

# Vpeljava umetne inteligence v poslovno analitiko

Aleksej Milošević, Gregor Pirš, Miha Pavlinek

Databox Inc., Ptuj, Slovenija

aleksej@databox.com, gregor.pirs@databox.com, miha.pavlinek@databox.com

Poslovni uporabniki se vsakodnevno srečujejo z ogromnim številom ključnih kazalnikov in povezanih metrik, preko katerih spremljajo uspešnost poslovanja. Pri tem pogosto analizirajo ogromne količine podatkov ter v njih iščejo povezave, vzorce in trende ter iz tega oblikujejo znanje, s katerim skušajo pridobiti prednost pred konkurenco. Ker se s količino podatkov večja kompleksnost njihovega razumevanja, se podjetja običajno poslužujejo rešitev za poslovno analitiko, ki omogočajo spremljanje poslovanja preko preglednih plošč, poročil, alarmov, ipd. Prav takšno rešitev ponujamo v podjetju Databox. Z namenom, da podpremo vse štiri tipe poslovne analitike: deskriptivno, diagnostično, prediktivno in preskriptivno, smo v naše produkte vpeljali številne funkcionalnosti, ki jih poganjajo metode umetne inteligence. Z njimi surove podatke pretvarjamo v kakovostne informacije in znanja iz katerih uporabniki črpajo nove ugotovitve, s pomočjo katerih sprejemajo boljše poslovne odločitve. V prispevku bomo predstavili inteligentne rešitve kot so napovedovanje metrik, zaznavanje anomalij, korelacije ter funkcionalnosti, ki temeljijo na generativni umetni inteligenci. Naslovili bomo izzive pri zasnovi in razvoju tovrstnih rešitev ter ponudili vpogled v njihovo delovanje.

## **Ključne besede:**

poslovna analitika

umetna inteligenca

napovedovanje

zaznavanje anomalij

korelacije

generativni modeli

## 1 Uvod

Poslovna analitika zajema veščine, tehnologije in prakse za preiskovanje in proučevanje preteklih poslovnih rezultatov z namenom pridobivanja vpogledov in usmerjanja poslovnega načrtovanja [1]. Na osnovi povezovanja podatkov iz različnih virov in uporabe statističnih metod se področje osredotoča predvsem na razvoj novih vpogledov, razumevanje poslovne uspešnosti in napovedovanje poslovnih dogodkov.

Za razliko od poslovne inteligence, ki je vezana na pregled in analizo preteklega poslovanja na osnovi predpriprave podatkov in poročil, se poslovna analitika ukvarja s poglobljeno analizo podatkov ter prediktivnimi modeli za podporo odločanju in razvoju poslovne strategije. Na primer, medtem ko poslovna inteligenca podjetju predstavlja trenutni profil idealne stranke, poslovna analitika ponuja vpogled v profil bodoče stranke.

V podjetju Databox razvijamo SaaS produkt za poslovno analitiko, ki je prilagojen zlasti manjšim in srednjim podjetjem, katera si težko privoščijo postavitev in vzdrževanje analitične infrastrukture ter analitika, ki bi pridobival in preiskoval podatke. Poleg zbiranja podatkov, upravljanja preglednih plošč ter spremljanja poročil in alarmov želimo našim odjemnikom ponuditi tudi dodatne vpoglede v poslovanje in jih voditi v sprejemanje boljših odločitev. V ta namen dodajamo nove funkcionalnosti, ki pretežno temeljijo na statističnih metodah in metodah umetne inteligence.

Pri tem se srečujemo s številnimi izzivi. Eden pomembnejših je generalizacija metod in parametrov za široko paleto podatkovnih zbirk. Medtem ko se podatkovni analitik v podjetju ukvarja s specifično zbirko podatkov nad katero v okviru razvoja vpogledov izvaja eksperimente in optimizira parametre modelov, naši sistemi uporabljajo generalne optimume, ki so prilagojeni da delujejo nad različnimi podatkovnimi zbirkami.

## 2 Štirje tipi poslovne analitike

Dolgoročni cilj naših produktov je celovita podpora podjetjem tako pri sprejemanju poslovnih odločitev kot pri poslovnem planiranju na podlagi podatkov. V ta namen želimo podpreti vse 4 tipe analitike, ki so boljše predstavljene v nadaljevanju [2].

