirati naprednim modelima koji mogu predvidjeti trendove, donositi odluke i preporučivati akcije s većom preciznošću.
3. Unaprijeđeno upravljanje podacima: AI tehnike poput strojnog učenja i obrade prirodnog jezika mogu poboljšati upravljanje podacima unutar ERP sustava. To uključuje klasifikaciju, strukturiranje i pretraživanje podataka radi bržeg pristupa i analize.
4. Personalizirano korisničko iskustvo: Primjena AI u ERP sustavima može omogućiti personalizirano korisničko iskustvo prilagođeno individualnim

potrebama korisnika. To može uključivati personalizirane preporuke, prilagođene izvještaje i intuitivno sučelje.

5. Praktična primjena

Praktični dio diplomskog rada izrađen je korištenjem SAP Analytics Clouda, koji je prethodno bio opisan u teorijskom djelu rada. SAC je samo jedan od alata za prediktivnu analitiku i izvještavanje te će se on koristiti kako bi se tema prikazala u praksi.

U praktičnom dijelu diplomskog rada, analizirat će se podaci fiktivnog farmaceutskog poduzeća koje se bavi prodajom lijekova. Cilj je proučiti njihov prodajni model i primijeniti what-if analizu kako bi se istražile mogućnosti povećanja određenih faktora (npr. cijena ili bruto marža). Skup podataka sastoji se od informacija o različitim lijekovima, identifikacijskim brojevima SKU, klijentima, datumima prodaje i volumenima prodaje. Također, skup podataka sadrži detalje o karakteristikama svakog SKU-a, kao što su marka, poslovna jedinica, terapijsko područje, cijena po jedinici i trošak prodane robe (COGS) po jedinici. Osim toga, skup podataka ima informacije o klijentima, uključujući postotke osnovnog popusta i popusta za promocije.

Promatra se poduzeće i njegov prodajni model kako bi se razumjela njihova prodaja i identificirale mogućnosti za povećanje bruto marže. Kroz what-if analizu, ima se mogućnost eksperimentiranja s promjenom cijena SKU-ova i postotaka popusta za odabrane klijente te procjenjuje njihov utjecaj na poslovanje poduzeća.

Analiza ovog fiktivnog poduzeća pružit će vrijedan uvid u praksu primjene analitičkih alata u farmaceutskoj industriji. Ova vrsta istraživanja omogućuje donositeljima odluka da donose informirane odluke o strategijama prodaje, optimizaciji cijena i upravljanju popustima kako bi ostvarili veću bruto maržu i povećali uspješnost svog poslovanja. Kroz analizu ovih podataka, pokušava se identificirati ključne pokazatelje prodaje, pratiti njihovu dinamiku tijekom vremena i istražiti kako promjene u cijenama i popustima mogu utjecati na bruto maržu. Sveukupno, ovaj praktični dio pružit će praktičan uvid u primjenu analitičkih alata u farmaceutskoj industriji te će pomoći u razumijevanju i optimizaciji prodajnog modela ovog fiktivnog poduzeća.

5.1. Definiranje modela

U ovom poglavlju definira se model podataka kroz njegovu samu izradu te identifikaciju svih faktora koji su međusobno povezani i utječu na model.

5.1.1. Skup podataka i postavljanje modela

Praktični dio diplomskog rada koncentrirat će se na fiktivno farmaceutsko poduzeće, čiji su podaci preuzeti s Farseera. Tablica koja je korištena u radu sadrži informacije o različitim lijekovima, njihovim SKU (identifikacijskim brojevima), klijentima, datumima, volumenima prodaje i godini. Skup podataka koji je korišten za daljnju analizu u svrhu izrade diplomskog rada radi se o različitim vrstama lijekova koji je podijeljen na sljedeće listove u Farseer excel dokumentu:

1. "Master Data SKUs": Ovaj list sadrži podatke o SKU-ovima (identifikacijski brojevi) fiktivne farmaceutske tvrtke. Za svaki SKU su navedene karakteristike kao što su marka, poslovna jedinica, terapijsko područje, status promocije, cijena po jedinici i trošak prodane robe (COGS) po jedinici.
2. "Master Data Clients": Ovaj list sadrži informacije o klijentima tvrtke. Za svakog klijenta su definirani postotak osnovnog popusta i postotak popusta za promocije. Ovi brojevi služe kao ulazni podaci za daljnje izračune modela.
3. "Import Data 2021": Ovaj list sadrži podatke o prodaji za 2021. godinu koji se koriste za izračune u modelu. Farmaceutska tvrtka prati kretanje volumena prodaje po SKU-u i po klijentu u svrhu poslovne analitike.
4. "Sales Report 2021": Ovaj list sadrži nadzornu ploču s ključnim pokazateljima u prodaji tvrtke. Koristeći Master i Import podatke, stvoren je izvještaj o prodaji za farmaceutsku tvrtku.
5. "Scenario SKUs List": Ovaj list sadrži SKU-ove koji su uključeni u scenarije what-if analize. Možete stvarati svoj popis SKU-ova koji su uključeni u određeni scenarij promjenom oznaka "YES/NO" u stupcu "Price Change".
6. "Scenario Clients List": Ovaj list sadrži popis klijenata čiji će se postotak popusta za promocije promijeniti u scenarijima. Možete stvarati svoj popis klijenata koji su uključeni u određeni scenarij promjenom oznaka "YES/NO" u stupcu "Promo Discount Change".
7. "Model Calculations 2021": Ovaj list sadrži izračune potrebne za stvaranje tablice s prekretnicama (pivot table) u listu "Sales Report". Kombiniranjem Import i Master podataka, izračuni za svaki ključni pokazatelj prodaje se izvode u izvještaju o prodaji.

Glavne dimenzije koje se koriste u praktičnom djelu rada i poslovanju fiktivnog farmaceutskog poduzeća su sljedeće:

- Account. Predstavlja glavnu dimenziju koja povezuje ostale dimenzije, ova dimenzija je mjerljiva te su joj hijerhijski podređene sljedeće dimenzije:

- Base_Discount__
- COGS__
- Price_
- Promo_Discount
- SKU. Predstavlja identifikacijski broj artikla
- Client. Predstavlja ID klijenta.
- Volume. Predstavlja broj jedinica artikla
- Year. Predstavlja godinu poslovanja
- Brand. Predstavlja brend određenog artikla
- Business_Unit. Predstavlja poslovnu jedinicu.
- Therapeutic_Area. Predstavlja područje u kojem se koristi artikl (lijek); npr. za liječenje boli
- Promo_Status. Trenutni status artikla, predstavlja je li na popustu ili nije
- Price_Change. Predstavlja promjenu cijene u obliku boolean vrijednosti (yes, no)
- Description. Description se odnosi na opis ID klijenta (Client 1, Client 2,...)
- Promo_Discount_Change. Predstavlja promjenu promo popusta u obliku boolean vrijednosti (yes, no)

Prije učitavanja podataka u SAP Analytics Cloud bilo je potrebno ponoviti iste datume za 2022. godinu kako bi se napravila predikcija te kako bi se mogle uspoređivati promjene u odnosu na 2021. godinu, odnosno kako će određene poslovne odluke utjecati na poduzeće. Slika 6 prikazuje prikaz prijelaza iz 2021. u 2022. godinu po pitanju narudžbi lijekova.

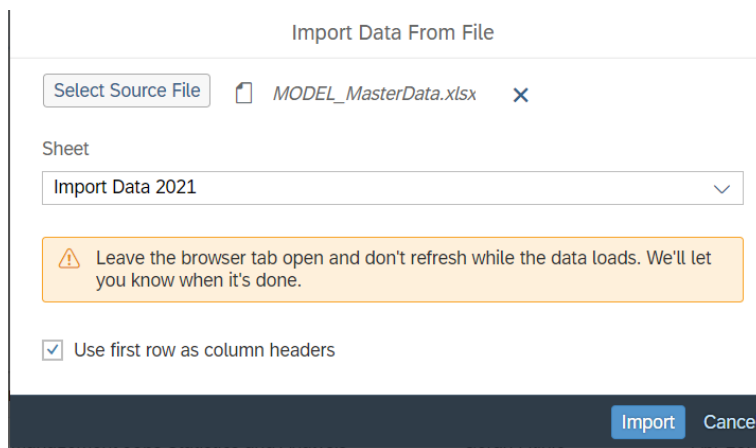
Slika 6. Modelirana excel tablica

691	AEROXAMINE 56x20	C00001	12/1/2021	5,270	2021
692	AEROXAMINE 14x40	C00011	12/1/2021	5,216	2021
693	AEROXAMINE 28x40	C00013	12/1/2021	2,722	2021
694	AEROXAMINE PROTECT	C00009	12/1/2021	5,278	2021
695	ZOLEDRONIC 4mg	C00007	12/1/2021	1,816	2021
696	VENRASE 30x650	C00001	12/1/2021	1,879	2021
697	VENRASE 50x650	C00003	12/1/2021	1,056	2021
698	OFLOPIRIN 225mg	C00007	1/1/2022	5,498	2022
699	AMPHEGENE 5mg	C00011	1/1/2022	4,969	2022
700	NORCLOTIDE 100 20x100	C00005	1/1/2022	1,824	2022
701	CEFTARINEX 10 mg	C00014	1/1/2022	4,372	2022
702	CEFTARINEX 15 mg	C00009	1/1/2022	4,945	2022
703	CEFTARINEX 30 mg	C00015	1/1/2022	4,116	2022
704	CEFTARINEX 5 mg	C00006	1/1/2022	4,449	2022
705	ARTICEL 10mg	C00003	1/1/2022	3,402	2022
706	ARTICEL 2,5mg	C00005	1/1/2022	1,100	2022
707	ARTICEL 5mg	C00008	1/1/2022	4,745	2022

Izvor: vlastita izrada

Uvoz podataka iz Excel datoteke u Modeler prvi je korak u analizi podataka i izgradnji modela za daljnju obradu i vizualizaciju. Prvo je dodan list „Import Data 2021“ (slika 7) na kojeg će se kasnije vezati drugi listovi iz excel datoteke.


Slika 7. Uvoz podataka iz excel datoteke u SAC



Izvor: vlastita izrada

Slika 8 prikazuje izbornik pomoću kojeg se kombiniraju i druge tablice s glavnom tablicom excel datoteke.


Slika 8. Kombiniranje podataka u SAC-u



Izvor: vlastita izrada


Na sljedećim slikama bit će prikazan uvoz i kombiniranje ostalih listova excel datoteke i njihovo povezivanje (slike 9, 10, 11 i 12). Povezivanje u vidu SAC-a je prilično važno zbog poslovanja i donešenja poslovnih odluka zato što je su različiti skupovi podataka većinom povezani s određenim dimenzijama jednog skupa podataka u drugi.

Slika 9. Uvoz Master Data SKU datoteke



Izvor: vlastita izrada

Slika 10. Kombiniranje podataka sa SKU skupom podataka



Izvor: vlastita izrada

Slika 11. Kombiniranje podataka s Master Data Clients skupom podataka

Combine Data

Combine Settings ? All primary data v

MODEL_MasterData.xlsx

11 1392

Search columns Q ↑↓ +

AA SKU ✓

AA Volume

AA Brand

AA Client

AA Therapeutic Area

AA Year

AA Business Unit

MODEL_MasterData.xlsx

3 58

Search columns Q ↑↓ +

AA SKU ✓

AA Price Change

AA

Combine Preview

13 1392

Accepted Duplicated Nulls Omitted

Data Sample Preview showing 20 of 1392 accepted rows

MODEL_MasterData.xlsx					MODEL_MasterData.xlsx			
AA Client	AA Volume	AA Year	Date	AA SKU	AA	AA Price Change		

Combine Back Cancel

Izvor: vlastita izrada

Slika 12. Kombiniranje podataka s Scenario Clients List skupom podataka

Combine Data

Combine Settings ? All primary data v

MODEL_MasterData.xlsx

12 1392

Search columns Q ↑↓ +

AA Client ✓

AA Volume

AA SKU

AA Brand

AA Therapeutic Area

AA Year

AA Business Unit

MODEL_MasterData.xlsx

5 15

Search columns Q ↑↓ +

AA Client ID ✓

AA Description

AA

1²³ Promo Discount %

1²³ Base Discount %

Combine Preview

16 1392

Accepted Duplicated Nulls Omitted

Data Sample Preview showing 20 of 1392 accepted rows

MODEL_MasterData.xlsx					MODEL_MasterData.xlsx			
AA SKU	AA Volume	AA Year	Date	AA Client	1 ²³ Base Disco...	1 ²³ Promo Disc...	AA	AA Description

Combine Back Cancel

Izvor: vlastita izrada

U konačnom uređivanju modela (slika 13) su dodani zapisi za 2022. godinu u proračunsku tablicu te je izračunata godina iz datuma. Provjereno je da proračunska tablica sada sadrži ukupno 1.392 zapisa (696 x 2). Nakon toga je kreiran model podataka na temelju podataka za 2021. i 2022. godinu. Također je postavljen format datuma da bude MM/DD/YYYY. Dodane su veze (eng. *relationships*) između klijenta, SKU-a, liste SKU-ova za scenarije i liste klijenata za scenarije. Nepotrebne stupce su uklonjene. Prije kreiranja modela u SAC-u bilo je potrebno učitati excel datoteku, pri učitavanju datoteke moglo se vidjeti da neki od zapisa ne daju dodatnu korist za model pa su uklonjeni. U modelu su uklonjeni svi prazni zapisi.

