Ko umetna inteligenca prevzame razvoj internih orodij

Gregor Kovač, Tomaž Kozlar, Žan Žvokelj

Bilumina d.o.o., Maribor, Slovenija
gregor.kovac@bilumina.com, tomaz.kozlar@bilumina.com, zan.zvokelj@bilumina.com

V lanskem prispevku smo predstavili lastno low-code platformo za razvoj ERP sistema, zgrajeno na jeziku SQL in jedru v Javi, z orodjema FormTool in Linea. Letos preverjamo, ali lahko umetna inteligenca postane resnična pomoč pri razvoju in vzdrževanju naših internih orodij. Odgovor najprej iščemo na primeru QueryToola, ki ga s pomočjo orodja za agentno programiranje prepišemo iz obstoječega okolja na spletno platformo Laravel. Umetna inteligenca nam je pomagala tudi pri drugih internih orodjih, kot so spremljanje, postavitev strežnikov, pomoč uporabnikom in podobno. Izkušnje umestimo v širši, inženirski in etični okvir ter izpostavimo, kje je bila pomoč umetne inteligence produktivna in kje je vodilno vlogo ohranil razvijalec.

Ključne besede:
umetna inteligenca
low-code
Laravel
QueryTool
Linea

Univerzitetna založba Univerze v Mariboru

ISBN 978-961-299-188-3
DOI https://doi.org/10.18690/um.feri.7.2026.18

1 Uvod

V prispevku na lanski konferenci OTS 2025 smo predstavili lasten low-code pristop k razvoju kompleksnega in visoko konfigurabilnega ERP sistema [1]. Pristop temelji na programskem jeziku SQL in jedru, napisanem v Javi, podpirata pa ga dve interni orodji: FormTool za oblikovanje vnosnih mask in Linea za načrtovanje podatkovne baze. Na ta način smo doslej zgradili več kot tisoč vnosnih mask in več tisoč baznih objektov, ob tem pa skrajšali čas razvoja in zmanjšali možnost napak.

V preteklem letu se nam je vse pogosteje zastavljalo vprašanje, ki si ga danes zastavlja velik del razvojne stroke: ali lahko umetno inteligenco, ki je postala izrazito zmogljiva in dostopna, uporabimo kot resnično pomoč pri razvoju in vzdrževanju naših internih orodij – ne le kot pripomoček za dopolnjevanje kode, temveč kot sodelavca pri večjih, dobro opredeljenih nalogah?

2 Prepis QueryToola na Laravel s pomočjo umetne inteligence

2.1. Kaj je QueryTool in zakaj smo ga izbrali za pilotni projekt

QueryTool je naše interno orodje za razčlenitev stavkov SQL na sestavne komponente: stolpce v stavku SELECT s pripadajočimi podatkovnimi tipi, pogoje v stavku WHERE z operatorji, tabele in poglede v delih FROM in JOIN, parametre (npr. :ID, :COUN_ID), agregacijske in skupinske klavzule (GROUP BY, HAVING), urejanje (ORDER BY) ter ugnezdene poizvedbe. Razčlenjena struktura se uporablja na več mestih v rešitvi ERP – pri povezovanju parametrov SQL in rezultatov poizvedbe s polji na vnosni maski. Ker je orodje funkcionalno zaokroženo, smo ga prepoznali kot idealnega kandidata za pilotni projekt.

QueryTool je napisan v programskem jeziku Java s pomočjo javanskega ogrodja GWT (Google Web Toolkit).

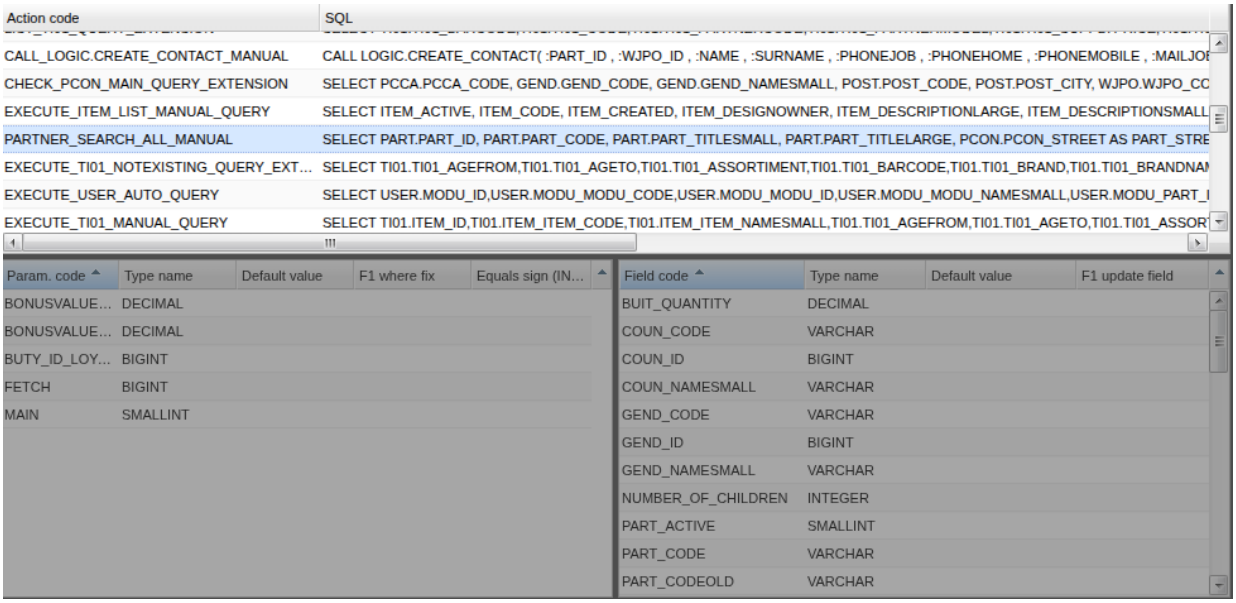

Slika 1: QueryTool

Vse podatke, ki jih vidite na sliki 1, uporabljamo v ERP aplikaciji pri izvajanju akcij, na katere je ta poizvedba vezana, in za preverjanje podatkov.

Ta rešitev ima tudi omejitve, ki jih sčasoma nismo odpravili iz različnih razlogov. Ena od takšnih omejitev je tudi, da orodje ne zna pridobiti ustreznih podatkov iz procedure v podatkovni bazi.

2.2. Razvojni proces s pomočjo umetne inteligence

2.2.1. Kako deluje velik jezikovni model

Preden opišemo sam potek dela, na kratko povzemimo, kako deluje velik jezikovni model (LLM), saj to pojasni tako njegove prednosti kot omejitve, na katere smo naleteli. LLM je model, naučen na velikih količinah besedila, ki deluje po enem osnovnem načelu: na podlagi dosedanjega besedila napoveduje najverjetnejši naslednji »žeton« (angl. token) – delček besede. Besedilo se najprej razbije na žetone, iz njih pa model zaporedoma gradi odgovor, žeton za žetonom.