**Opisna analitika** preučuje podatke z namenom izboljšanja razumevanja dogajanja v preteklosti. Povzema zgodovinske podatke in ponuja vpogled v vzorce, trende in ključne metrike. Gre za najbolj osnovno vrsto analitike, kjer se za potrebe analize običajno uporabljajo agregacijske funkcije in osnovni matematični koncepti. V to kategorijo sodijo rešitve poslovne inteligence s preglednimi ploščami, poročili in alarmi.

**Diagnostična analitika** je nadgradnja opisne analitike, ki se ukvarja z iskanjem povezav med preteklimi dogodki in odgovarja na vprašanje zakaj? Vključuje poglobljeno analizo podatkov za prepoznavanje temeljnih vzrokov določenega rezultata.

**Napovedna analitika** se na podlagi zgodovinskih podatkov in statističnih metod ukvarja z napovedovanjem prihodnjih dogodkov ali rezultatov. Z uporabo vzorcev in povezav v podatkih podaja verjetnosti dogodkov. Sem sodi napovedovanje časovnih vrst, napovedovanje osipa (ang. Churn Prediction), pa tudi ocenjevanje uporabnikove preference do posameznih izdelkov v priporočilnih sistemih.

**Preskriptivna analitika** podaja priporočila za specifična dejanja z namenom optimizacije rezultatov. Posredovana priporočila so oblikovana na podlagi napovednih modelov in poslovnih ciljev. Uporablja napredne algoritme, tehnike optimizacije in simulacije za ustvarjanje uporabnih vpogledov. Dober primer preskriptivne analitike so sistemi za točkovanje in rangiranje uporabnikov glede na njihova dejanja. Te uporabljajo zlasti

prodajniki, ki izbirajo in nagovarjajo le tiste uporabnike, pri katerih je možnost za pretvorbo v plačljive stranke največja.

Poleg zgoraj naštetih se v zadnjem obdobju vse več omenja tudi t.i. obogatena analitika (ang. Augmented Analytics) [3]. Sem sodijo sistemi, ki s pomočjo strojnega učenja in obdelave naravnega jezika avtomatizirajo analitične procese, uporabniku pa na razumljiv način predstavijo rezultate in vpogled. Takšen primer bi bil sistem za avtomatsko spremljanje metrik poslovanja ter redno obveščanje o spremembah, trendih in posebnostih v naravnem jeziku.

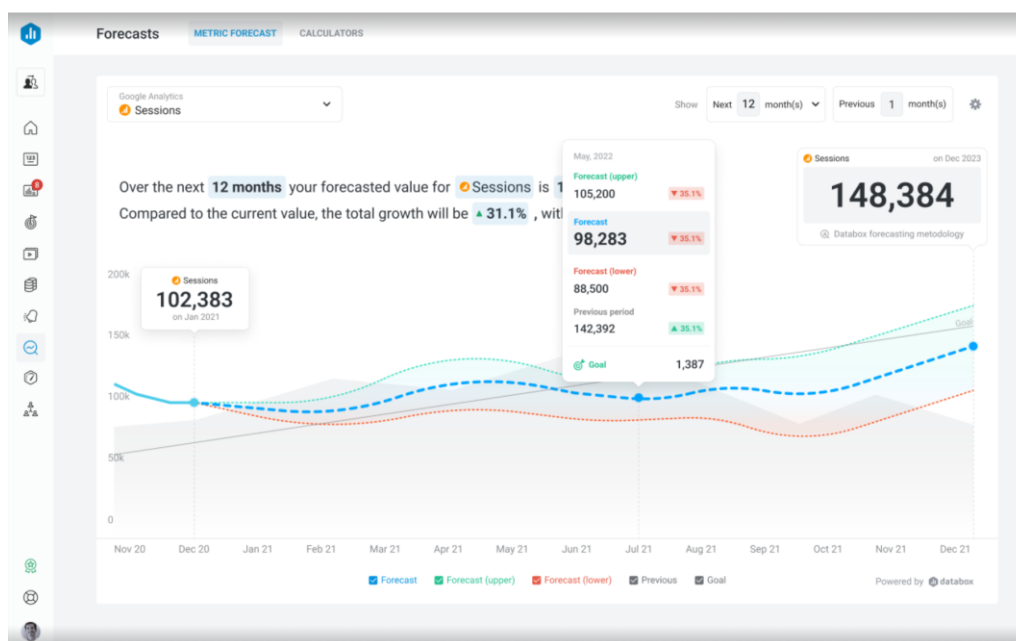
### 3 Nove funkcionalnosti v produktu za poslovno analitiko