Slika 13. Konačni izgled kreiranja modela sa odgovarajućim redovima

The screenshot shows the SAP Modeler interface. On the left, a table titled 'Create Transform' displays data for 16 rows. The columns are SKU, Client, Date, Volume, and Year. The data includes various pharmaceutical products like OFLOPIRIN, AMPHEGENE, NORCLOTIDE, CEFTARINEX, and ARTICEL. On the right, a panel for 'MODEL_MasterData' shows model statistics: 1,392 Rows, 6 Columns, 6 Dimensions, and 0 Measures. It also includes sections for Model Requirements (No issues detected), Model Information (Data source: MODEL_MasterData.xlsx), and Model Options (Enable Planning: unchecked, Fill empty ID cells: checked, Default Currency: USD). A 'Create Model' button is at the bottom right.

	SKU	Client	Date	Volume	Year
2	OFLOPIRIN 225mg	C00007	01/01/2021	5498	2021
3	AMPHEGENE 5mg	C00011	01/01/2021	4969	2021
4	NORCLOTIDE 100	C00005	01/01/2021	1824	2021
5	CEFTARINEX 10 m	C00014	01/01/2021	4372	2021
6	CEFTARINEX 15 m	C00009	01/01/2021	4945	2021
7	CEFTARINEX 30 m	C00015	01/01/2021	4116	2021
8	CEFTARINEX 5 mg	C00006	01/01/2021	4449	2021
9	ARTICEL 10mg	C00003	01/01/2021	3402	2021
10	ARTICEL 2.5mg	C00005	01/01/2021	1100	2021
11	ARTICEL 5mg	C00008	01/01/2021	4745	2021
12	DASAPINE FINAZC	C00013	01/01/2021	3973	2021
13	DASAPINE FINAZC	C00012	01/01/2021	2612	2021
14	AMOXIRANON 10r	C00007	01/01/2021	1036	2021
15	AMOXIRANON 50r	C00002	01/01/2021	5086	2021
16	ULTRICADREN 30r	C00008	01/01/2021	4234	2021

Izvor: vlastita izrada

Slika 14 prikazuje krajnju strukturu modela, nakon što su izbačeni suvisli atributi i ostavljeni podaci koji će se koristiti za daljnji rad. Na slici je vidljivo koliko atributa ima određena dimenzija.

Slika 14. Prikaz strukture modela

Workspace			
General		Edit	
Data		View	
Validation			
Model Structure			
Search			
Account			
Account	Account	4	1
Date			
Date	Date	—	—
Generic			
SKU	SKU	59	0
Client	Client	16	0
Volume	Volume	646	0
Year	Year	3	0
Brand	Brand	27	0
Business_Unit	Business Unit	3	0
Therapeutic_Area	Therapeutic Area	9	0
Promo_Status	Promo Status	4	0
Price_Change	Price Change	3	0
Description_2	Description	16	0
Promo_Discount_Change	Promo Discount Change	3	0

Izvor: vlastita izrada

5.1.2. Izrada finalnog modela u SAP Analytics Cloudu

Kako bi model bio potpun bilo je potrebno dodatno izraditi kalkulacije unutar modela. Kako bi se naknadno uređivao model koristi se sljedeća opcija (Rebuild model), prikazan na slici 15:

Slika 15. Mogućnost ponovne izgradnje modela



Izvor: vlastita izrada

Ponovna izgradnja modela radi se kako bi se napravile kalkulacije koje će se kasnije koristiti u izradi „What-if simulacije“. Kalkulacije se u pišu u integriranom JavaScriptu u SAC-u. Prikazat će se izrađene kalkulacije za koje su korištene već postojeće mjere (slike 16, 17, 18, 19, 20, 21 i 22), te poslijetku i izgled dodatnih mjera unutar modela (slika 23):

Slika 16. Gross Revenue kalkulacija

Calculated Columns

Name

Gross Revenue

Edit Formula ?

1 [Volume] * [Price €]

Format

Formula Functions

Functions

IF()

SUBSTRING()

TRIM()

CONTAIN()

CONCAT()

REPLACE()

Conditions

Operators

Izvor: vlastita izrada

Slika 17. Base discount kalkulacija

Calculated Columns

Name
Base Discount

Edit Formula ?

1 [Gross Revenue] * [Base Discount %]

Format

Formula Functions
Functions

- IF()
- SUBSTRING()
- TRIM()
- CONTAIN()
- CONCAT()
- REPLACE()

Conditions

Izvor: vlastita izrada

Slika 18. Promo discount kalkulacija

Calculated Columns

Name
Promo Disocunt

Edit Formula ?

1 [Gross Revenue] * [Promo Discount %]

Format

Formula Functions
Functions

- IF()
- SUBSTRING()
- TRIM()
- CONTAIN()
- CONCAT()
- REPLACE()

Conditions

Izvor: vlastita izrada

Slika 19. Net Revenue kalkulacija

Calculated Columns

Name
Net Revenue

Edit Formula ?

1 [Gross Revenue] - [Base Discount] - [Promo Discount]

Format

Formula Functions
Functions

- IF()
- SUBSTRING()
- TRIM()
- CONTAIN()
- CONCAT()
- REPLACE()

Conditions

Izvor: vlastita izrada

Slika 20. COGS kalkulacija

Calculated Columns

Name
COGS

Edit Formula ?

1 [Volume] + [COGS €]

Format

Formula Functions
Functions

- IF()
- SUBSTRING()
- TRIM()
- CONTAIN()
- CONCAT()
- REPLACE()

Conditions

Izvor: vlastita izrada

Slika 21. Gross profit1 kalkulacija

Calculated Columns

Name
Gross Profit1

Edit Formula ?

1 [Net Revenue] - [COGS]

Format

Formula Functions
Functions

- IF()
- SUBSTRING()
- TRIM()
- CONTAIN()
- CONCAT()
- REPLACE()

Conditions

Izvor: vlastita izrada

Slika 22. Gross Margin % kalkulacija

Calculated Columns

Name
Gross Margin %

Edit Formula ?

1 [Gross Profit1] / [Gross Revenue]

Format

Formula Functions
Functions

- IF()
- SUBSTRING()
- TRIM()
- CONTAIN()
- CONCAT()
- REPLACE()

Conditions

Izvor: vlastita izrada


Slika 23. Prikaz dodanih kalkulacija u model

Gross ...	fx	Base D...	fx	Promo ...	fx	Net Re...	fx	COGS	fx	Gross ...	fx	Gross ...	fx
2399143.93333333		23991.4393333333		239914.393333333		2135238.10066666		562738.13278138		1572499.9678852		0.6554421125123	
96431.7266666666		964.317266666666		7714.5381333333		87752.8712666666		18935.300895136		68817.570371530		0.7136403417249	
2383.3600000000		23.833600000000		357.504000000000		2002.0224000000		370.93719784937		1631.0852021506		0.6843637562729	
75688.064		756.88064		4541.28384		70389.89952		19769.790551566		50620.108968433		0.6687990984738	
135816.073333333		1358.1607333333		9507.1251333333		124950.787466666		42678.031094014		82272.756372652		0.6057659771294	
168920.64		1689.2064		11824.4448		155406.9888		58858.490186021		96548.498613978		0.5715612882710	
47544.980000000		475.449800000000		3803.5984000000		43265.931800000		14875.923490962		28390.008309037		0.5971189452395	
16288.776		162.88776		1140.21432		14985.67392		3978.6296286184		11007.044291381		0.6757441008079	
1322.9333333333		13.229333333333		198.44000000000		1111.2640000000		259.71741129684		851.54658870315		0.6436806506020	
11413.3066666666		114.133066666666		1027.1975999999		10271.975999999		3508.2562666887		6763.7197333112		0.5926170154583	
2592827.476		25928.27476		518565.4952		2048333.70604		957101.75526915		1091231.9507708		0.4208656229045	
1598251.456		15982.51456		143842.63104		1438426.3104		556081.74887568		882344.56152431		0.5520686736820	
6041.952		60.41952		604.1952		5377.33728		845.44053029553		4531.8967497044		0.7500716241546	
148307.76		1483.0776		8898.4656		137926.2168		48062.375416227		89863.841383772		0.6059281145084	
17737.637333333		177.37637333333		1596.3873599999		15963.873599999		4164.4544842471		11799.419115752		0.6652193239726	
35003.016		350.03016		7000.6032		27652.38264		11078.999099779		16573.383540220		0.4734844431754	
17871.398502800		178.71398502800		1250.9978951960		16441.686622576		7147.7934100430		9293.8932125334		0.5200428612834	
36866.448		368.66448		5529.9672		30967.81632		13172.092761107		17795.723558892		0.4827078420707	
25204.661005173		252.04661005173		3276.6059306725		21676.008464449		4955.3900512734		16720.618413175		0.6633939020145	
5112.204		51.12204		766.8306		4294.25136		1930.3997190766		2363.8516409233		0.4623938404890	
10814.496		108.14496		2162.8992		8543.45184		3129.3233788771		5414.1284611228		0.5006362257772	

Izvor: vlastita izrada

Na temelju prikupljenih podataka o prodaji farmaceutskog poduzeća, kreiran je model koji obuhvaća informacije o SKU-ovima, klijentima, volumenima prodaje, cijenama, popustima i ostalim relevantnim pokazateljima. Modeliranje je uključivalo korake kao što su integracija podataka, izrada veza između entiteta, definiranje dimenzija i mjera, te primjena potrebnih transformacija podataka. Na slici 24 prikazuje se model koji je generiran nakon što je uređen konačni skup podataka za model koji će se koristiti za daljnji rad.

Slika 24. Grafički prikaz strukture modela



Izvor: vlastita izrada

Na slici 25 prikazane su sve mjere kod hijerarhijski u modelu spadaju pod Account. Pomoću prikazanih mjera računaju se i ostali parametri u modelu te se isti koriste i u dimenzijama.

Slika 25. Mjere unutar dimenzije Account

ID	Description	Aggregation Type	accType	Formula	Hierarchy
Base_Discount_	Base Discount %				<root>
COGS_	COGS €				<root>
Price_	Price €				<root>
Promo_Discount_	Promo Discount %				<root>

Izvor: vlastita izrada

5.2. Pregled poslovanja

Pregled poslovanja farmaceutskog poduzeća ključan je korak u razumijevanju njegovih operacija, uspjeha i izazova. Kao što je navedeno, korišteno je nekoliko skupova podataka u excel datoteci koji su u međusobno u relaciji.

Analiza financijskih rezultata farmaceutskog poduzeća, uključujući prihode, troškove, dobit i bilancu stanja, omogućuje procjenu financijske stabilnosti i profitabilnosti poduzeća. Također je važno sagledati trendove u financijskim pokazateljima kako bi se identificirale snage i slabosti te potencijalne prilike za poboljšanje. Pregled poslovanja farmaceutskog poduzeća omogućuje cjelovit uvid u njegove ključne aspekte i utječe na donošenje informiranih odluka. Razumijevanje prodaje, istraživanja i razvoja, kvalitete proizvoda, regulatornih zahtjeva i financijskih rezultata ključno je za upravljanje uspješnim farmaceutskim poduzećem. Uzimajući u obzir financijske pokazatelje kao što su dobit i konačni prihodi, farmaceutsko poduzeće može donositi informirane odluke, optimizirati poslovanje i osigurati dugoročnu profitabilnost, što je ključno za uspješno poslovanje na tržištu farmaceutskih proizvoda.


Kako bi se bolje razumjelo poslovanje te i sami definirani cilj na početku poglavlja izrađuje se analitička aplikacija.

5.3. Prediktivna analitika

Prediktivna analitika, u sklopu praktičnog djela rada, bavi se modelima predviđanja kroz klasifikaciju, regresiju i vremenske serije. Slika prikazuje mogućnosti u prozoru „Predictive Scenarios“. Nakon što se odabere željena vrsta prelazi se na treniranje modela prema odabranom skupu podataka, influencerima i ciljanoj vrijednosti.

U kontekstu ovog diplomskog rada, primjena prediktivnih scenarija može se primijeniti na primjeru poslovanja poduzeća fiktivne farmaceutske tvrtke. Slika 26 prikazuje vrste prediktivnih scenarija koji se mogu koristiti u SAC-u.