Ključni gradnik je mehanizem pozornosti (angl. attention): pred izbiro vsakega novega žetona model presodi, kako pomemben je vsak od dosedanjih žetonov. Ta pozornost je omejen proračun – njena skupna teža je stalna in se porazdeli med vse žetone. Ko je konteksta malo, pomemben podatek dobi znaten delež pozornosti; ko je konteksta veliko, se isti podatek utopi med tisoči drugih [3]. To je neposreden vzrok za razpadanje konteksta in razlog, da se je pri prepisu obneslo delo z majhnimi, jasno omejenimi enotami.

Model nima baze dejstev, temveč statistične vzorce iz učnih podatkov. Zato je lahko izjemno tekoč in prepričljiv, hkrati pa lahko samozavestno navede napačen podatek (halucinacija) ali spregleda pomenske podrobnosti, na primer zanikanje [7]. Prav tako nima resničnega razumevanja izvorne kode ali poslovne logike; deluje po vzorcih, ki jih je videl. Za nas iz tega sledita dve praktični posledici: navodila in kontekst morajo biti konkretni in omejeni, vsak rezultat pa je treba preveriti glede na dokazano pravilno referenco - kar podrobneje opišemo v nadaljevanju.

2.2.2. Izbrani izdelek

Po tehtnem premisleku in posvetovanju smo v podjetju izbrali izdelek Claude podjetja Anthropic.

Claude ni vezan na en sam model, temveč omogoča izbiro med več modeli iste družine. To je koristno, ker za vsako vrsto naloge – zahtevno sklepanje, hitro rutinsko delo ali delo z dolgim kontekstom – izberemo najprimernejši model in s tem uravnovesimo kakovost, hitrost in stroške. V času pisanja so na voljo naslednji modeli [11]:

- **Claude Opus 4.8** - najzmogljivejši model za zahtevno agentno programiranje in poslovne naloge; kontekstno okno milijon žetonov,
- **Claude Sonnet 5** - najboljše razmerje med hitrostjo in zmogljivostjo; primeren za vsakodnevno razvojno delo; kontekstno okno milijon žetonov,
- **Claude Haiku 4.5** - najhitrejši model z zmogljivostjo blizu vrhunske; primeren za hitre, pogoste in cenovno občutljive naloge; kontekstno okno 200 tisoč žetonov,
- **Claude Fable 5** - najzmogljivejši širše dostopen model, zasnovan za dolgotrajne (angl. long-running) agente in najzahtevnejše naloge; kontekstno okno milijon žetonov.

Anthropic ponuja tudi specializiran model Claude Mythos 5 za obrambne kibernetskovarnostne naloge, ki pa je dostopen le po vabilu.

Pri prepisu QueryToola smo največ uporabljali model Claude Opus 4.8. Zanj smo se odločili, ker je zasnovan prav za zahtevno agentno programiranje in delo v poslovnem okolju: dobro razume obsežno izvorno kodo in poslovno logiko, njegovo veliko kontekstno okno (milijon žetonov) pa omogoča, da mu naenkrat predstavimo večje dele obstoječega orodja skupaj s pojasnili. Ob tem ponuja dobro razmerje med zmogljivostjo na eni strani ter hitrostjo in stroškom na drugi, kar je pomembno pri dolgotrajnem, iterativnem delu. Del najzahtevnejših nalog smo opravili z zmogljivejšim modelom Claude Fable 5, dokler njegova uporaba ni bila omejena na ameriške državljane; nato smo se v celoti vrnili na Opus 4.8.

2.3. Ponovna implementacija

Brez predhodnih izkušenj z agentnim programiranjem smo začeli po najbolj neposredni poti – z raziskovalnim, sproščenim slogom dela, ki se ga je prijelo ime »vibe coding«.

Najprej je bilo treba pripraviti spletno okolje z naslednjim pozivom:

```
V /var/www pripravi nov imenik queryTool z zadnjo verzijo Laravel-a in login
ekranom, ki deluje preko Google prijave.
```

Po nekaj iteracijah prejmemo zadnje sporočilo Clauda:

Končano. V `/var/www/queryTool` stoji nov projekt z **Laravel 13.18.1** (zadnja verzija) in delujočo Google prijavo.

Kaj je narejeno

Ogrodje

- Svež `laravel/laravel` (v13.18.1), nameščen `laravel/socialite` za OAuth.
- Baza SQLite, migracije pognane.

Google prijava

- GoogleAuthController.php — `redirect`, `callback` (poišče/ustvari uporabnika po `google_id`), `logout`.
- routes/web.php — `/login`, `/auth/google/redirect`, `/auth/google/callback`, `/logout`, zaščiten `/dashboard`.
- config/services.php — Google blok.
- Migracija users: dodan `google_id` (unique), `avatar`, `password` je zdaj nullable.
- User.php — `google_id`, `avatar` v fillable.
- login.blade.php — prijavni zaslon z Google gumbom + dashboard.blade.php.
- `.env` / `.env.example` — `GOOGLE_CLIENT_ID`, `GOOGLE_CLIENT_SECRET`, `GOOGLE_REDIRECT_URI`.

Preverjeno (dev strežnik)

- `/` → 302 na `/login` ✓
- `/login` izriše zaslon z gumbom ✓
- `/dashboard` brez prijave → 302 na `/login` (auth middleware) ✓
- `/auth/google/redirect` → 302 na `accounts.google.com` ✓

Kar moraš še narediti sam

Vpiši **Google OAuth gesla** v `.env` (`GOOGLE_CLIENT_ID` + `GOOGLE_CLIENT_SECRET` iz Google Cloud Console → Credentials, redirect URI `http://localhost/auth/google/callback`), nato `php artisan config:clear`. Postopek po korakih je v README.md.

Opomba: imenik je last `claude_` [redacted]. Za serviranje prek `www-data` (nginx/apache) bo morda treba prilagoditi lastništvo `storage/` in `bootstrap/cache/`.

Slika 2: Končno sporočilo priprave spletnega okolja

Pri poskusu odpiranja strani dobimo napako, ker prezremo opombo, Claude pa težavo uspešno odpravi.