#### 3.1 Napovedovanje poslovnih metrik

Z napovedovanjem poslovnih metrik želimo našim uporabnikom ponuditi vpogled v prihodnost poslovanja. Pri tem uporabljamo modele za napovedovanje časovnih vrst iz odprtokodnega orodja Prophet [3]. Pri izbiri napovednih modelov smo se osredotočili predvsem na hitrost učenja in točnost. Prophet za napovedovanje uporablja preprostejšie regresijske modele, ki v primerjavi z ostalimi bolj sofisticiranimi modeli zagotavljajo zelo hitre napovedi z visoko natančnostjo. Poleg tega ima sposobnost samodejnega prilagajanja parametrov, je odporen na manjkajoče podatke, v rezultatih pa poleg napovedi podaja tudi intervale zaupanja, s čimer je zelo primeren za napovedovanje raznolikih časovnih vrst. Slabost Propheta je njegova omejenost na univariatne časovne vrste, kar pomeni, da zna modele prilagajati zgolj nad eno časovno-odvisno spremenljivko.

Prophet pri svojem delovanju časovno vrsto razdeli na tri komponente: sestavljeni trendi, sezonskost in prazniki. Komponenta sestavljenih trendov je oblikovana s pomočjo sestave linearnih ali logističnih krivulj in samodejnim zaznavanjem spremembe trenda. Prav tako je samodejno tudi zaznavanje sezonskosti, medtem ko je potrebno praznike pred prilagajanjem modela posredovati manualno preko seznama.

V naši storitvi za napovedovanje poslovnih metrik dodatno pred učenjem modela iz podatkov porežemo prevelika odstopanja, ki se kažejo v obliki nenadnih skokov ali padcev. S tem se izognemo širokim intervalom zaupanja ter vplivu na zaznavanje sezonskosti ter tako povečujemo robustnost modela.



Slika 1: Funkcionalnost za napovedovanja poslovnih metrik.

Kot omenjeno v uvodu, je bil glavni izziv razvoja storitve za napovedovanja generalizacija modelov za raznolike časovne vrste. To je bilo deloma rešeno z ogrođjem za evalvacijo napovednih modelov, preko katerega smo poganjali eksperimente ter preučevali njihove rezultate, deloma pa s segmentacijo časovnih vrst glede na njihove značilnosti ter prilagajanje parametrov .

Za naprej si želimo vpeljati multivariatne modele, ki bodo pri napovedovanju uporabljali znanje iz različnih povezanih metrik. Npr. za napovedovanje skupnega letnega prihodka v spletni trgovini bo algoritem zmožen poleg zgodovine prihodkov uporabiti tudi obisk na spletni strani, stopnjo konverzije ter vrednost povprečnega naročila. Glavni izziv pri takšnih modelih je vpeljava dodatnih podatkovnih cevovodov, bistveno daljši čas gradnje modela in posledično podražitev. Takšnih modelov ni mogoče pripravljati sproti, pač pa jih je potrebno graditi na zalogo.

### 3.2 Zaznavanje anomalij

Agilnost in sposobnost prilagajanja spremembam sta dve od ključnih lastnosti, ki izjemno uspešna podjetja dvigujejo nad povprečje. V tem smislu je prepoznavanje nenavadnih in nepredvidljivih dogodkov - oziroma odkrivanje anomalij - eno izmed osrednjih orodij. Pravočasno zaznavanje takšnih anomalij podjetjem omogoča hitro reakcijo z namenom zmanjševanja možne škode, hkrati pa izkoriščanje nastalih priložnosti. Za odkrivanje anomalij se uporabljajo modeli, ki vključujejo statistične metode in pristope strojnega učenja, med katerimi so tako klasične kot tudi metode, temelječe na nevronske mrežah. Postopek rezultira z oceno anomalije v obsegu med -1 in 1, ki prikazuje stopnjo nenavadnosti posamezne podatkovne točke.