Slika 26. Prikaz odabira prediktivnog scenarija



Izvor: vlastita izrada

5.3.1. Klasifikacija

U ovom poglavlju se usredotočuje na primjenu klasifikacije u prediktivnim scenarijima u analizi podataka farmaceutskog poduzeća. Klasifikacija je izvedena na temelju lista Excel tablice pod nazivom "Scenario SKU list" (slika 27), u kojoj se analizira stupac "price change" (yes i no). Ova metoda klasifikacije omogućuje razvrstavanje SKU-ova prema promjeni cijene i identifikaciju skupina proizvoda koji su podložni promjeni cijene i onih koji nisu.

Kroz proces klasifikacije, mogu se donijeti informirane odluke o prilagodbi cijena određenih SKU-ova kako bi se postigli željeni rezultati u poslovanju. Analizirajući stupac "price change", može se identificirati SKU-ove koji zahtijevaju promjenu cijene kako bi se poboljšala bruto marža ili stvorile konkurentske prednosti. Također, mogu se prepoznati SKU-ove koji zadržavaju stabilne cijene i fokusirati se na druge aspekte poslovanja kako bi se ostvario rast i profitabilnost. Slika prikazuje podatke unutar navedenog lista.

Slika 27. Scenario SKU list

SKU	Price Change
AEROXAMINE 14x40	NO
AEROXAMINE 28x20	YES
AEROXAMINE 28x40	YES
AEROXAMINE 56x20	YES
AEROXAMINE PROTECT	NO
AFININALIN 30x1.5	YES
AGETIZA 100	YES
AGETIZA 50	NO
ALCAFSTRYL 28x10	YES
ALCAFSTRYL 28x5	YES
ALCAFSTRYL gran.	NO
AMOXIRANON 10mg	YES
AMOXIRANON 50mg	YES
AMPHEGENE 5mg	YES
AQUAVANCE 20mg	YES
AQUAVANCE 30mg	YES
ARTICEL 10mg	YES
ARTICEL 2,5mg	YES
ARTICEL 5mg	YES
BUTATASOL 30x300	YES
CEFTARINEX 10 mg	YES
CEFTARINEX 15 mg	YES
CEFTARINEX 30 mg	YES
CEFTARINEX 5 mg	NO
CERETRIENE 50x300	YES
CERETRIENE 50x600	YES
DASAPINE FINAZOLID 12x40	YES
DASAPINE FINAZOLID 28x20	NO
INVATANE 684x10	NO
INVATANE 684x20	NO
NORCLOTIDE 100 20x100	NO
OFLOPIRIN 225mg	YES
PRAXITEN 30x15	YES
PRILEN PLUS 30x2,5	YES
PRILEN PLUS 30x5	YES
PRILEN PLUS 60x2,5	YES
PRILEN PLUS 60x5	YES
RINOLAN 10mg	NO

Izvor: Farseer

U nastavku će se istražiti rezultati klasifikacije i razmotriti kako ove informacije mogu biti korisne za donošenje strategijskih odluka u području prodaje farmaceutskog poduzeća. Nakon što je treniranje modela u svrhu klasifikacije izvršeno otvaraju se izvještajni prozori na kojima se mogu vidjeti rezultati klasifikacije, što je vidljivo na slici 28.

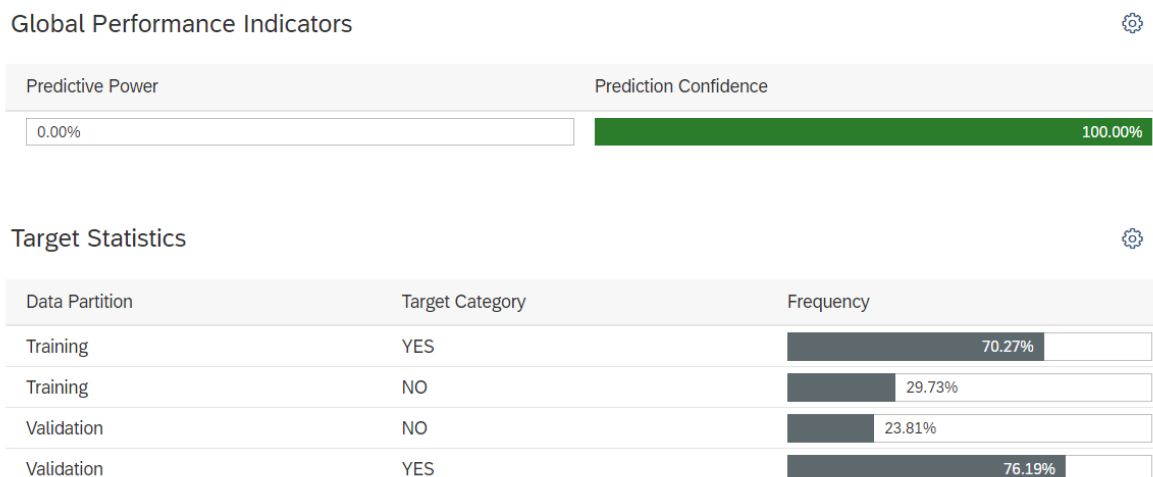
Slika 28. Prikaz izvještajnih prozora nakon izvršenja klasifikacije



Izvor: vlastita izrada

Na slici 29 je prikazana klasifikacija na temelju toga sadrži li SKU popust ili ne. Rezultati su grupirani u skupine prema kojima se mogu promatrati dobiveni rezultati klasifikacije. U prozoru Overview, vidljivo je da je korišten Random Forest klasifikator sa 100 stabala i korištena su sva dostupna svojstva (značajke) u klasifikaciji, što je prikazano na slici 29. Skup podataka s kojim je model treniran sastoji se od informacija o SKU-ovima.

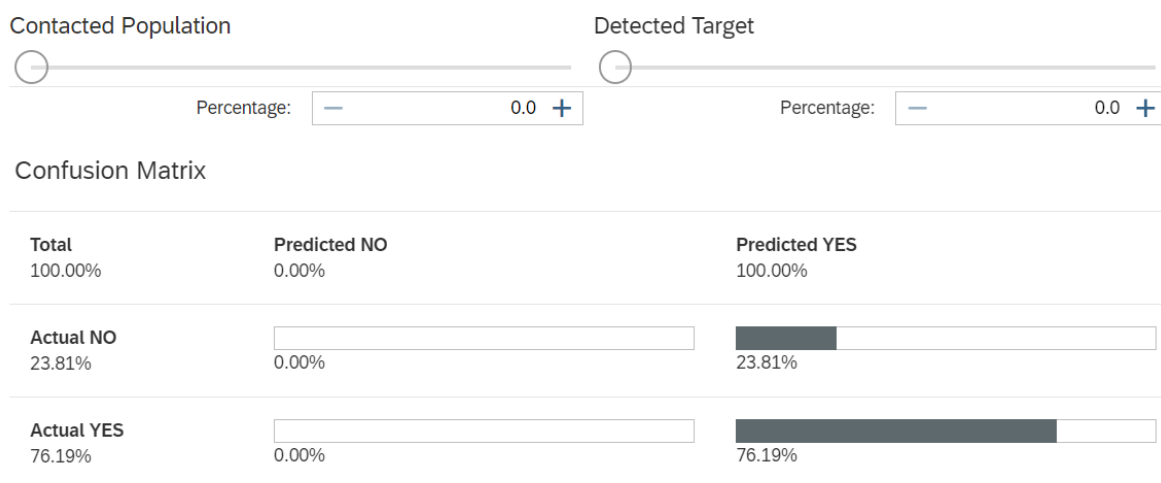
Slika 29. Prikaz performansi izvršene klasifikacije u Predictive Scenarios



Izvor: vlastita izrada

U prozoru Confusion Matrix, na slici 29, prikazana je točnost klasifikacije za svaku klasu. Točnost za klasu koja sadrži popust iznosi 76.19%, a točnost za klasu koja ne sadrži iznosi 23.18%.


Slika 29. Matrica konfuzije



Izvor: vlastita izrada

Na slici je prikazana krivulja %detected target, ona može pružiti uvid u to koliko je dobro model identificirao lijekove koji sadrže popust na ukupan broj pozitivnih primjera. Krivulja Lift daje informacije o tome koliko je model bolji u identificiranju u odnosu na nasumično odabiranje lijekove. Na slici se vidi da je ostvarena 100%-tna validacija.

Slika 30. Krivulja %Detected target




Izvor: vlastita izrada

U prozoru Performance Curves, prikazane su krivulje za preciznost i odziv za svaku klasu. Krivulja preciznosti pokazuje koliko je klasifikator točno identificirao primjere za svaku klasu, dok krivulja odziva pokazuje koliko primjera za svaku klasu je klasifikator točno identificirao.

Krivulja Lift (ili krivulja poboljšanja), prikazana na slici 31, je metoda koja prikazuje koliko je bolje model u usporedbi s nasumičnom klasifikacijom. Ova krivulja uspoređuje postotak pozitivnih primjera koje je model identificirao u odnosu na postotak pozitivnih primjera koji se očekuje ako bi se koristila nasumična klasifikacija.


Slika 31. Krivulja Lift



Izvor: vlastita izrada

Krivulja Lorenz (ili Lorenzova krivulja), prikazana na slici 32, je metoda koja se koristi za prikazivanje distribucije ciljne varijable u odnosu na predviđene vrijednosti modela (SAP blog, 2022). Ova krivulja prikazuje koliko su dobro ciljne vrijednosti modela raspoređene u odnosu na stvarne ciljne vrijednosti te one obje iznose 100%.


Slika 32. Lorenzova krivulja



Izvor: vlastita izrada

Krivulja Density, prikazana na slici 33, (ili gustoća krivulje) je metoda koja prikazuje distribuciju vjerojatnosti predviđenih vrijednosti modela u odnosu na stvarne ciljne vrijednosti. Ova krivulja pruža uvid u to kako model funkcionira u pogledu identifikacije pozitivnih i negativnih primjera u odnosu na stvarnu distribuciju ciljne varijable (SAP blog, 2022).

Slika 33. Krivulja Density



Izvor: vlastita izrada

5.3.2. Regresija

Regresijski predikcijski scenarij se koristi za predviđanje numeričkih vrijednosti ciljne varijable, što je u ovome slučaju numerička vrijednost Volume.

Nakon što je odabrana baza podataka koja će se trenirati u prediktivnom scenariju regresije model počinje s treniranjem. Nakon što je treniranje završeno, u desnom prozoru se prikazuje sažetak vezan uz izvršenje treniranja, vrijeme koje je provedeno trenirajući model, tip modela te status modela (slika 34).


Slika 34. Prikaz sažetka treniranja za regresiju

The screenshot shows a 'Settings' window for a regression model. The window has a blue header with a gear icon and the text 'Settings' and a refresh icon. Below the header, there are three main sections: 'General', 'Predictive Goal', and 'Influencers'. The 'General' section has a 'Description' field. The 'Predictive Goal' section has a 'Target' field set to 'Volume'. The 'Influencers' section has an 'Exclude As influencer' field set to 'No Column'. At the bottom right, there is a 'Train' button. The 'Training Data Source' is set to 'ZaRegresiju' and the 'Limit Number Of Influencers' is set to 1.

Izvor: vlastita izrada

Influencer contributions je prikaz koji pokazuje koje su dimenzije, odnosno utjecajne varijable, najviše utjecale na vrijednost ciljne varijable. Regresija također daje uvid u predict vs actual analizu, što je usporedba između predviđenih i stvarnih vrijednosti ciljne varijable. U predictive scenariju Regresija, cilj je bio predvidjeti vrijednost „Volume“ na temelju ostalih dimenzija u odabranom skupu podataka, prikazanih na slici 35.




Slika 35. Prikaz Influencer Contributionsa



Izvor: vlastita izrada

Influencer contributions, koje su prikazane na slici 34, su dimenzije koje su utjecale na konačni rezultat, a koje su u ovom slučaju sve ostale dimenzije u skupu podataka. Influencer contributions prikazuje koje dimenzije su imale najveći utjecaj na konačni rezultat. Grouped category influence prikazuje kako svaka kategorija utječe na konačni rezultat, što je korisno za razumijevanje koja kategorija ima najveći utjecaj na konačni rezultat. Group category statistics prikazuje statističke podatke o kategorijama koje su korištene u analizi, uključujući broj uzoraka, srednju vrijednost i standardnu devijaciju.

Slika 34. Utjecaj dimenzija na „Volume“ vrijednost




Izvor: vlastita izrada

Na slici 35 prikazan je predicted vs actual grafikon. Predicted vs. actual grafikon u regresijskom scenariju koristi se za vizualno prikazivanje usporedbe između predviđenih vrijednosti i stvarnih (actual) vrijednosti u regresijskoj analizi. U idealnom scenariju, sve točke na grafikonu bi se nalazile na liniji koja predstavlja idealno poklapanje predviđenih i stvarnih vrijednosti. Međutim, u stvarnosti, točke će se često raspršiti oko te linije. Grafikon omogućuje vizualnu procjenu koliko dobro predviđeni model odgovara stvarnim podacima. Ako su točke na grafikonu raspoređene blizu linije, to ukazuje na dobru usklađenost između predviđenih i

stvarnih vrijednosti, što znači da je regresijski model dobro uspio predvidjeti vrijednosti zavisne varijable. S druge strane, ako su točke raspršene i udaljene od linije, to ukazuje na veću pogrešku predviđanja i manju preciznost regresijskog modela (SAP, 2020). Kao što je vidljivo na slici, ako se izuzme min i max točke su prilično blizu savršenog modela.