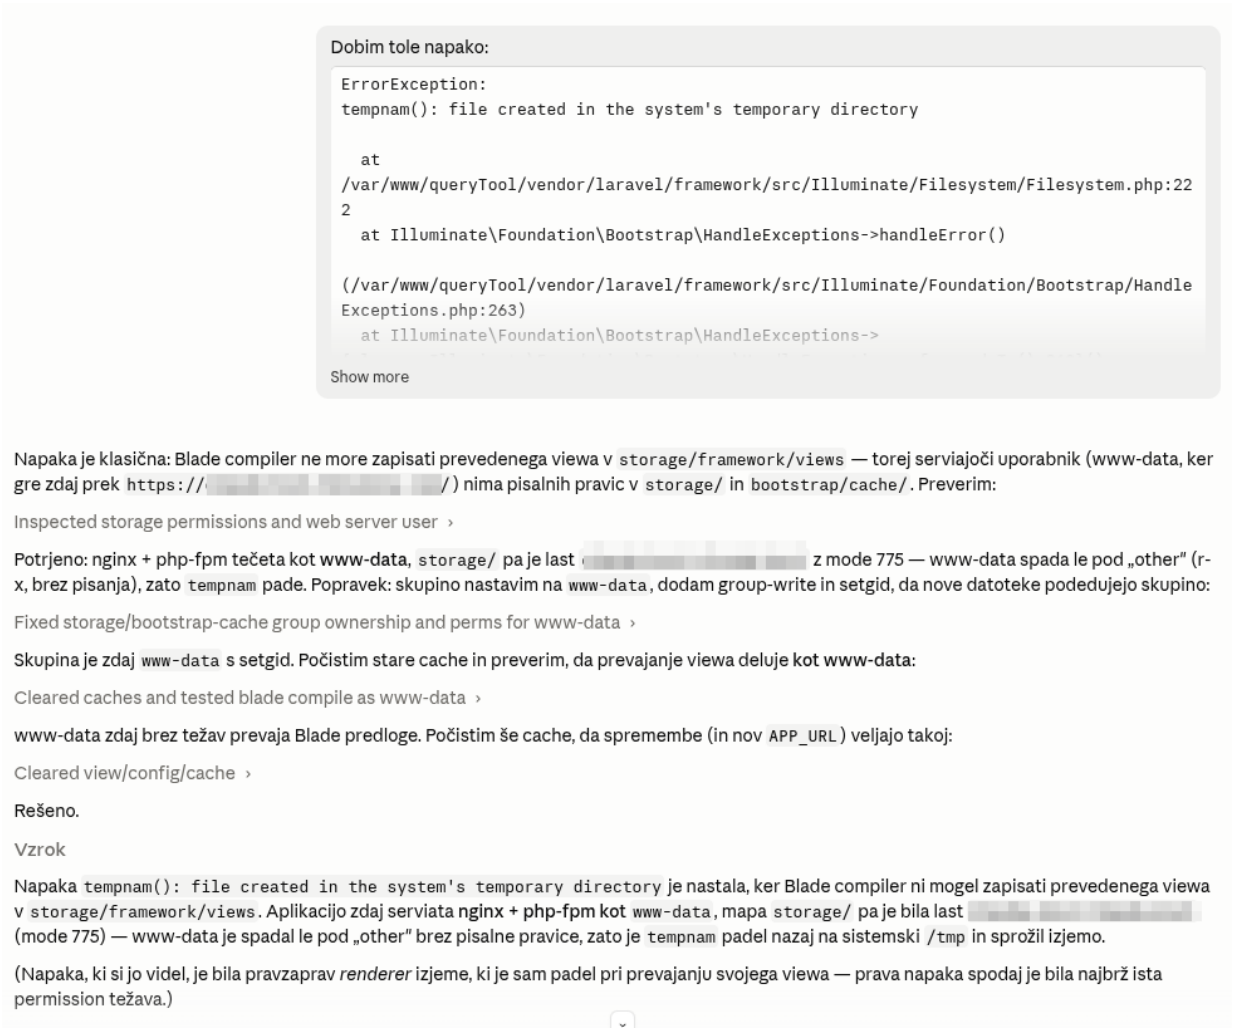

Slika 3: Prva napaka in rešitev

Spletno stran ponovno preizkusimo in dobimo naslednjo podobno napako, ki jo Claude prav tako odpravi.

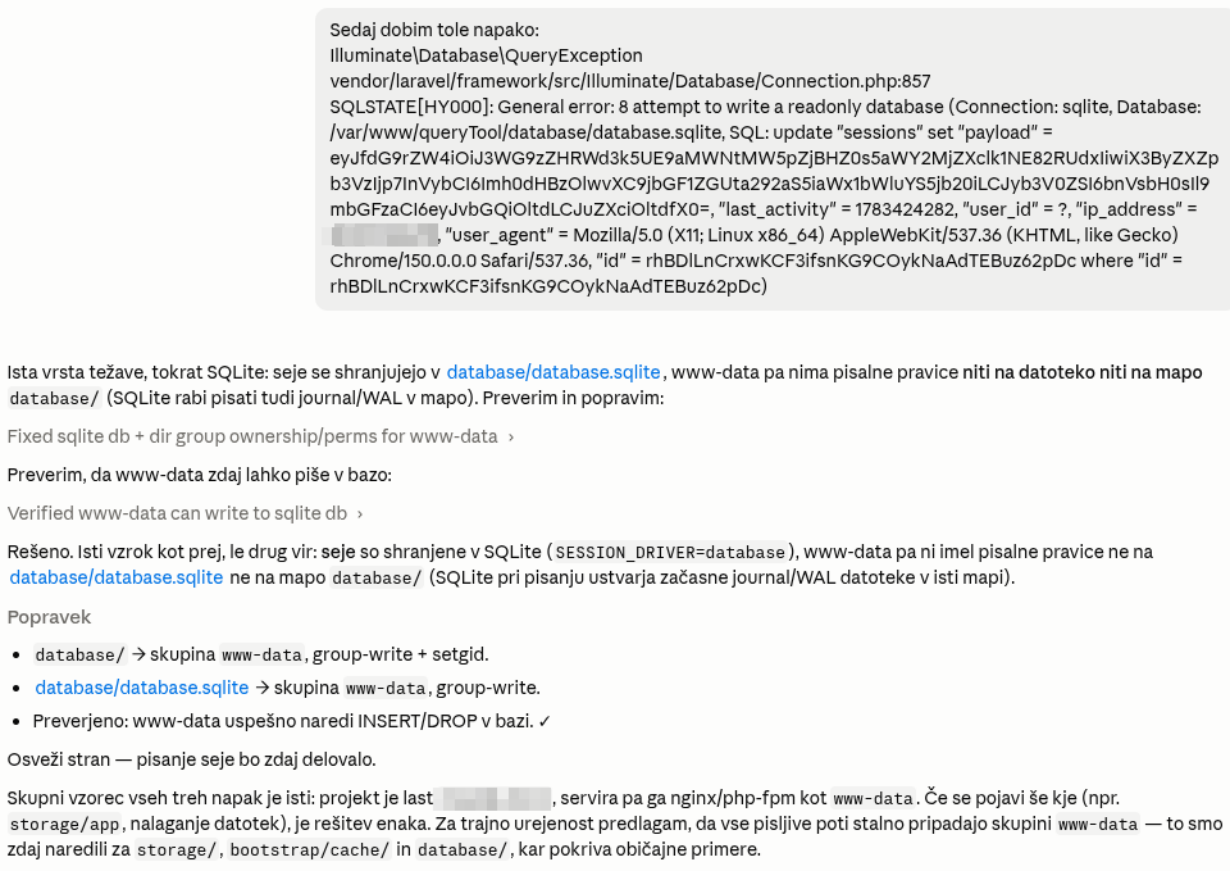

Slika 4: Druga napaka in rešitev

S to rešitvijo nas pričaka spletna stran.