Obstajajo tri vrste anomalij: točkovne, kontekstualne in kolektivne [4]. Točkovne ali dogodkovne anomalije glede na vrednost bistveno odstopajo od ostalih točk v nizu. Za njih je značilno, da so globalne, saj so anomalne v primerjavi s poljubno normalno točko v časovni vrsti. Najpogosteje nastanejo zaradi napak pri zbiranju ali obdelavi podatkov, ali pa označujejo nenavaden ali nepričakovan dogodek. Kontekstualne anomalije v globalnem smislu posebej ne izstopajo, vendar so anomalne znotraj lokalnega konteksta. Naglo povečanje števila uporabnikov med božičem ali nenadno zmanjšanje prodaje na začetku leta se lahko smatra kot normalno obnašanje zaradi časa, v katerem se anomalija pojavi. Če pa prodaja skozi ta čas ostane relativno stabilna, lahko to interpretiramo kot kontekstualno anomalijo. Kolektivne anomalije predstavljajo skupino. Kolektivne anomalije predstavljajo več zaporednih anomalij znotraj niza. Vzrok za vse tipe anomalij je potrebno določiti empirično.

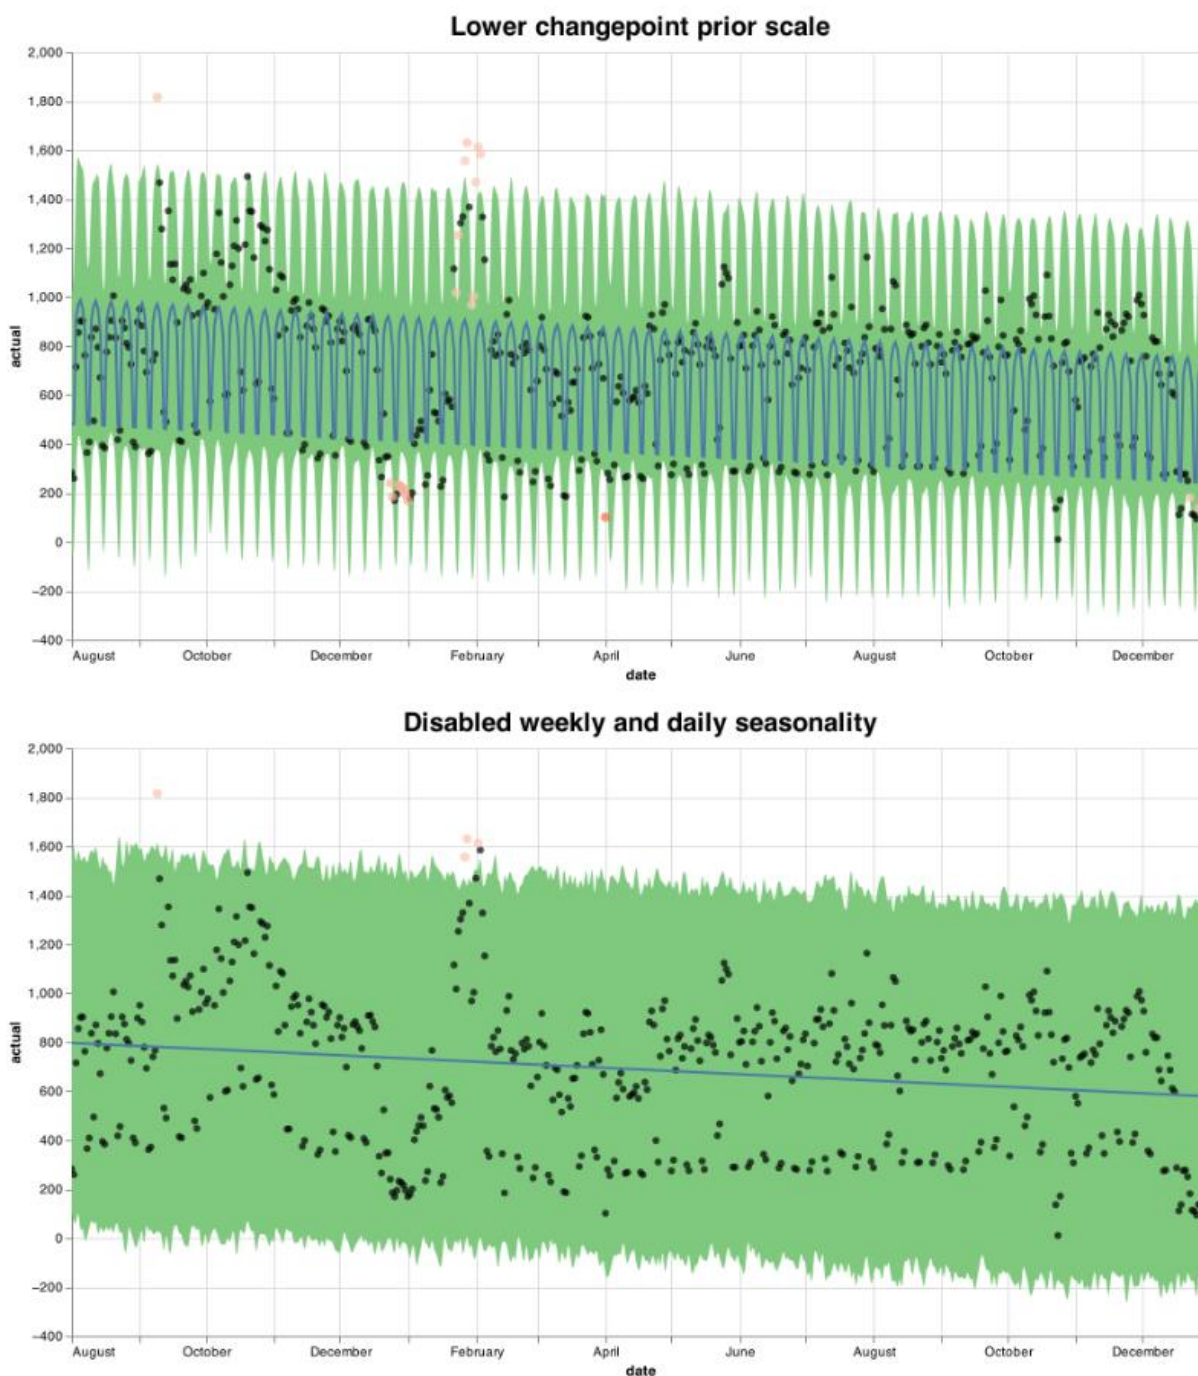
Pri razvijanju sistema za zaznavanje anomalij v okviru produkta Databox je ključnega pomena izbira modela, ki omogoča hitro identifikacijo anomalij ter zmožnost obdelave obsežnih časovnih nizov. Zaradi velikega števila različnih poslovnih