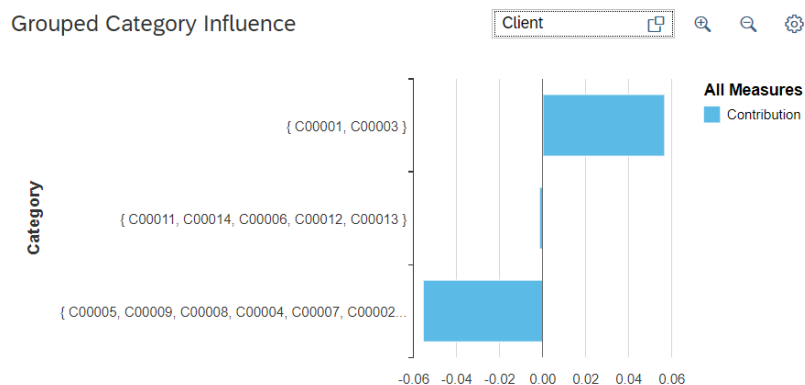
Slika 35. Predicted vs. Actual



Izvor: vlastita izrada

Na slici 36 je prikazano grupiranje utjecajnih varijabli. Cilj grouped category influence analize je razumjeti kako te grupirane kategorije utječu na varijablu interesa. To se postiže usporedbom srednjih vrijednosti ili udjela varijable interesa među različitim grupiranim kategorijama (SAP, 2020). Na slici se može vidjeti koji lijekovi se nalaze u istim skupinama te tako planirati poslovanje.


Slika 36. Grupiranje utjecajnih varijabli



Izvor: vlastita izrada

Kada se podaci grupiraju, to znači da se uzorak ili populacija dijeli na nekoliko kategorija ili skupina temeljem određenih karakteristika ili atributa (SAP, 2020). Grouped category statistics, prikazan na slici 37, omogućuje analizu svake grupe zasebno, što može pružiti korisne uvide u razlike i varijacije među grupama (slika 37).

Slika 37. Statistika grupiranih kategorija




Izvor: vlastita izrada

5.3.3. Vremenske serije predviđanja

Vremenske serije predviđanja izrađene u Canvas story-u. Story je jedna od mogućnosti za kreiranje vremenskih serija predviđanja, a drugi način je kreiranje putem prediktivnih scenarija, u istom pregledu kao što su izrađene i klasifikacija i regresija u ovom modelu.

Kako bi se moglo uopće kreirati vremensku seriju predviđanja potrebno je upotrijebiti dovoljno dimenzija na koje će ona utjecati. Kod vremenske serije predviđanja nužno je uključiti dimenziju datuma, koja se hijerarhijski može staviti na različite razine. Zbog detaljnosti izrade ona je postavljena na razinu 4. Na slici 38 je prikazan Builder pomoću kojega se određuju performanse grafikona.


Slika 38. Prikaz Buildera za grafikone u CANVAS storyu



Izvor: vlastita izrada

Na prošloj slici su prikazane postavke u Builderu koje su naposljetku dovele do grafikona prikazanog na slici 39.

Slika 38. Predviđanje iznosa promo popusta za 2023. godinu



Izvor: vlastita izrada

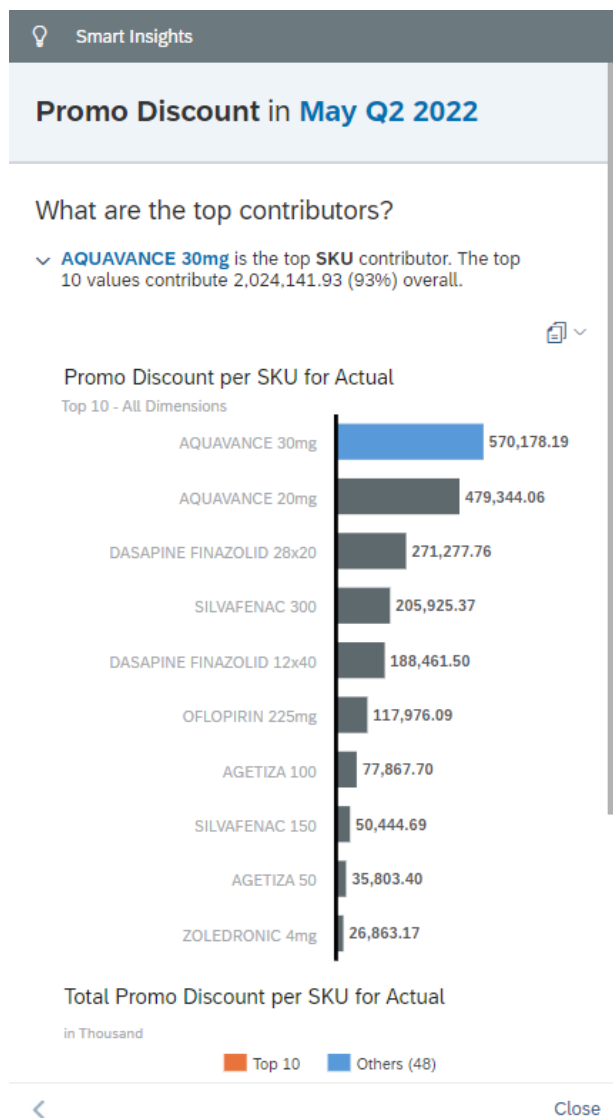
Nakon što se izradi grafikon prema željenima dimenzijama, kalkulacijama, odabranom vremenu i korištenim filterima postoji mogućnost za pregled „Smart insights“. Ovaj način pregleda koristi se za prikaz zaključaka na temelju modela kroz određenu traženu vremensku jedinicu. Analizom CANVAS storya primjećuje se zanimljiv trend u Promo Discountu tijekom razdoblja prvog mjeseca u 2023. godini. Postoji lagani pad Promo Discounta za 400 eura u prvom mjesecu, što ukazuje na potencijalne promjene u marketinškim strategijama ili potražnji za proizvodima farmaceutskog poduzeća.

Analiza Promo Discounta unutar CANVAS storya omogućuje farmaceutskom poduzeću da identificira optimalan popust kako bi ostvarilo profitabilnost u budućim razdobljima. Ovaj rezultat je važan jer pruža informacije o očekivanom smanjenju popusta u budućnosti. To može imati utjecaj na planiranje prodajne strategije i profitabilnost poduzeća, a korištenje storya omogućuje vizualno privlačan i intuitivan prikaz vremenskih serija predviđanja, čime se olakšava razumijevanje trendova i donošenje informiranih odluka.

Također, u pogledu CANVAS storya postoje i pametni uvidi nakon izrađenog grafikona. Pametni uvidi pružaju vrijedne informacije i uvide u različite aspekte poslovnog uspjeha. Jedno od ključnih saznanja je značajan doprinos Aquavancea 30 mg kao vodećeg SKU-a (Stock

Keeping Unit). Ovo ukazuje na to da Aquavance 30 mg ima važnu ulogu u generiranju prihoda i poticanju općeg poslovnog uspjeha, što je i vidljivo na slici 39.

Slika 39. Pametni uvid u poslovanje – promo discount



Izvor: vlastita izrada

5.4. „What if“ simulacija

U ovom poglavlju prikazuje se izrada analitičke aplikacije kako bi se postigao definirani cilj poduzeća te naposljetku prikazao „What if“ simulacijom.

5.4.1. Definiranje cilja

Definiranje cilja je važan korak u poslovnom procesu jer pruža smjer i fokusiranost. Cilj postavljen na jasan i mjerljiv način omogućuje organizaciji da ima jasnu viziju željenog ishoda i usmjerava sve aktivnosti prema postizanju tog ishoda. U poslovnom problemu koji je opisan, tvrtka nije ostvarila profit u 2021. godini, budući da je ukupan bruto prihod negativan. To rezultira i negativnim neto prihodom, što znači da je tvrtka zapravo izgubila novac u toj godini. Prodaja tvrtke iznosila je 2,44 milijuna jedinica, što je generiralo bruto prihod od 144,241 milijuna. Međutim, tvrtka je primijenila 10,039 milijuna u osnovne popuste. Do tog trenutka tvrtka je bila profitabilna. No, daljnjih 9,045,375 milijuna kuna je utrošeno na promocije, što je rezultiralo stvarnim gubitkom novca:

$$\text{Neto prihod} = 144,241 - 10,039 - 9,045,375 = -8,911,173.$$

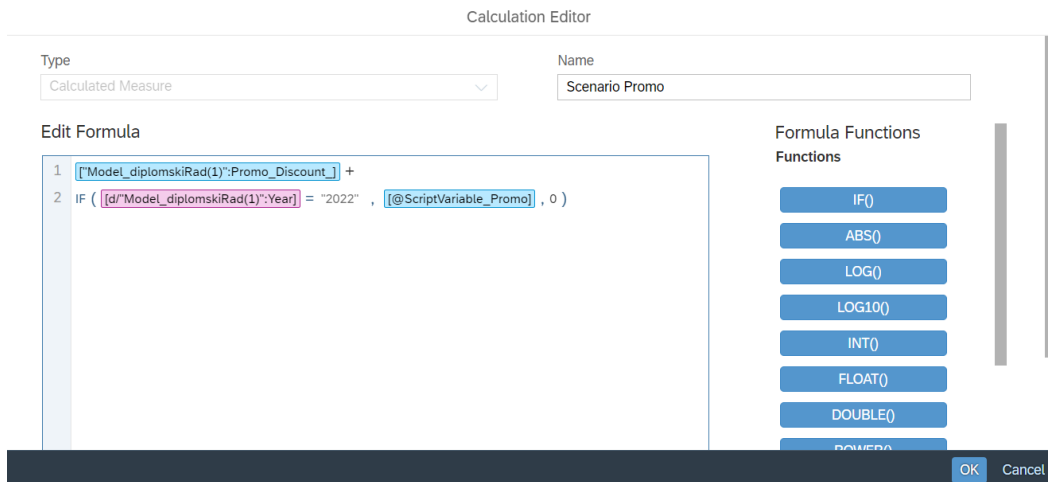
Definiranje cilja u ovom slučaju bio bi postizanje profitabilnosti tvrtke. Smanjenjem popusta za promocije kako bi se postigla pozitivna neto prihoda i izbjegla gubitak, tvrtka će stvoriti održiv poslovni model i povećati ukupnu profitabilnost. Postavljanje cilja omogućuje fokusiranje na konkretan ishod i donošenje potrebnih odluka i akcija kako bi se taj cilj ostvario.

5.4.2. Izrada kalkulacija ovisnih o 2021. godini

Kako bi se došlo do željenih rezultata bilo je potrebno izraditi kalkulacije za vrijednosti koje ne postoje u skupu podataka. Kako bi se naposljetku izradile kalkulacije koje će se primjenjivati na tablicu i grafikone i prikazivati promjene u 2022. godini bilo je potrebno povezati kalkulacije (slika 40-49) iz modela s kalkulacija u analitičkoj aplikaciji koje se primjenjuju samo na 2022. godini te su one uvjetno povezane s dimenzijom Year:

- Scenario promo

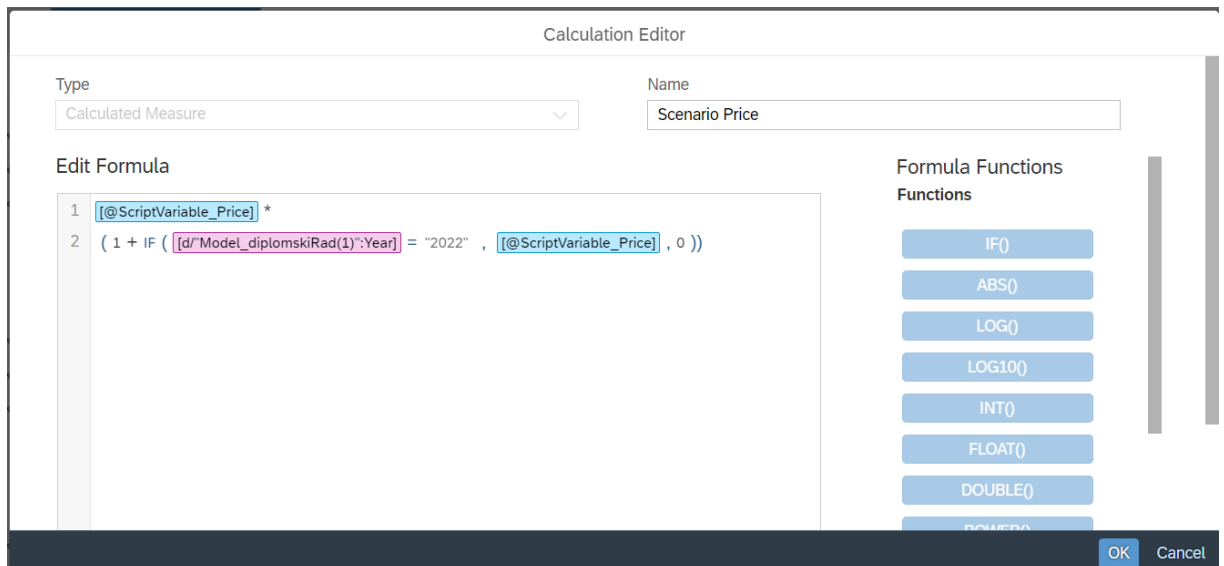
Slika 40. Scenario promo



Izvor: vlastita izrada

- Scenario price


Slika 41. Scenario price



Izvor: vlastita izrada

- COGS

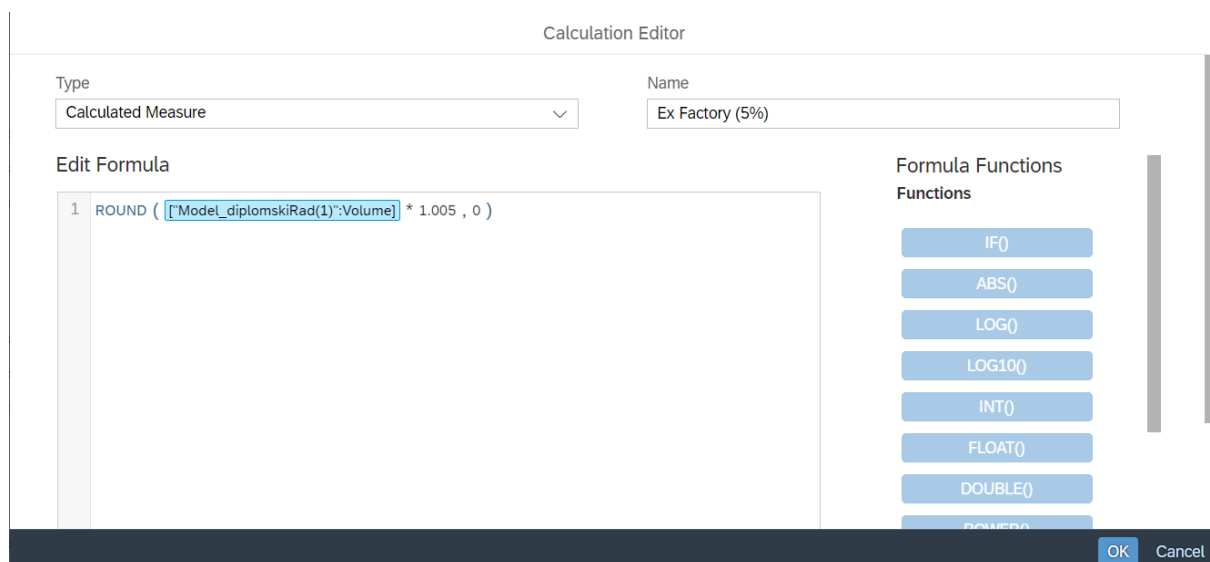
Slika 42. COGS



Izvor: vlastita izrada

- Ex factory (primjena popusta od 5%)

Slika 43. Ex factory



Izvor: vlastita izrada

- Base discount

Slika 44. Base discount

Calculation Editor

Type: Calculated Measure

Name: Base Discount

Edit Formula

1 `[#Gross Revenue] * [Model_diplomskiRad(1):Base Discount %] / 100`

Formula Functions

Functions

- IF()
- ABS()
- LOG()
- LOG10()
- INT()
- FLOAT()
- DOUBLE()
- POWER()

OK Cancel

Izvor: vlastita izrada

- Gross revenue

Slika 45. Gross revenue

Calculation Editor

Type: Calculated Measure

Name: Gross Revenue

Edit Formula

1 `[Model_diplomskiRad(1):Volume] * [#Scenario Price]`

Formula Functions

Functions

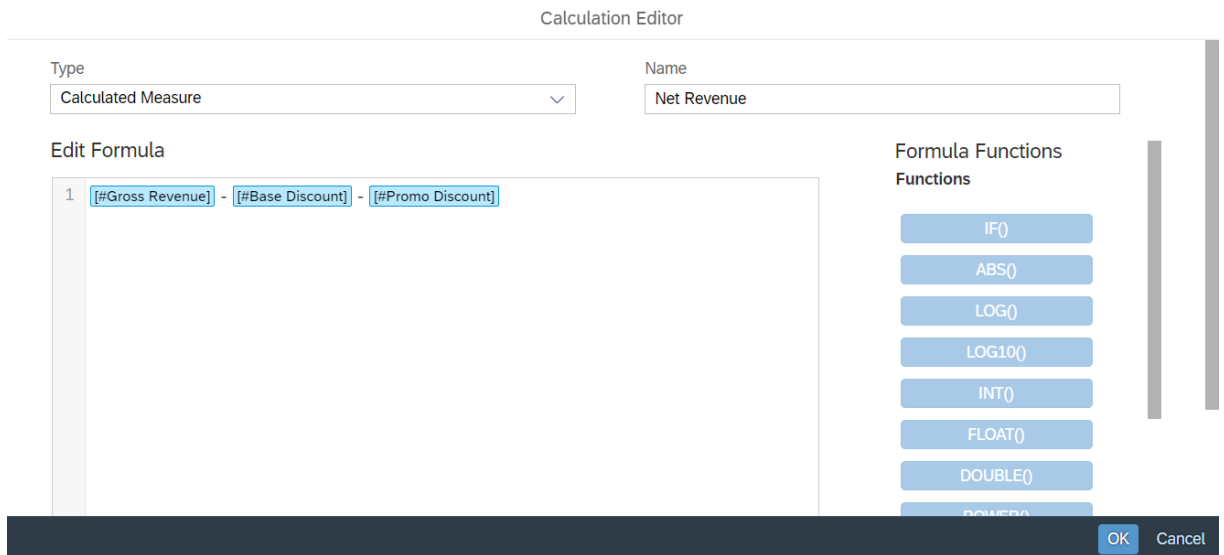
- IF()
- ABS()
- LOG()
- LOG10()
- INT()
- FLOAT()
- DOUBLE()
- POWER()

OK Cancel

Izvor: vlastita izrada

- Net revenue


Slika 46. Net revenue



Izvor: vlastita izrada

- Promo discount

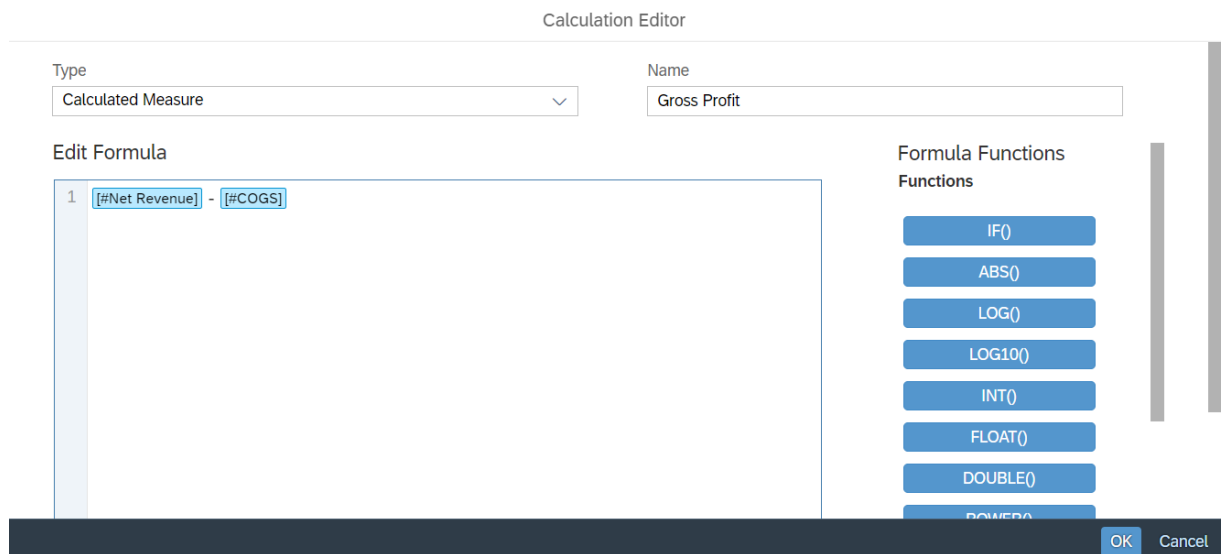
Slika 47. Promo discount



Izvor: vlastita izrada

- Gross Profit

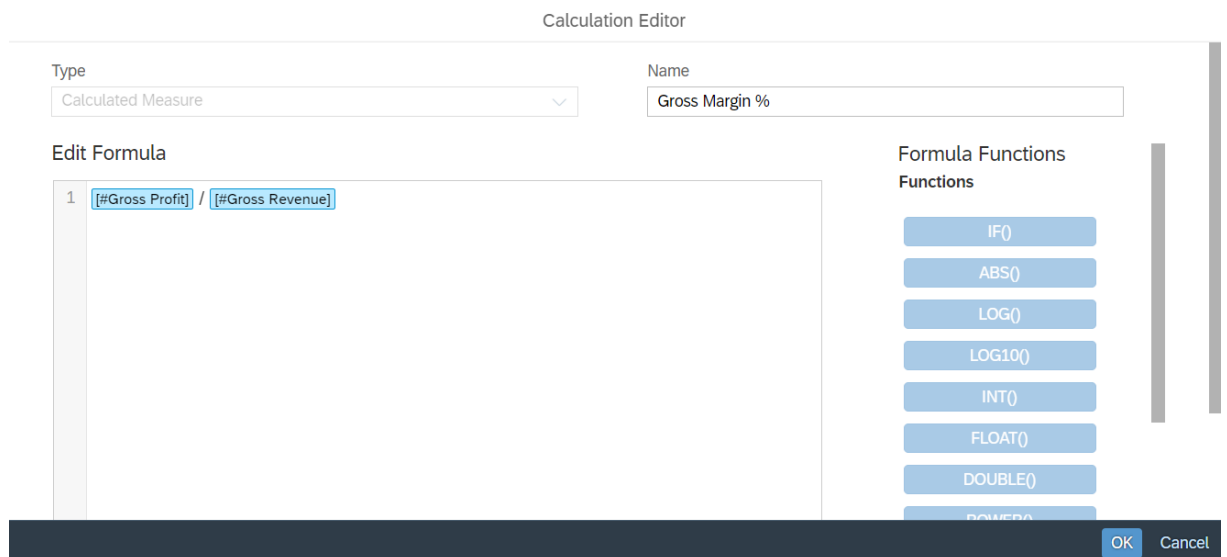
Slika 48. Gross profit



Izvor: vlastita izrada

- Gross Margin %

Slika 49. Gross Margin %



Izvor: vlastita izrada

5.4.3. Kreiranje analitičke aplikacije

U SAP Analytics Cloud implementiran je JavaScript, on omogućuje izradu vlastitih dodatnih mogućnosti. Jedna od ključnih mogućnosti SAC-a je korištenje skriptnih varijabli u JavaScriptu za stvaranje interaktivnih i prilagodljivih vizualizacija. Jedna od mogućnosti koju JavaScript nudi u SAC-u je dodavanje klizača (slidera) kao interaktivne varijable za filtriranje podataka. To je korisno za ograničavanje prikaza podataka na određeni vremenski raspon ili recimo dodavanje popusta unutar mjera kalukacija. JavaScript u SAC-u također omogućuje dodavanje raznih objekata na stranice, poput slika, tekstualnih okvira, gumba itd. Analitička aplikacija koju je bilo potrebno izraditi sastoji se od mnoštvo elemenata koji su međusobno interaktivni. Kako bi se postigla interakcija između grafikona, tablica, buttona, slidera i drugih objekata bilo je potrebno isprogramirati aplikaciju u JavaScriptu. Aplikacija se treba sastojati od dva grafikona i jedne tablice koje prikazuju bruto prihode i promo popuste. Ideja ove aplikacije je prikazati promjene koje se mogu donijeti u 2022. godini u odnosu na 2021. godinu. Kako bi podaci bili što vjerniji korišteni su isti datumi, ali za 2022. godinu. Kroz grafikone i tablicu promjene cijene proizvoda i promo popusta utječu samo na 2022. godinu kako bi se vidio krajnji rezultat.

Kako bi se promjene prikazivale na grafikonima nakon promjene vrijednosti na slideru korištena je funkcija *onResultChanged()*: Kod koji je ovdje kreiran je prikazan u isječku 2.