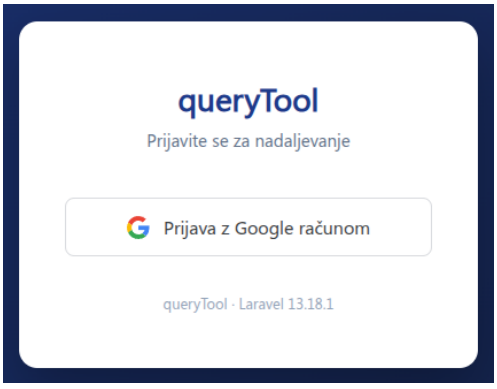

Slika 5: Prijavno okno

Ko po Claudovih navodilih pridobimo Google Client ID in skrivnost:

```
Nastavil sem GOOGLE_CLIENT_ID in GOOGLE_CLIENT_SECRET spremenljivke in ko se
prijavim dobim 404. Naredi en welcome screen, dodaj tudi Odjavi gumb
```

Prijava in odjava delujeta:

Slika 6: Po prijavi

```
Vzpostavi dostop do baze in kreiraj stran za izvajanje poizvedb, samo SELECT-ov.
```

Gotovo. Povzetek.

Dostop do baze — vzpostavljen in preverjen

- `ibm_db2` je bil že nameščen (v2.3.1) — nič za namestit.
- DB2 okolje za php-fpm je pripravljeno prek systemd drop-ina `db2.conf` (`clear_env=no`). Tekoči master ga ni imel → naredil `daemon-reload` + restart php-fpm.
- Potrjeno skozi fpm socket: `DB2INSTANCE=db2inst1` prisoten, `db2_connect` doseže strežnik `127.0.0.1:50000` (gonilnik + mreža delujeta). Web pot ima poln DB2 dostop.

Stran za poizvedbe (samo SELECT)

- `/query` (za prijavljene) — query.blade.php: textarea, tabela rezultatov, čas izvedbe, opozorilo o skrajšanju.
- QueryController.php + poti v web.php.
- Db2Connection.php — native `ibm_db2`, DSN-less, autocommit OFF (nič se ne zapiše), meja `DB2_MAX_ROWS` (1000).
- SelectOnlyValidator.php — dovoli le en `SELECT`/`WITH`/`VALUES`, blokira DML/DDL, stacked queries in DB2 `FINAL/OLD/NEW TABLE(INSERT…)`. Vseh 8 testov gre skozi (vključno robni `created_orders`, ki ni napačno blokiran).
- `php artisan db2:ping` za test povezave.
- Povezava „SQL poizvedbe" dodana na welcome screen in v navigacijo.

Slika 7: Vzpostavitev povezave na IBM Db2 bazo

Kar moraš narediti ti

Vpiši dostop v `.env` (ključi so že pripravljeni, prazni):

```
DB2_DATABASE=LUMINA
DB2_USERNAME=<bazni user>
DB2_PASSWORD=<geslo>
```

Nato:

```
php artisan config:clear
source /home/db2inst1/sqllib/db2profile && php artisan db2:ping
```

`db2:ping` zdaj pravilno javi „ni konfigurirano" (dokaz, da je ožičenje pravilno — poveže se takoj ko vpišeš credentiale).

Varnostno priporočilo: uporabi DB2 uporabnika samo z pravico branja (SELECT). Validator + autocommit OFF sta prva obramba, read-only user pa zanesljiva — poizvedbena stran je javno dostopna vsem, ki se prijavijo prek Googla.

Ko vpišeš credentiale in `db2:ping` uspe, lahko skupaj preverim še dejansko poizvedbo skozi spletni vmesnik.