časovnih nizov je robustnost modela, ki ne potrebuje neprestanega človeškega nadzora, še posebej pomembna. Za zaznavanje anomalij smo, podobno kot za napovedovanje časovnih nizov, uporabili Facebookov model Prophet. Ta model se dobro prilagaja trendom in sezonskim vzorcem v podatkih, zato ga je mogoče uporabiti ne le za napovedovanje prihodnosti, temveč tudi za "napovedovanje" sedanjosti. Če dejanska vrednost preseže interval zaupanja napovedi, lahko to kaže na anomalijo. Ker model v napoved vključuje element sezonskosti, je mogoče zaznavanje tako točkovnih kot kontekstualnih in kolektivnih anomalij.

Interpretacije posameznih anomalnih pojavov je odgovornost uporabnika.

Vključitev zaznavanja anomalij kot funkcionalnost platforme je posebej zanimivo za Databoxovo ciljno publiko majhnih in srednje velikih podjetij, ki pogosto nimajo finančnih in strokovnih kapacitet za vzpostavitev lastnih sistemov. Sistem namreč lahko omogoča zaznavanje anomalij za več kot 80 različnih integracij, med drugimi tudi za tiste, ki v lastni platformi zaznavanja anomalij ne podpirajo. Najbolj zaželen primer uporabe zaznavanje anomalij je gotovo avtomatiziranje alarmov, kar omogoča strankam, da se lahko v najkrajšem možnem času odzovejo na izredni pojav.