Isječak kôda 1. Primjena filtriranja dimenzija

```
console.log('onResultChanged');  
  
Chart_2.getDataSource().copyDimensionFilterFrom(Chart_1.getDataSource(),"Brand");  
Chart_2.getDataSource().copyDimensionFilterFrom(Chart_1.getDataSource(),"Client");  
Chart_2.getDataSource().copyDimensionFilterFrom(Chart_1.getDataSource(),"Therapeutic_Area");  
Table_1.getDataSource().copyDimensionFilterFrom(Chart_1.getDataSource(),"Brand");  
Table_1.getDataSource().copyDimensionFilterFrom(Chart_1.getDataSource(),"Client");  
Table_1.getDataSource().copyDimensionFilterFrom(Chart_1.getDataSource(),"Therapeutic_Area");
```

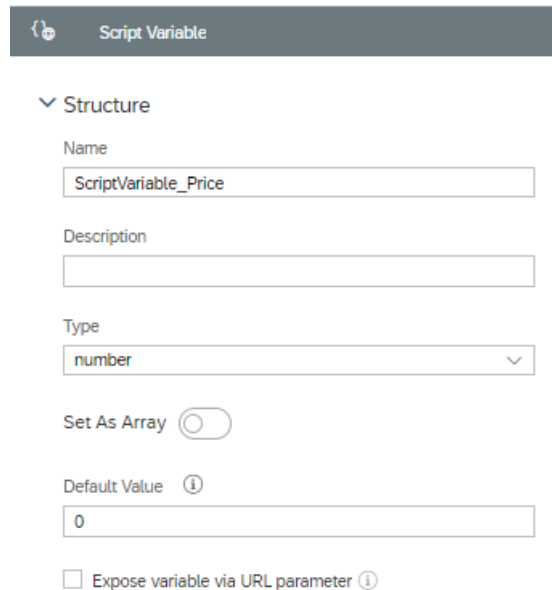
Osim za pozivanje promjena bilo je potrebno i kreirati vezu između buttona i sadržaja koji se prikazuje (isječak kôda 2). Za ovaj slučaj korištena je funkcija *onClick()*: Sljedeći kod prikazuje funkciju za korištenje buttona koji daje rezultat za Klijenta 1 (njegov ID je C00001):

Isječak kôda 2. Primjena filtra dimenzije Client

```
var selection1 = this.getText();  
Chart_1.getDataSource().setDimensionFilter("Client",selection1);
```

U analitičkoj aplikaciji kreirane su dvije skriptne varijable koje će se koristiti unutar pozivanja slidera u aplikaciji. Slika 50 prikazuje kreiranje varijable za promjenu cijene.

Slika 50. Kreiranje varijable za promjenu cijene



Script Variable

Structure

Name
ScriptVariable_Price

Description

Type
number

Set As Array

Default Value ⓘ
0

Expose variable via URL parameter ⓘ

Izvor: vlastita izrada

Na slici 51 prikazana je druga skriptna varijabla koja je kreirana u aplikaciji, pod nazivom *ScriptVariable_promo*.

Slika 51. Kreiranje varijable za promjenu promo popusta


The image shows a configuration panel for a 'Script Variable'. The title bar at the top reads 'Script Variable'. Below it, a section titled 'Structure' is expanded. It contains the following fields and controls:

- Name:** A text input field containing 'ScriptVariable_Promo'.
- Description:** An empty text input field.
- Type:** A dropdown menu with 'number' selected.
- Set As Array:** A toggle switch that is currently turned off.
- Default Value:** A text input field containing '0', with an information icon to its right.
- Expose variable via URL parameter:** A checkbox that is currently unchecked, with an information icon to its right.

Izvor: vlastita izrada

Na slici 52 je vidljiv prikaz mogućnost koje se mogu vršiti skriptiranjem u JavaScriptu. Mogu se vidjeti i varijable koje su prethodno dodane.

Slika 52. Prikaz mogućnosti korištenja JavaScripta u SAC-u



Izvor: vlastita izrada

Bitna stavka aplikacije je i dodavanje mogućnosti odabira brenda, područja liječenja i klijenta. Ovaj način rada aplikacije je napravljen pomoću dodavanja interaktivnih gumba.

Prikazat će se jedan od primjera, lijek brenda, Zoledronic, prikazan na slici 53. Prva linija koda `var selection1 = this.getText();` izdvaja tekst unesen u polje teksta (textbox) ili drugi element korisničkog sučelja. Tekst koji se izdvaja predstavlja odabir korisnika koji se odnosi na određeni lijek. Druga linija koda `Chart_1.getDataSource().setDimensionFilter("Brand", selection1);` koristi metodu `getSource()` kako bi pristupila izvoru podataka koji se koristi u grafikonu (npr., bazi podataka). Nakon toga, metoda `setDimensionFilter()` se primjenjuje na izvor podataka kako bi se postavio filtrirajući uvjet. U ovom slučaju, filtrirajući uvjet odnosi se na dimenziju "Brand" u izvoru podataka. Vrijednost odabira korisnika (tj. odabrani lijek) se pridružuje kao vrijednost tog filtrirajućeg uvjeta. Rezultat ovog koda je da će se prikazani grafikon ili drugi vizualni element ažurirati i prikazati samo podaci koji su povezani s odabranim lijekom. To omogućuje korisniku da vizualno prati i analizira specifične rezultate ili trendove vezane uz taj lijek. "Chart_1" prikazuje grafikon na kojem će se naposljetku i prikazati rezultati.

Slika 53. JavaScript kod za prikaz podataka za lijek brenda Zoledronic

```
ZOLEDRONIC – onClick  
Called when the user clicks the button.  
  
function onClick() : void  
  
var selection1 = this.getText();  
Chart_1.getDataSource().setDimensionFilter("Brand", selection1);
```

Izvor: vlastita izrada

Isti postupak napravljen je i za sve ostale brendove kako bi se ostvarila mogućnost odabira bilo kojega brenda. Prikazat će se primjer odabira dva različita brenda, slika 54 i 55, u ovom sličaju Articiel i Zoledronic. Vidljivo je da se prikazuju drugačiji rezultati za Gross profit i Promo discount kada se klikne na različite brendove te su rezultati brendova striktno vezani uz gumb tog brenda.

Slika 54. Prikaz rezultata za Articel



Izvor: vlastita izrada

Slika 55. Prikaz rezultata za Zolodronic



Izvor: vlastita izrada

Bilo je potrebno i izraditi kod koji će se koristiti za odjel područja liječenja pojedinih lijekova. Prikazan će se primjer za CNS na slici 56. Ovaj kod predstavlja akciju koja se izvršava prilikom pritiska na gumb u korisničkom sučelju. Cilj ovog koda je postavljanje filtriranja po dimenziji "Therapeutic_Area" u izvoru podataka povezanom s određenim grafičkim prikazom ili vizualnim elementom. Prva linija koda `var selection1 = this.getText();` izdvaja tekst unesen u polje teksta ili drugi element korisničkog sučelja. Tekst koji se izdvaja predstavlja odabir korisnika koji se odnosi na određeno terapijsko područje. Druga linija koda `Chart_1.getDataSource().setDimensionFilter("Therapeutic_Area", selection1);` koristi metodu `getSource()` kako bi pristupila izvoru podataka koji se koristi u grafikonu ili vizualnom elementu. Nakon toga, metoda `setDimensionFilter()` primjenjuje se na izvor podataka i postavlja filtriranje po dimenziji "Therapeutic_Area". Vrijednost odabira korisnika (tj. odabrano terapijsko područje) pridružuje se kao vrijednost tog filtriranja.

Rezultat ovog koda je ažuriranje prikaza grafikona kako bi se prikazali samo podaci koji su povezani s odabranim terapijskim područjem. To omogućuje korisniku da vizualno prati i analizira specifične rezultate ili trendove vezane uz to područje.

Slika 56. JavaScript kod za prikaz podataka za područje liječenja

```
CNS – onClick  
Called when the user clicks the button.  
  
function onClick() : void  
  
var selection1 = this.getText();  
Chart_1.getDataSource().setDimensionFilter("Therapeutic_Area", selection1);
```


Također, izrađeni su i gumbi za odabir željenog klijenta, ova stavka je također bitna kako bi se moglo pratiti poslovanje ovisno o klijentu. Klijent se poziva na isti način kao i područje liječenja i brend lijeka. Na slici je prikazan primjer za klijenta C00002.

Slika 56. JavaScript kod za prikaz podataka za željenog klijenta

```
C00002 – onClick  
Called when the user clicks the button.  
  
function onClick() : void  
  
var selection1 = this.getText();  
Chart_1.getDataSource().setDimensionFilter("Client", selection1);
```

Naposljetku, slika 57 prikazuje konačni izgled aplikacije. Na slici su vidljivi slider s kojima postoji mogućnost promjene cijene i popusta, tablica koja je interaktivna s promjenama, grafikonima za 2021. i 2022. godinu te područja kao što su klijenti, područje liječenja i brend.

Slika 57. Konačni izgled aplikacije



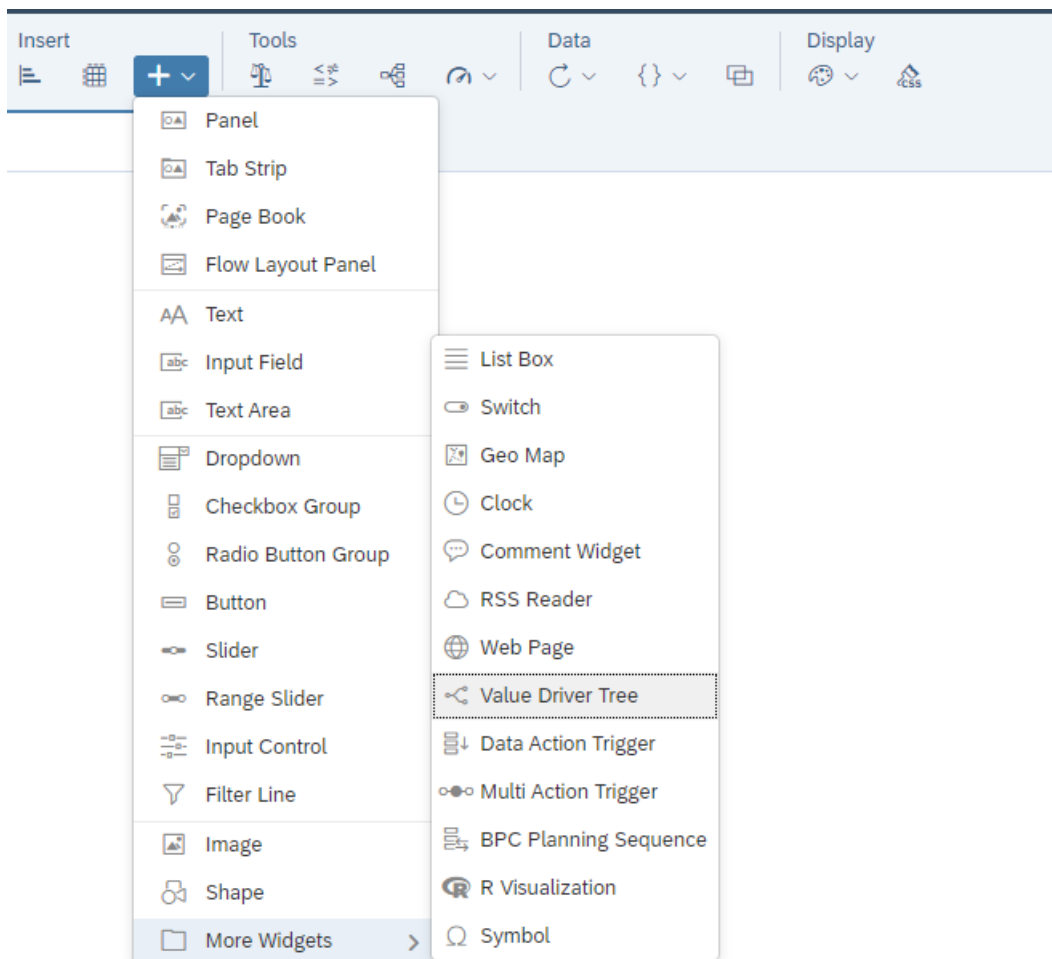
Izvor: vlastita izrada

5.4.4. Kreiranje stabla pokretača vrijednosti

Value Driver Tree je alat koji se koristi za analizu i vizualizaciju ključnih faktora koji utječu na financijske rezultate i vrijednost poslovanja. Ova metoda omogućuje organizacijama da razumiju i kvantificiraju različite faktore koji doprinose ukupnoj vrijednosti njihovog poslovanja. Izrada stabla vrijednosti je važan korak u procesu upravljanja performansama i strategijama poduzeća. Stablo identificira ključne vozače vrijednosti, odnosno faktore koji imaju najveći utjecaj na ostvarenje ciljeva i financijski uspjeh organizacije (SAP, 2020).