Slika 8: Dopolnitev poverilnic

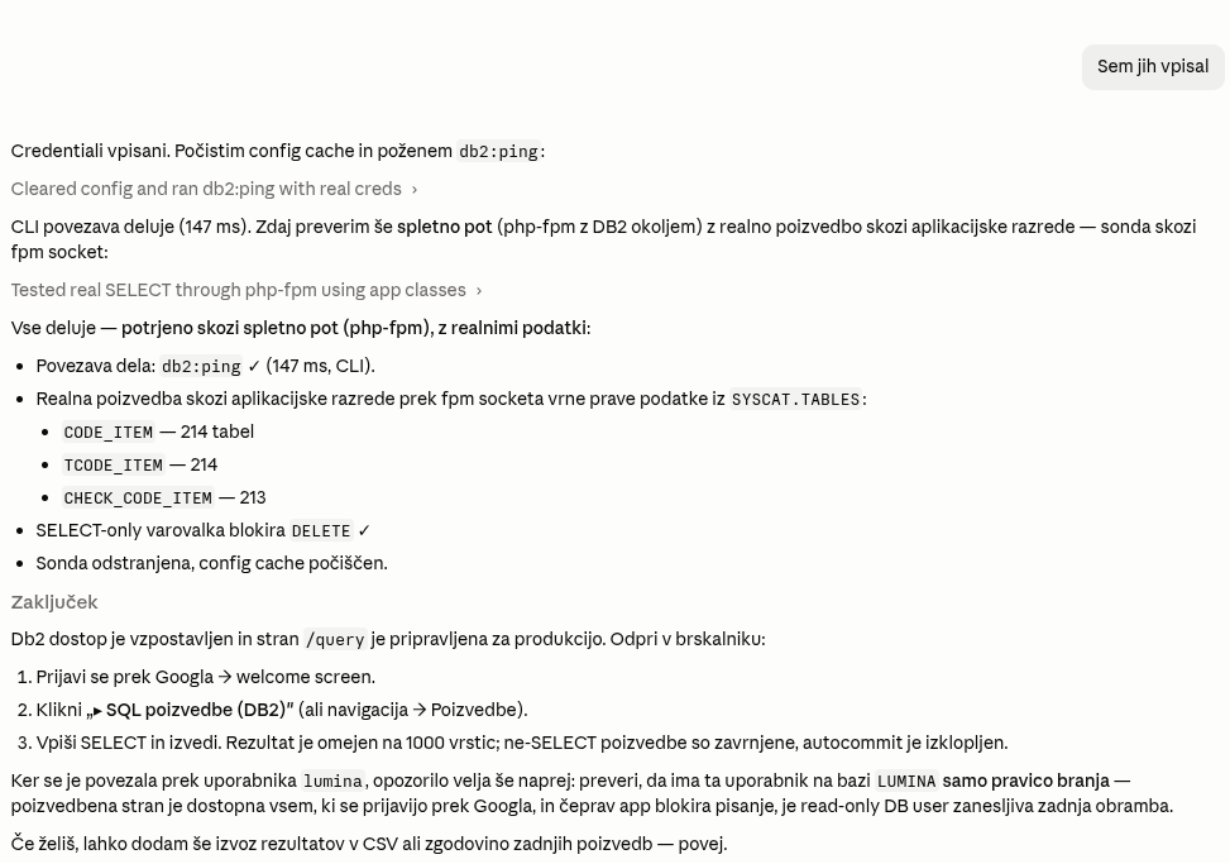

Slika 9: Test povezave na bazo uspešen

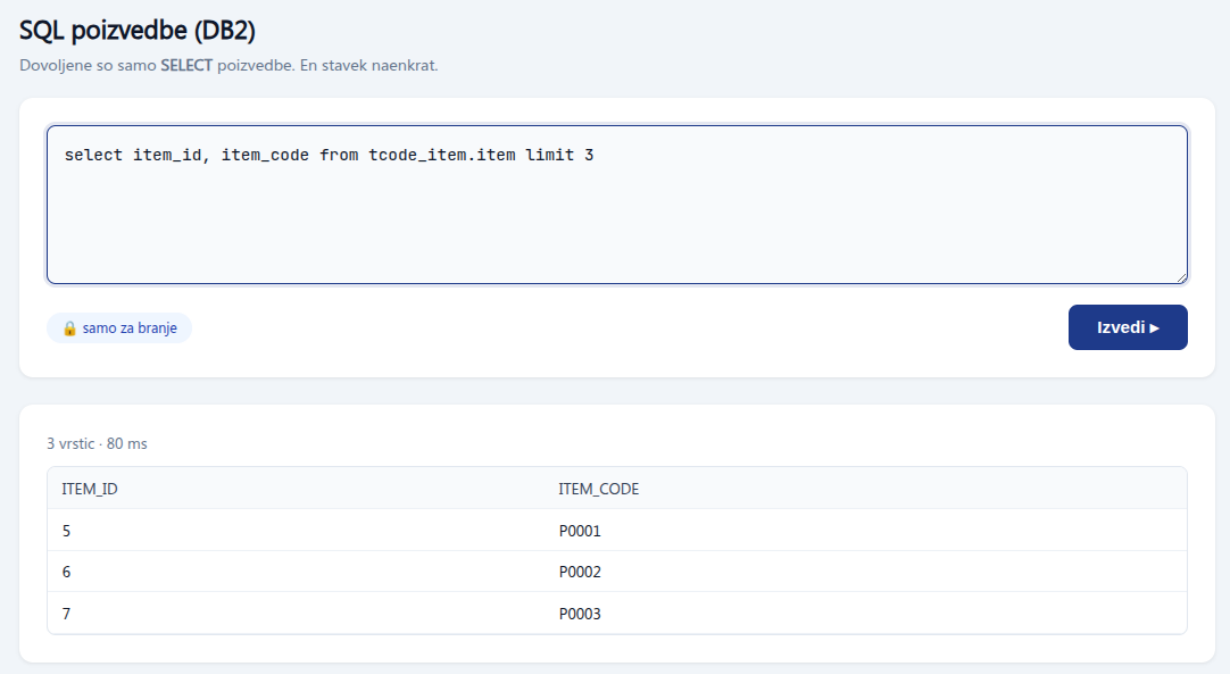

Slika 10: Uspešno izveden SELECT

Zdaj potrebujemo še orodje za analizo SQL stavkov:

```
zdej bomo pa naredil query tool - za delanje sqlov. tabele so v shemi logic in
sicer action , actionquery, actionqueryfield in actionqueryparameter ..
analiziraj te tabele kaj so in kaj vsebinsko in mi potem naredi query tool
```

Po nekaj iteracijah s Claudom:

Vse deluje in je preverjeno. Query tool je narejen.

Analiza tabel (kaj so)

Gre za **metapodatkovni register parametriziranih poizvedb** aplikacijskega ogrodja:

```
LOGIC.ACTION (9.593)  →  LOGIC.ACTIONQUERY (6.831)  →  ACTIONQUERYFIELD (76.505)   [izhodni stolpci]
   akcija                  SQL (CLOB) + :params          ↳ ACTIONQUERYPARAMETER (16.969) [vhodni :parametri]
```

- **ACTIONQUERY.AQUE_SQL** = dejanski SQL z imenskimi parametri (`:GLOS_CODE`), pogosto `WITH UR`; lahko je SELECT ali `CALL proc(...)`.
- **FIELD** = izhodna polja (ime+tip), **PARAMETER** = vhodni parametri (ime+tip), oba se ujemata z SQL-jem.

Orodje (kot si želel: vpišeš SQL → dobiš parametre s tipi + izhodne stolpce s tipi)

Nova stran `/analyze` (analyze.blade.php):

- Vpišeš SQL z `:parametri` → dve tabeli: **Parametri (ime + tip + izvor)** in **Izhodni stolpci (ime + tip)**.
- **Poizvedbe NE izvede** — uporablja DB2 `DESCRIBE` (samo prepare).

Kako pridobi tipe (Db2Describe.php):

- **Izhodni stolpci**: DB2 CLP `DESCRIBE OUTPUT` → točni SQL tipi (`VARCHAR(257)`, `BIGINT`, `DATE`, `CLOB`…). Parser obvlada osnovno in razširjeno (LOB) obliko.
- **Parametri**:
  - `CALL` → tipi iz **signature procedure** (SYSCAT.ROUTINEPARMS), pozicijsko.
  - `SELECT` → tip **primerjanega stolpca** (SYSCAT.COLUMNS, prek FROM/JOIN aliasov); prikaže tudi izvorni stolpec.
  - kjer ni mogoče → `neznano` (jasno označeno).

Preverjeno (skozi php-fpm kot www-data, na realnih podatkih)

- SELECT: `:GLOS_CODE → VARCHAR(257)`, `:LANG_ID → BIGINT`; izhod vklj. `GLOS_DESCRIPTIONLARGE → CLOB` ✓
- CALL `IMPORT.TEMPLATE_ITEM01`: 61 parametrov pravilno preslikanih na proc signaturo ✓
- Robni primeri (CLOB razširjena oblika, več tabel) ✓

Povezave dodane na dashboard in v navigacijo (Domov · Poizvedbe · **Analiza**). Odpri `/analyze` po prijavi in vpiši SQL.

Opomba: `/analyze` bere le metapodatke (DESCRIBE + SYSCAT), ničesar ne izvede in ne piše. Če želiš, lahko dodam še: (a) gumb „naloži iz registra" (izbereš ACTIONQUERY po `ACTI_CODE` in ti napolni SQL), ali (b) primerjavo dobljenih tipov z deklariranimi v `ACTIONQUERYFIELD`/`ACTIONQUERYPARAMETER`.