Glavni izziv pri zaznavanju anomalij predstavlja heterogena narava časovnih vrst. Kar je za eno metriko in uporabnika anomalija, to ne velja za drugega uporabnika. Z nastavljanjem hiperparametrov modela je mogoče spreminjati občutljivost zaznavanja anomalij. To omogoča razvoj sistema za povratne informacije, ki uporabniku omogoča spreminjanje občutljivosti modela glede na lastne potrebe.

Na sliki 2 je prikazana primerjava rezultata procesa zaznavanja anomalij na primeru poslovne časovne vrste z dnevno granulacijo in izrazito tedensko sezonskostjo. Na zgornjem grafu je zaznavanje sezonskosti vklopljena, na spodnjem pa je izklopljena. Zaradi prisotnosti sezonskosti so na zgornjem grafu vidne razen točkovnih anomalij tudi kontekstualne anomalije, na spodnjem pa zgolj točkovne.




Slika 2: Primerjava rezultata procesa zaznavanja anomalij.

### 3.3 Korelacije med poslovnimi metrikami

Da bi podprli tudi diagnostično analitiko, trenutno razvijamo funkcionalnost za predstavitev korelacij med poslovnimi metrikami. Cilj je, da za uporabnika identificiramo povezane metrike in jih ustrezno vizualiziramo, kar bo uporabnikom omogočilo vpogled v relacije med metrikami. Osnovna zahteva funkcionalnosti je v njeni intrepabilnosti, kar pomeni, da morajo biti povezane metrike smiselno predstavljene ter uporabniku razložljive. V ta namen smo pred pričetkom razvoja v okviru raziskovalnega projekta analizirali različne mere podobnosti za

časovne vrste ter preučevali njihovo časovno zahtevnost, obravnavanje manjkajočih vrednosti ter interpretabilnost.

Mere podobnosti, ki smo jih izbrali in jih lahko uporabimo v produktu so Pearsonov koeficient korelacije, navzkrižne korelacije (ang. Cross-correlation) ter metoda dinamičnega časovnega sledenja (ang. Dynamic Time Warping - DTW). Vsaka med njimi prinaša izzive, zlasti ko gre za interpretabilnost rezultatov. Npr. metoda DTW zahteva kompleksne vizualizacije, vendar lahko ponudi tudi najbolj nepričakovane vpogleda.



Slika 3: Predstavite korelacij z metodo dinamičnega časovnega sledenja.

Korelacij pa ne želimo podpirati zgolj v okviru vizualizacij, pač pa želimo na njihovi osnovi uporabnika tudi obveščati, npr. kadar se korelirane metrike pričnejo oddaljevati, ali pa ga usmerjati na korelirane metrike npr. pri zaznavanju anomalij. Končni cilj je identifikacija ključnih dejavnikov uspešnosti poslovanja. Npr. ob vpogledu, da prodaja v poslovalnici korelira s tedensko sezonskostjo in je največja ob sobotah v času tik pred koncem delovnega časa, lahko poslovanje izboljšamo s prilagoditvijo delovnega časa.

### 3.4 Generativna umetna inteligenca

Generativna umetna inteligenca se je v preteklem letu izkazala kot prelomna tehnologija, ki korenito spreminja naš način življenja in dela. Generiranje nove vsebine se je izkazalo za uporabno ne samo v kreativnih disciplinah, kot so umetnost, glasba in ustvarjalna besedila, ampak tudi v poslovni analitiki. Ta tehnologija Databoxu omogoča prehod iz vloge orodja za poročanje in vizualizacijo podatkov v vlogo aktivnega asistenta pri sprejemanju odločitev.

V kombinaciji z obsežnimi agregiranimi podatki, generativna umetna inteligenca omogoča integracijo funkcionalnosti, ki z dodajanjem prilagojenih informacij obogatijo obstoječe podatke. Eden izmed ključnih primerov uporabe v našem produktu je generiranje celovitih pisnih poročil, ki poudarjajo ključne ugotovitve. S pomočjo generativne umetne inteligence lahko ustvarimo pripovedi, ki izpostavijo najpomembnejše informacije in tako olajšajo razumevanje kompleksnih podatkov širokemu krogu uporabnikov.