U ovom poglavlju prikazat će se izrada jednog jednostavnijeg stabla, kako bi se dobio uvid u veze između mjera u modelu. VDT je kreiran unutar analitičke aplikacije, a slika 58 prikazuje putanju do njega.

Slika 58. Izrada stabla pokretača vrijednosti




Izvor: vlastita izrada

Kod izrade modela stabla pokretača vrijednosti potrebno je odrediti koji vremenski period će se promatrati. Odabran je period od 2021. do 2022. godine, što je vidljivo na slici 59.

Slika 59. Raspon promatranog vremena

Set Data Range for Date

Hierarchy



▼ Range 1 : 2021 - 2022

Granularity

to to

Izvor: vlastita snimka zaslona

U prošlom poglavlju su bile objašnjene i prikazane skriptne varijable i njihova primjena, stoga se u ovom poglavlju prelazi na unos skriptne varijable u mjeru kalkulacije. Izrađena je kalkulacija za izračunavanje COGS-a, prikazana na slici 60.

Slika 60. Korištenje kalkulacija u stablu pokretača vrijednosti

Calculation Editor

Type Name

Edit Formula

1

Formula Functions

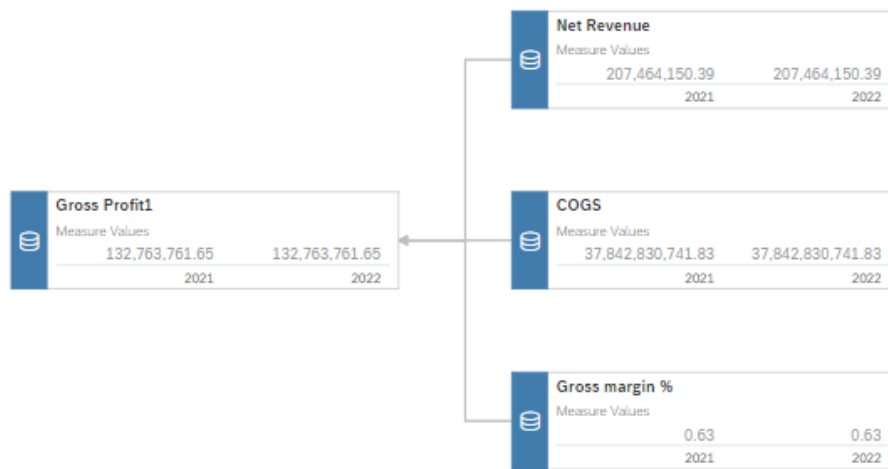
Functions

-
-
-
-
-
-
-
-
-
-

Izvor: vlastita izrada

Slika 61 prikazuje konačni izgled stabla pokretala vrijednosti prije nego što se aplikacija pokrenula. Dok aplikacija nije pokrenuta i dalje se mogu dodavati čvorovi (eng. *Node*) i međusobno povezivati, kao i mjere i kalkulacije između njih. Kao što je vidljivo na slici, VDT se sastoji od četiri različita nodeova. Oni su međusobno povezani parent-child vezama. Profit je u ovome slučaju roditelj svim ostalim nodeovima.

Slika 61. Prikaz stabla pokretala vrijednosti prije pokretanja simulacije



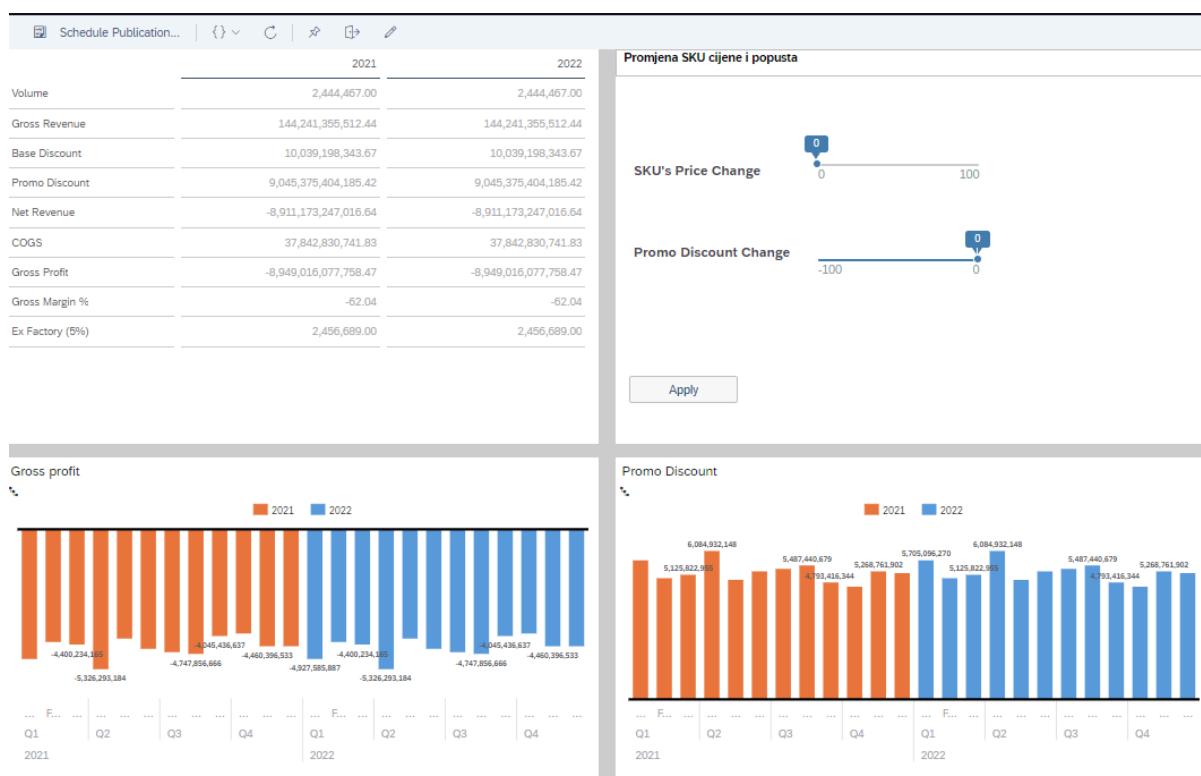
Izvor: vlastita izrada

5.4.5. Rezultati

Kao rezultat rada izrađena je interaktivna analitička aplikacija koja na jednom zaslonu daje prikaz o svim važnim parametrima. Nakon što se aplikacija pokrenula može se upravljati sliderom i namjestiti ga na popust prema želji. Sada se može vidjeti koliko će primjena popusta utjecati na konačni prihod i koja će biti cijena nakon primjene popusta.

Ponajprije je u JavaScriptu bilo potrebno definirati vidljivost grafikona i tablica, kako bi se na zaslonu prikazivali samo traženi prikazi. Za vizualizaciju modela u SAP Analytics Cloudu koriste se dvije komponente, grafikoni i tablice. Na slici 62 je prikazano početno stanje aplikacije prije korištenja slidera i interaktivnih gumbova.

Slika 62. Početno stanje poslovanja poduzeća



Izvor: vlastita izrada

Posebno je važno pažnju obratiti na neto prihod, koji je za 2021. godinu bio u minusu (slika 63) te je preventivno želja da se on promijeni u pozitivno stanje.

Slika 63. Iznos neto prihoda prije promjene

	2021
Volume	2,444,467.00
Gross Revenue	144,241,355,512.44
Base Discount	10,039,198,343.67
Promo Discount	9,045,375,404,185.42
Net Revenue	-8,911,173,247,016.64

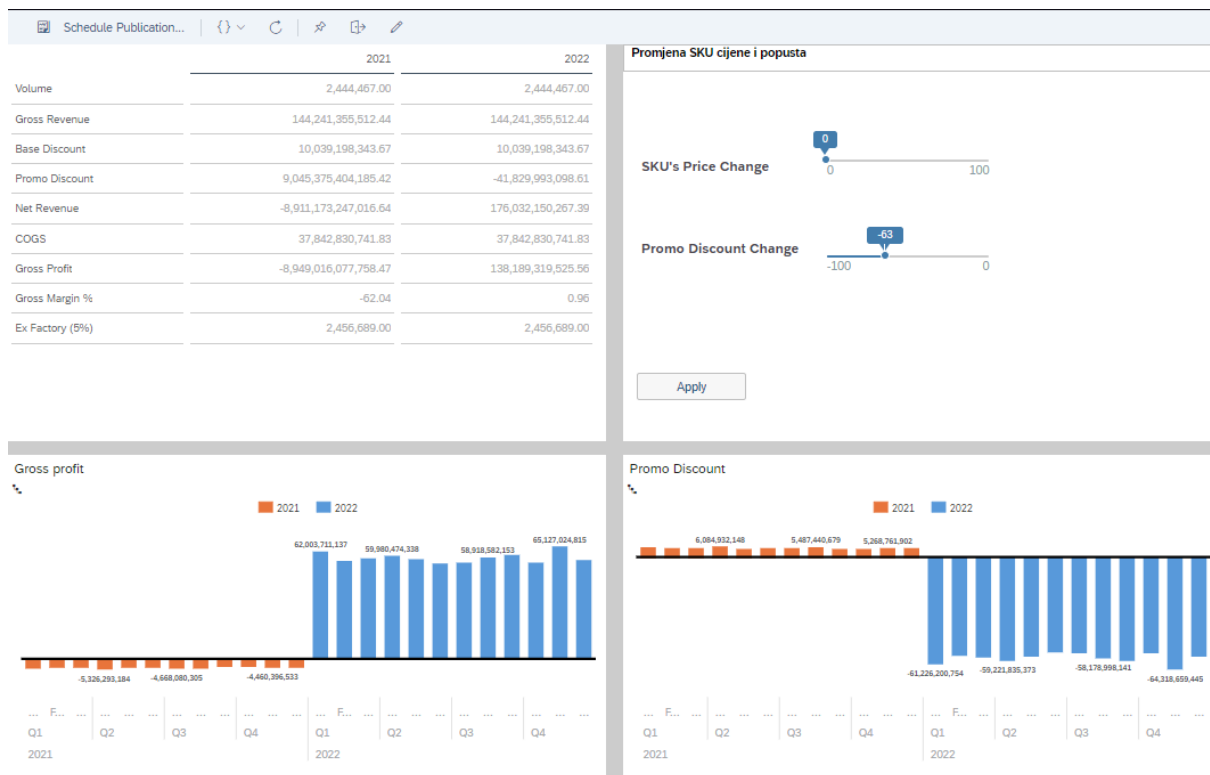
Izvor: vlastita izrada

Kao rješenje, razmotra se mogućnost povećanja cijena SKU-ova kako bi se riješio problem. Međutim, takav pristup može samo dodatno pogoršati situaciju jer su promocije ovisne o cijeni po jedinici. Stoga, jedina opcija koja ostaje jest smanjenje popusta za promocije. Smanjenje popusta omogućuje tvrtki veću maržu i veću profitabilnost. Korištenjem klizača "Promo

Discount Change" moguće je utvrditi maksimalan iznos popusta koji tvrtka može primijeniti, a to iznosi -63. Bilo koji veći popust od toga neće rezultirati profitabilnošću. Ova strategija omogućuje tvrtki da održi profitabilnost, osigurava prihode i osigurava stabilnost poslovanja.

Strategija je prikazana na slici 64 te je sada jasno vidljivo u tablici da je Net Revenue, a samim time i Gross profit, sada pozitivan, što je vidljivo naposljetku i na slici 64.

Slika 64. Promjena poslovanja poduzeća



Izvor: vlastita izrada

6. Zaključak

Implementacija prediktivne analitike u ERP sustavu omogućuje organizacijama da dublje razumiju svoje poslovanje, identificiraju trendove, predvide potrebe kupaca i optimiziraju operativne procese. Kombinacija prediktivne analitike i "what if" simulacija pruža alate za dublje razumijevanje poslovanja, identifikaciju potencijalnih izazova i pronalaženje optimalnih rješenja. Uvođenje analitičkih pristupa u poslovne procese farmaceutskog poduzeća omogućava brže i bolje donošenje odluka te osigurava konkurentske prednosti na tržištu, kao što se vidjelo i na praktičnom primjeru diplomskog rada.

U uvodnom djelu rada postavljena su sljedeća istraživačka pitanja:

1. Kako prediktivna analitika može poboljšati učinkovitost ERP sustava?

Prediktivna analitika može poboljšati učinkovitost ERP sustava tako što omogućava bolje predviđanje budućih trendova i potreba poslovanja. ERP sustav može koristiti prediktivnu analitiku za predviđanje buduće potražnje za proizvodima i uslugama, te za optimizaciju proizvodnih procesa i upravljanje zalihama. Također, prediktivna analitika može pomoći u prepoznavanju trendova u ponašanju kupaca i u prilagodbi marketinških kampanja za povećanje prodaje.