Slika 11: Implementacija QueryTool-a

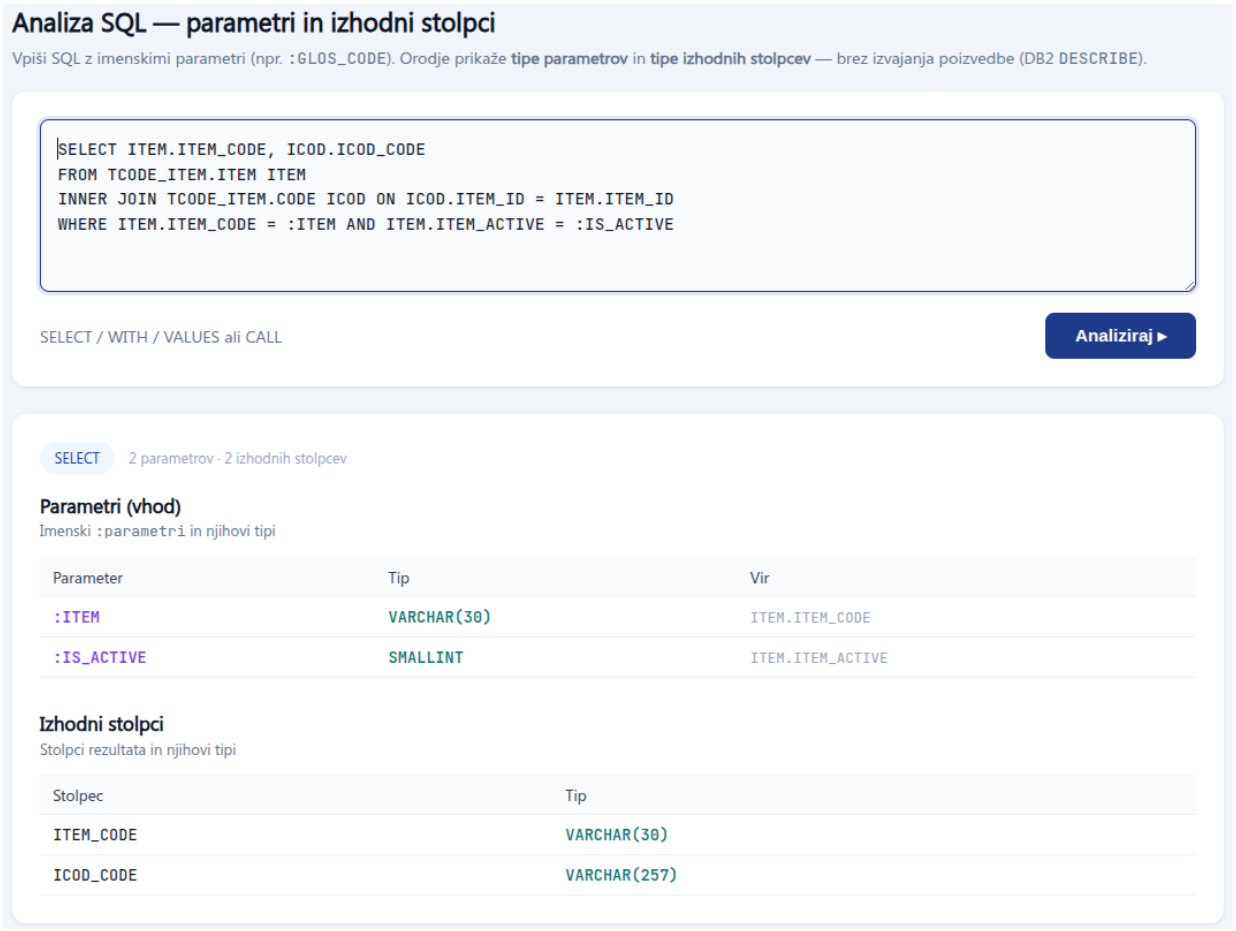

Slika 12: Test SELECT-a

Preizkus procedure (CALL TEREN.OTS_2026(:NORDE_ID)) vrne seznam vhodnih parametrov, ne pa tudi informacij o vrnjenih podatkih (lahko je en nabor rezultatov, lahko jih je več), kar povemo tudi Claudu; rešitev najde, ko mu pokažemo še vzorec, po katerem so napisane naše procedure.

Poglej kako je narejena procedura WD_FORM.SET_DOCUMENT in poglej kateri sql je v katerem result setu. Podobno so narejeno tudi druge naše procedure.

Preberem celo telo `WD_FORM.SET_DOCUMENT` in izluščim: katere `WITH RETURN` kurzorje ima, na kateri STATEMENT je vsak vezan, in od kod (SET/PREPARE) dobi SQL. Tako razberem vzorec:

Created a file, ran a command ›

`SET XSQL = 'SELECT...'` — pri tej proceduri je SQL literal (ne kot pri TEMPLATE_ITEM01). To je ključno. Izvlečem celoten XSQL (od `SET XSQL` do `PREPARE`) in preverim pravo dolžino telesa:

Extracted full XSQL construction in SET_DOCUMENT ›

Zdaj razumem vzorec. `WD_FORM.SET_DOCUMENT` (telo 6789 znakov):

```
SET XSQL = 'SELECT … FROM … WITH UR';   ← cel SELECT je LITERAL string
PREPARE XSQLSTATE_3 FROM XSQL;          ← pripravi iz spremenljivke XSQL
DECLARE XRESULT_SET_3 CURSOR WITH RETURN TO CLIENT FOR XSQLSTATE_3;  ← 1 result set
```

Ključno: SQL je statično v telesu, le da gre prek `SET XSQL = 'literal'` → `PREPARE … FROM XSQL` (spremenljivka), ne neposredno iz literala. Moja koda je iskala le literal neposredno v PREPARE — zato ni ujela tega vzorca. To je popravljivo (sledim spremenljivki do njenega SET).

Najprej konkretno odgovorim: opišem ta SELECT (result set #1):

Described SET_DOCUMENT result set SELECT ›

Popolno — result set #1 (`XRESULT_SET_3`) vrne 14 stolpcev z natančnimi tipi (`VARCHAR(30)`, `TIMESTAMP`, `BIGINT`...).

Zdaj razumem vaš splošni vzorec: `SET XSQL = 'literal SELECT'` → `PREPARE stmt FROM XSQL` → `DECLARE cursor WITH RETURN FOR stmt`. Nadgradim orodje, da sledi spremenljivki do SET literala in prikaže stolpce po posameznem result-setu. To pokrije SET_DOCUMENT in podobne procedure.