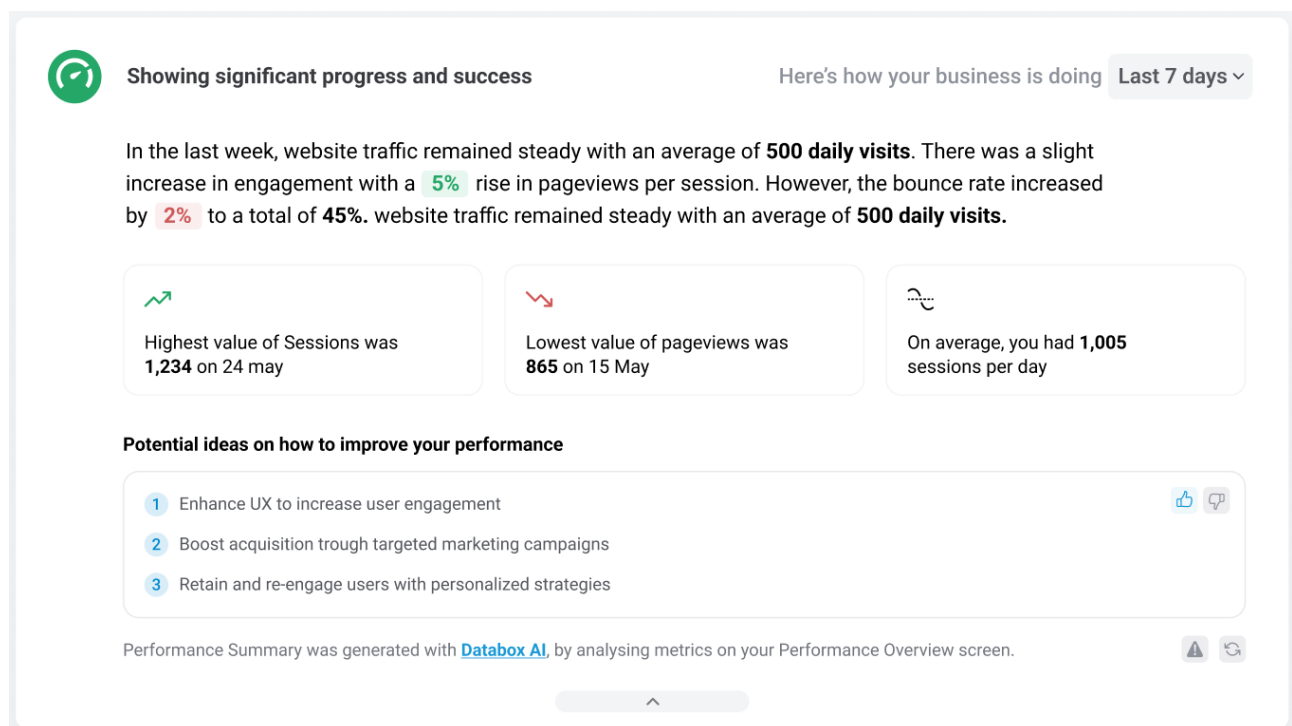
Z namenom, da bi to omogočili, smo razvili mikroritve, ki ponuja funkcionalnosti generativne umetne inteligence drugim komponentam Databoxovega storitvenega ekosistema. Storitve prejme podatke in metapodatke poslovnih metrik, nato pa vrne povzetek, trend in priporočila, ki temeljijo na podatkih in rezultatih drugih storitev, podprtih z umetno inteligenco. Povzetek vključuje deskriptivni in analitični opis podatkov, trend



pa je binarna vrednost, ki zbere trend vseh podanih podatkov v en rezultat. Priporočila so rezultat preskriptivne analize generativnega modela in so predstavljena v obliki alinej. Odjemalci storitve lahko prilagajajo parametre, kot so največje število znakov in število priporočil.