2. Koje su glavne prednosti implementacije "what-if" simulacija u ERP sustavu?

Prediktivna analitika i "what-if" simulacije mogu se koristiti u planiranju poslovanja tako što omogućavaju bolje predviđanje budućih trendova i potreba tržišta. Ovo može pomoći u donošenju odluka o ulaganjima, razvoju novih proizvoda i usluga, te u optimizaciji procesa i resursa. Također, prediktivna analitika i "what-if" simulacije mogu pomoći u planiranju budžeta, te u smanjenju rizika poslovanja.

3. Kako se prediktivna analitika i "what-if" simulacije mogu koristiti u planiranju poslovanja?

Glavne prednosti implementacije "what-if" simulacija u ERP sustavu su da omogućava korisnicima da testiraju različite scenarije i predviđaju ishode prije nego što donesu konačnu odluku. Na taj način, korisnici mogu donositi bolje informirane odluke koje su temeljene na stvarnim podacima. "What-if" simulacije mogu pomoći u planiranju budućnosti poslovanja, optimizaciji procesa i resursa, te u smanjenju rizika poslovanja

4. Koje su mogućnosti za implementaciju prediktivne analitike u ERP sustavu?

Integracija vanjskih alata za prediktivnu analitiku: ERP sustav može biti integriran s vanjskim alatima za prediktivnu analitiku poput alata za strojno učenje i analizu podataka. Ovo

omogućuje korištenje algoritama strojnog učenja kako bi se predvidjeli budući trendovi i ponašanje kupaca. Također, korištenje ERP podataka za prediktivnu analitiku; ERP sustav sadrži mnogo podataka o poslovanju tvrtke, a ti podaci mogu se koristiti za prediktivnu analitiku. Primjerice, podaci o prodaji mogu se koristiti za predviđanje budućih prodajnih trendova. Može se koristiti i za automatizaciju prediktivne analitike, odnosno sustav može biti programiran za automatsko generiranje prediktivnih modela temeljenih na podacima koji se unose u sustav. Ovo može biti korisno za generiranje predviđanja bez potrebe za ručnim analizama.

Popis literature

KNJIGE

1. Bakhshi, S., & Bates, M. (2018). Predictive Analytics: The Power to Predict Who Will Click, Buy, Lie, or Die. John Wiley & Sons.
2. Budgaga, W., Malensek, M., Pallickara, S., Harvey, N., Breidt, F. J., & Pallickara, S. (2016). Predictive analytics using statistical, learning, and ensemble methods to support real-time exploration of discrete event simulations. *Future Generation Computer Systems*, 56, 360-374.
3. Chen, H., Chiang, R. H., & Storey, V. C. (2012). Business intelligence and analytics: From big data to big impact. *MIS quarterly*, 36(4), 1165-1188.
4. Gartner. (2019). Predicts 2020: Artificial intelligence. Gartner Inc.
5. Han, J., Kamber, M., & Pei, J. (2011). Data mining: Concepts and techniques. Elsevier.
6. Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: data mining, inference, and prediction. Springer Science & Business Media.
7. Montgomery, D. C., Peck, E. A., & Vining, G. G. (2012). Introduction to linear regression analysis. John Wiley & Sons.
8. Pavlović, R., & Dejanović, R. (2014). Big Data i poslovna inteligencija.
9. The best run SAP. (2022). SAP Analytics Cloud, analytics designer Developer Handbook. Document Version: 12.1 – 2022-05-25.
10. Varga, M. (2004). Poslovna inteligencija: ciljevi i metode. Ekonomski fakultet Zagreb.
11. Varga, M. (2020). Baze podataka: konceptualno, logičko i fizičko modeliranje podataka.
12. Waisberg, D., Kaushik, A. (2009): Web Analytics 2.0: Empowering Customer Centricity, SEMJ.org 2, No. 2.

STRUČNI ČLANCI

1. Chou, D. C., Bindu Tripuramallu, H., & Chou, A. Y. (2005). BI and ERP integration. *Information management & computer security*, 13(5), 340-349.
2. Davenport, T. H. (2006). Competing on analytics. *Harvard business review*, 84(1), 98-107.
3. Davenport, T. H., Harris, J. G., & Cantrell, S. (2004). Enterprise systems and ongoing process change. *Business process management journal*, 10(1), 16-26.
4. Deka, G. C. (2014). Big data predictive and prescriptive analytics. In *Handbook of research on cloud infrastructures for Big Data analytics* (pp. 370-391). IGI Global.

5. Hsieh, Y. H. (2017). The Next-Generation ERP. In *Advanced Methodologies and Technologies in Business Operations and Management* (pp. 31-50). IGI Global.
6. Nazarov, D. M., Kovtun, D. B., & Reichert, T. N. (2020). SAP Analytics Cloud: intellectual analysis of small and medium-sized business activities in Russia in the context of COVID-19. In *2020 IEEE 14th International Conference on Application of Information and Communication Technologies (AICT)* (pp. 1-6). IEEE.
7. Park, J., & Kim, Y. (2017). Predictive Analytics in Enterprise Resource Planning (ERP) Systems: A Review. *Journal of Open Innovation: Technology, Market, and Complexity*, 3(17), 1-17.
8. Radmilović, D. (2012). *Poslovna inteligencija* (Doctoral dissertation, University of Zagreb. Faculty of Organization and Informatics Varaždin. Department of Theoretical and Applied Foundations of Information Sciences).
9. SAP. (2020). *Data Modeling with SAP Analytics Cloud*.
10. Soldić-Aleksić, J., Krasavac, B. C., & Karamata, E. (2020). Business analytics: new concepts and trends. *Management: Journal of Sustainable Business and Management Solutions in Emerging Economies*, 25(2), 15-29.

INTERNETSKI IZVORI

1. Bokulić, T. (2021). *Prediktivna analiza prodaje* (Diplomski rad). Preuzeto s <https://urn.nsk.hr/urn:nbn:hr:217:813610>
2. Čuljak, I. (2018). *ERP sustavi u poslovanju poduzeća* (Specijalistički diplomski stručni). Preuzeto s <https://urn.nsk.hr/urn:nbn:hr:112:393364>
3. Erna, G. (2018). *Izrada prediktivnih modela u marketingu* (Diplomski rad). Varaždin: Sveučilište u Zagrebu, Fakultet organizacije i informatike. Preuzeto 24.5.2023. s <https://urn.nsk.hr/urn:nbn:hr:211:359248>
4. Europski parlament (2020). Preuzeto 27.5.2023. https://www.europarl.europa.eu/doceo/document/TA-9-2020-0275_HR.html
5. Farser Team (2022). *What-if Analysis in Sales Planning* Preuzeto 15.5.2023. s <https://www.farseer.io/post/what-if-analysis-in-sales-planning-how-to-excel-template-example>
6. INPro3. Preuzeto 27.2. 2023 s <https://inpro.hr/sto-je-bi-i-zasto-je-vazan-za-vase-poslovanje/>
7. Komorčec, M. (2008) *Microsoft Dynamics NAV*. Preuzeto 15.3.2023. s <http://www.infotrend.hr/clanak/2008/12/microsoft-dynamicsnav%C2%AE,28,562.html>

8. MongoDB. (2022). What is NoSQL? Preuzeto 24.3. 2023. s <https://www.mongodb.com/nosql-explained>
9. Perkuto. (2023). Five Ways to Integrate Predictive Analytics with Your Marketing Automation. Preuzeto 25.5.2023. s <https://perkuto.com/blog/integrate-predictive-analytics-with-marketing-automation/>
10. Rašetina, K. (2017). Komparativna analiza alata za web analitiku (Doctoral dissertation, University of Split. Faculty of economics Split).
11. SAP Analytics Cloud & Live Connections | Taking the First Step. Preuzeto 24.3. 2023. s <https://www.truqua.com/sap-analytics-cloud-live-connections-first-step/>
12. SAP blog (2021). Predictive Planning What-If Simulation in SAP Analytics Cloud. <https://blogs.sap.com/2021/09/15/predictive-planning-what-if-simulation-in-sap-analytics-cloud/>
13. SAP blog (2022). SAP Analytics Cloud: Introduction to Predictive Scenarios, and their applications. <https://blogs.sap.com/2022/06/01/sap-analytics-cloud-introduction-to-predictive-scenarios-and-applications/>
14. Zapbi. Preuzeto 16.3.2023. s <https://www.zapbi.com/solution/microsoft-dynamics-nav-reporting-solution/>

Kratice

BI = Business intelligence

IoT = Internet Of Things

KPI = Ključni pokazatelji uspješnosti

SAC = SAP Analytics Cloud

VDT = Value Driver Tree

SKU = prodajna jedinica

COGS = Trošak prodane robe

EX-FACTORY = prodajna cijena proizvoda

KNN = K najbližih susjeda

AI = Artificial intelligence

Popis slika

Slika 1. Poslovna inteligencija kroz procese i aktivnosti.....	5
Slika 2. Prikaz sučelja u NAV-u za izvještavanje	10
Slika 3. Proces web analitike	16
Slika 4. Dinamička veza s podacima	25
Slika 5. Marketinška automatizacija.....	32
Slika 6. Modelirana excel tablica.....	39
Slika 7. Uvoz podataka iz excel datoteke u SAC	40
Slika 8. Kombiniranje podataka u SAC-u.....	40
Slika 9. Uvoz Master Data SKU datoteke	40
Slika 10. Kombiniranje podataka sa SKU skupom podataka.....	41
Slika 11. Kombiniranje podataka s Master Data Clients skupom podataka	42
Slika 12. Kombiniranje podataka s Scenario Clients List skupom podataka.....	42
Slika 13. Konačni izgled kreiranja modela sa odgovarajućim redovima	43
Slika 14. Prikaz strukture modela	44
Slika 15. Mogućnost ponovne izgradnje modela.....	44
Slika 16. Gross Revenue kalkulacija.....	44
Slika 17. Base discount kalkulacija	46
Slika 18. Promo discount kalkulacija.....	46
Slika 19. Net Revenue kalkulacija.....	47
Slika 20. COGS kalkulacija.....	47
Slika 21. Gross profit1 kalkulacija	48
Slika 22. Gross Margin % kalkulacija.....	48
Slika 23. Prikaz dodanih kalkulacija u model	49
Slika 24. Grafički prikaz strukture modela	50
Slika 25. Mjere unutar dimenzije Account.....	50
Slika 26. Prikaz odabira prediktivnog scenarija.....	51
Slika 27. Scenario SKU list.....	52
Slika 28. Prikaz izvještajnih prozora nakon izvršenja klasifikacije	53
Slika 29. Prikaz performansi izvršene klasifikacije u Predictive Scenarios	53
Slika 29. Matrica konfuzije	54
Slika 30. Krivulja %Detected target.....	54
Slika 31. Krivulja Lift	55
Slika 32. Lorenzova krivulja	55
Slika 33. Krivulja Density	56
Slika 34. Prikaz sažetka treniranja za regresiju.....	56

Slika 35. Prikaz Influencer Contributionsa	57
Slika 34. Utjecaj dimenzija na „Volume“ vrijednost	58
Slika 38. Prikaz Buildera za grafikone u CANVAS storyu	61
Slika 38. Predviđanje iznosa promo popusta za 2023. godinu	62
Slika 39. Pametni uvid u poslovanje – promo discount	63
Slika 40. Scenario promo.....	65
Slika 41. Scenario price.....	65
Slika 42. COGS.....	65
Slika 43. Ex factory.....	66
Slika 44. Base discount	67
Slika 45. Gross revenue	67
Slika 46. Net revenue	68
Slika 47. Promo discount.....	68
Slika 48. Gross profit	69
Slika 49. Gross Margin %	69
Slika 53. JavaScript kod za prikaz podataka za lijek brenda Zolodronic.....	74
Slika 56. JavaScript kod za prikaz podataka za područje liječenja.....	76
Slika 57. Konačni izgled aplikacije	77
Slika 58. Izrada stabla pokretača vrijednosti	78
Slika 59. Raspon promatranog vremena.....	79
Slika 60. Korištenje kalkulacija u stablu pokretača vrijednosti.....	79
Slika 61. Prikaz stabla pokretala vrijednosti prije pokretanja simulacije	80
Slika 63. Iznos neto prihoda prije promjene	81
Slika 64. Promjena poslovanja poduzeća	82

Popis tablica

Tablica 1. Prikaz modula koje nudi SAP ERP	7
Tablica 2. Pregled BI opcija po modulima ERP sustava	12
Tablica 3. Trendovi u korištenju naprednih analitičkih funkcionalnosti	17
Tablica 4. Primjeri primjene prediktivne analitike u proizvodnji	28
Tablica 5. Primjeri primjene prediktivne analitike u financijama	29

Popis isječaka kôda

Isječak kôda 1. Primjena filtriranja dimenzija	70
Isječak kôda 2. Primjena filtra dimenzije Client <code>var selection1 = this.getText();</code>	71

Korišteni alati

1. SAP Analytics Cloud
2. Drawio
3. Microsoft Excel