Najprej prenovim CALL logiko v `Db2Describe` (result-seti namesto enega seznama):

Edited Db2Describe.php +21 -15 ›

Zdaj zamenjam `procedureResultColumns` z `procedureResultSets`, ki sledi vzorcu `SET var = 'literal'` → `PREPARE` → kurzor:

Edited Db2Describe.php +91 -42 ›

Zdaj testiram na `SET_DOCUMENT` (1 result set) in `GET_ACTIONSAVE` (5 result setov) prek CLI:

Tested result set extraction on SET_DOCUMENT and GET_ACTIONSAVE ›

SET_DOCUMENT: 1 result set, 14 stolpcev ✓. Ampak dva buga vidim: (1) pri GET_ACTIONSAVE regex prekomerno požre in najde le 1,3,5 namesto vseh 5 kurzorjev; (2) enkratni dinamični result set (npr. TEMPLATE_ITEM01) zdaj ne pade več na register (regresija). Popravim oboje — regex z offset-om in dopolnitev iz registra za enkratni dinamični result set:

Edited a file, ran a command ›

Odlično, oba buga popravljena:

- SET_DOCUMENT: 1 result set, 14 stolpcev (iz telesa) ✓
- GET_ACTIONSAVE: vseh 5 result setov najdenih (dinamični → poštene opombe) ✓
- TEMPLATE_ITEM01: 1 result set, 154 stolpcev — izkazalo se je, da tudi ta uporablja `SET XSQL = 'literal'` (moja prejšnja ocena „dinamičen" je bila napačna; zdaj ga orodje pravilno prebere iz telesa).

Zdaj posodobim UI, da prikaže stolpce po posameznem result-setu (in pripadajoči SELECT). Prenovim izhodni del `analyze.blade.php`:

Slika 13: Popravki za procedure

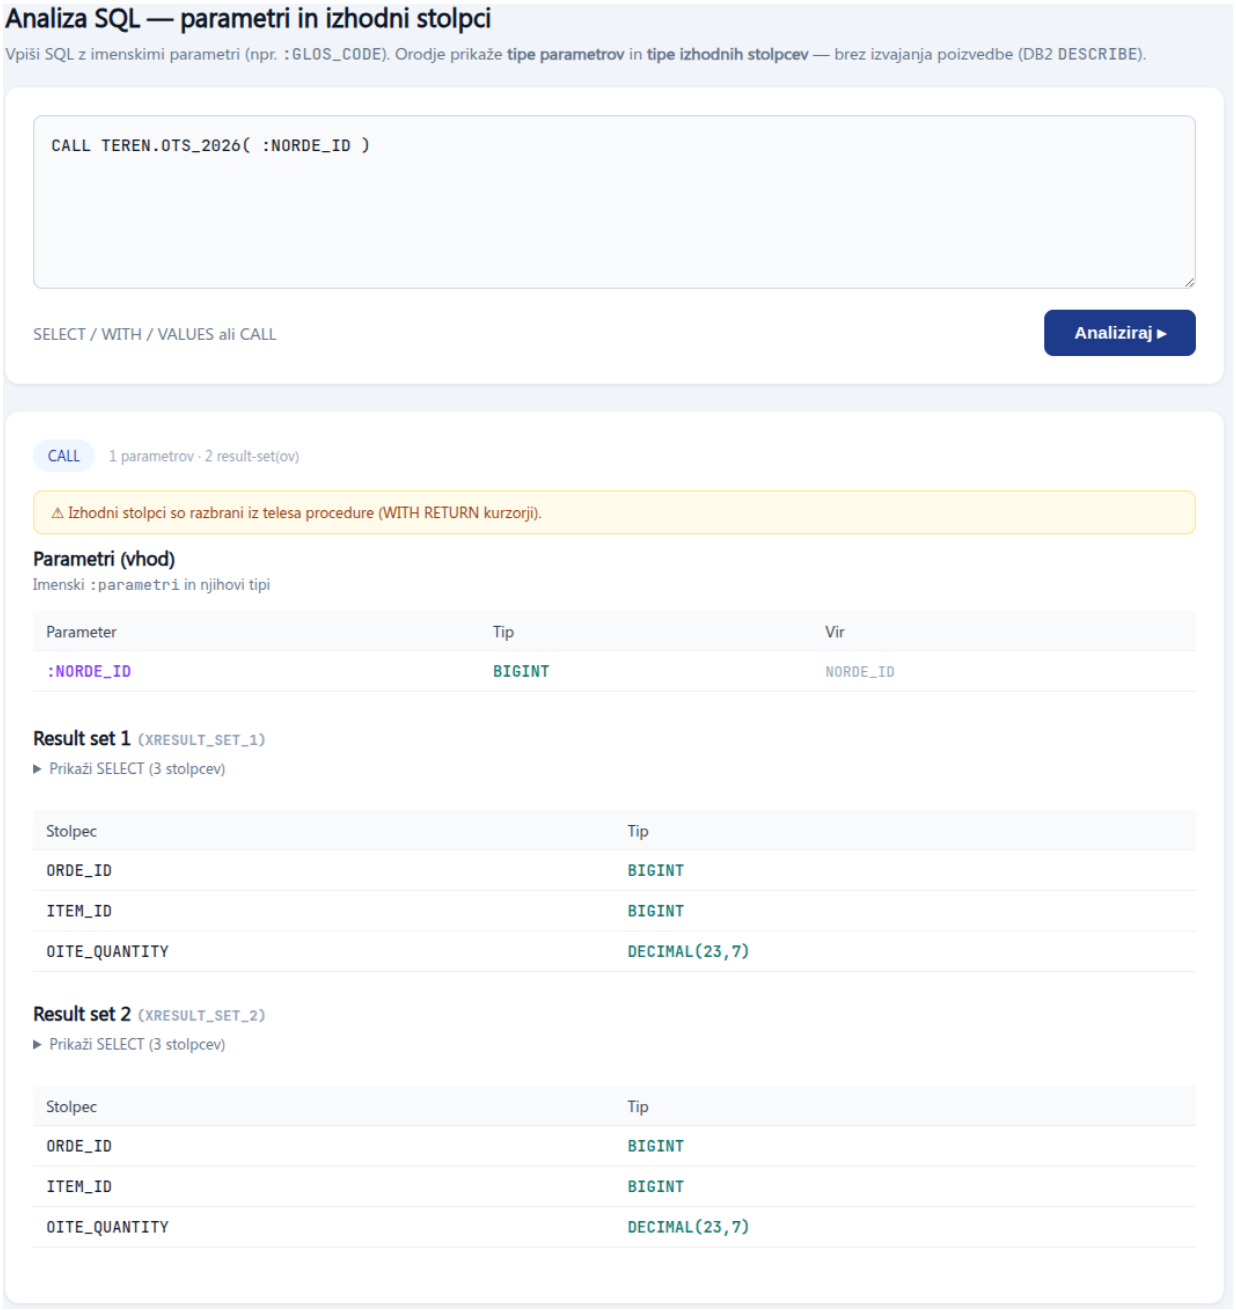

Slika 14: Test procedure

2.4. Naslednji koraki

S pomočjo umetne inteligence smo v kratkem času (približno mesec dni) na ogrodje Laravel prenesli še nekaj drugih internih orodij, kot so Linea, monitoring baz in helpdesk.