Uporabljamo generativni modelt GPT4 [6], katerega razvija raziskovalni laboratorij podjetja OpenAI. Zanj smo se odločili na podlagi pozitivnih izkušenj med testiranjem. Zahtevnost našega produkta namreč presega zgolj proizvodnjo golega besedila. Generativni model mora besedilo obogatiti s HTML značkami, ki besedilo dopolnjujejo z dodatno semantiko, kot je na primer uporaba zelene barve za naraščajoče in rdeče barve za padajoče metrike. Da bi bilo branje rezultatov modela enostavnejše, je dodatna zahteva, da model vrne rezultate skladno z JSON shemo, ki je podana v vhodnih podatkih modela.

Razvoj aplikacij, podprtih z velikimi jezikovnimi modeli predstavlja poseben izziv. Razen pravilne integracije v že obstoječe sisteme je potrebno pri snovanju rešitve upoštevati skalabilnost, odzivnost in upravljanje s stroški. Posebno težavo pri razvoju in testiranju rešitve je predstavljala omejitev dostopa do modela ChatGPT4. Zaradi velikega povpraševanja po modelu smo bili precej časa na čakalni listi za dostop. Posledično smo aplikacijski del rešitve začeli razvijati preden smo dobili dostop do ChatGPT4. Rešitve smo prototipirali s spletnim vmesnikom, ki ga gosti OpenAI. Razen tega smo se spopadali z najboljšim načinom priprave in posredovanja JSON sheme tako, da jo bo model uporabil za formatiranje izhoda. Kot rešitev smo uporabili "tagging" funkcionalnost knjižnice LangChain[7], katera se je v svetu razvoja aplikacij na osnovi velikih jezikovnih modelov izkazala kot nepogrešljivo.



Slika 4: Primer generiranega opisa večih metrik.

## 4 Zaključek

Živimo v vznemirljivem času, ko se umetna inteligenca razvija s svetlobno hitrostjo. Tehnološki vzpon na tem področju so v zadnjem obdobju dodatno pospešili veliki jezikovni modeli ter povezane tehnologije kot je npr. ogrodje Langchain. Podjetja, ki se tega tehnološkega napredka zavedajo in tehnologijo ustrezno izkoriščajo, bodisi z neposredno vpeljavo teh tehnologij v procese dela, bodisi z uporabo naprednih orodij za poslovno analitiko, so nedvomno učinkovitejša in si ustvarjajo konkurenčno prednost.

V prispevku smo predstavili funkcionalnosti, preko katerih tudi sami vpeljujemo metode umetne inteligence v naš osnovni produkt za poslovno analitiko. Z napovedovanjem poslovnih metrik, zaznavanjem anomalij, iskanjem korelacij med metrikami ter funkcionalnostmi na osnovi generativne umetne inteligence želimo podpreti vse tipe poslovne analitike.

Predstavili smo tudi pomembnejše izzive, s katerimi smo se srečevali med razvojem. Pri tem izpostavljamo izzive zaradi uporabe generaliziranih metod in parametrov na različnih podatkovnih zbirkah, poseben izziv pa predstavlja tudi zavedanje, da obnašanje tovrstnih sistemov definirajo predvsem podatki in ne zgolj nekakšno zaporedje funkcij, česar smo vajeni iz tradicionalnih sistemov s popolnoma predvidljivimi izhodi.

## Literatura

- [1] [https://en.wikipedia.org/wiki/Business\\_analytics](https://en.wikipedia.org/wiki/Business_analytics), obiskano 21. 7. 2023.
- [2] <https://www.analyticsinsight.net/four-types-of-business-analytics-to-know/>, MEHTA Anushka, "Four Types of Business Analytics to Know", 2017, obiskano 21. 7. 2023.
- [3] [https://en.wikipedia.org/wiki/Augmented\\_Analytics](https://en.wikipedia.org/wiki/Augmented_Analytics), obiskano 27. 7. 2023.
- [4] TAYLOR Sean J, LETHAM Benjamin "Forecasting at scale", PeerJ Preprints, 2017.  
<https://facebook.github.io/prophet/>, obiskano 27. 7. 2023.
- [5] CHANDOLA Varun., BANERJEE Arindam, KUMAR Vipin, Anomaly detection: A survey, ACM Computing Surveys, letnik 41, številka 2 str. 1-58, 2009
- [6] OpenAI, GPT4 Technical report, 2023
- [7] <https://www.langchain.com>, obiskano 26.7.2023