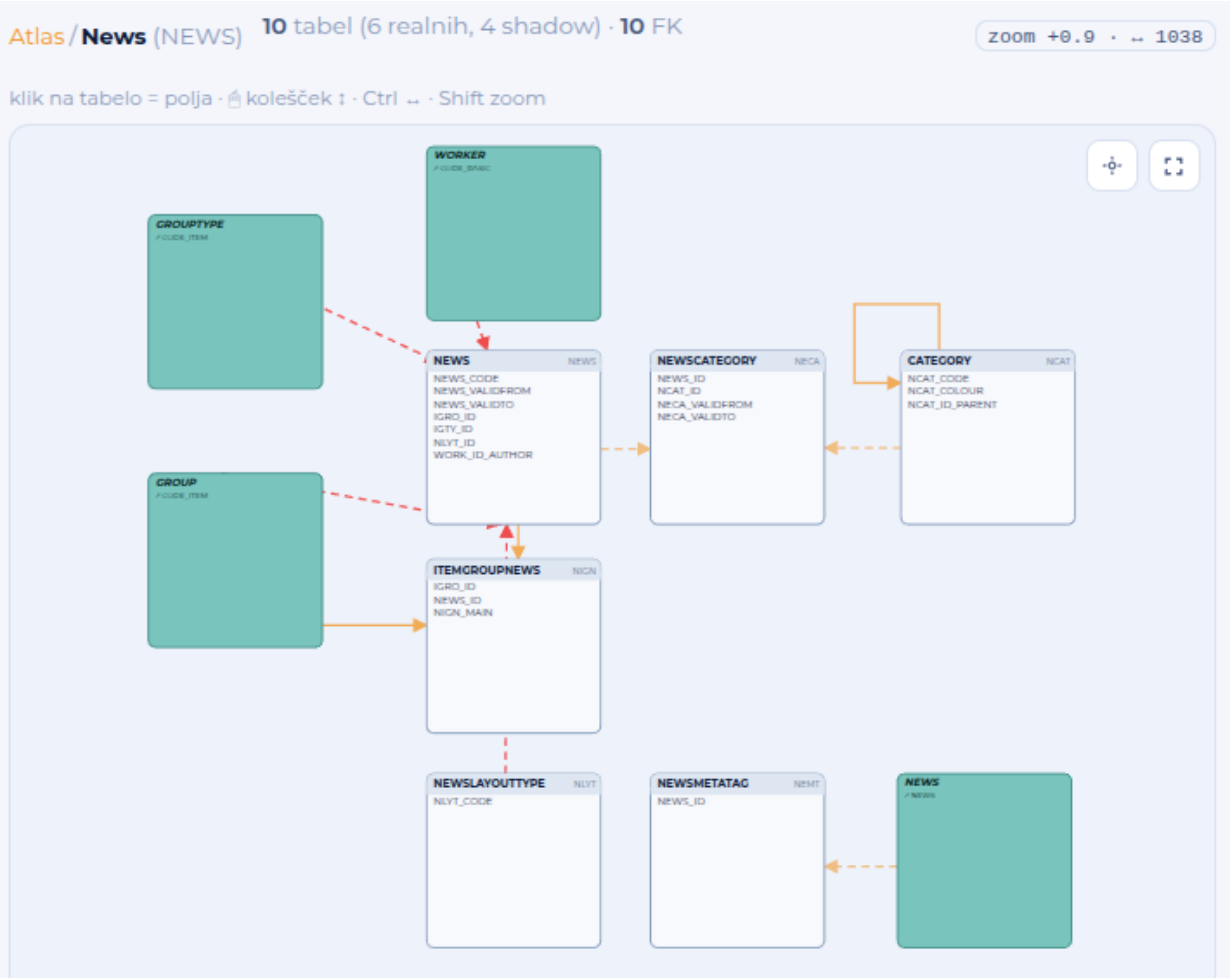

Slika 15: »Nova« Linea

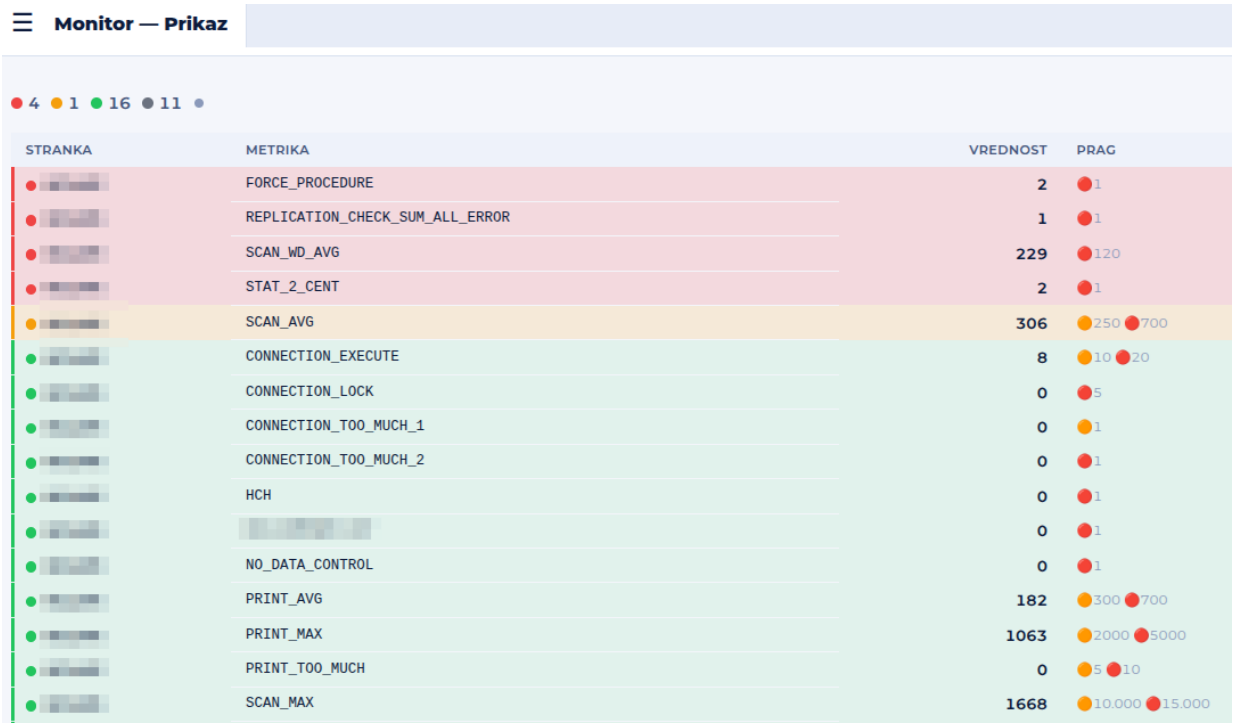

Slika 16: Spremljanje podatkovne baze

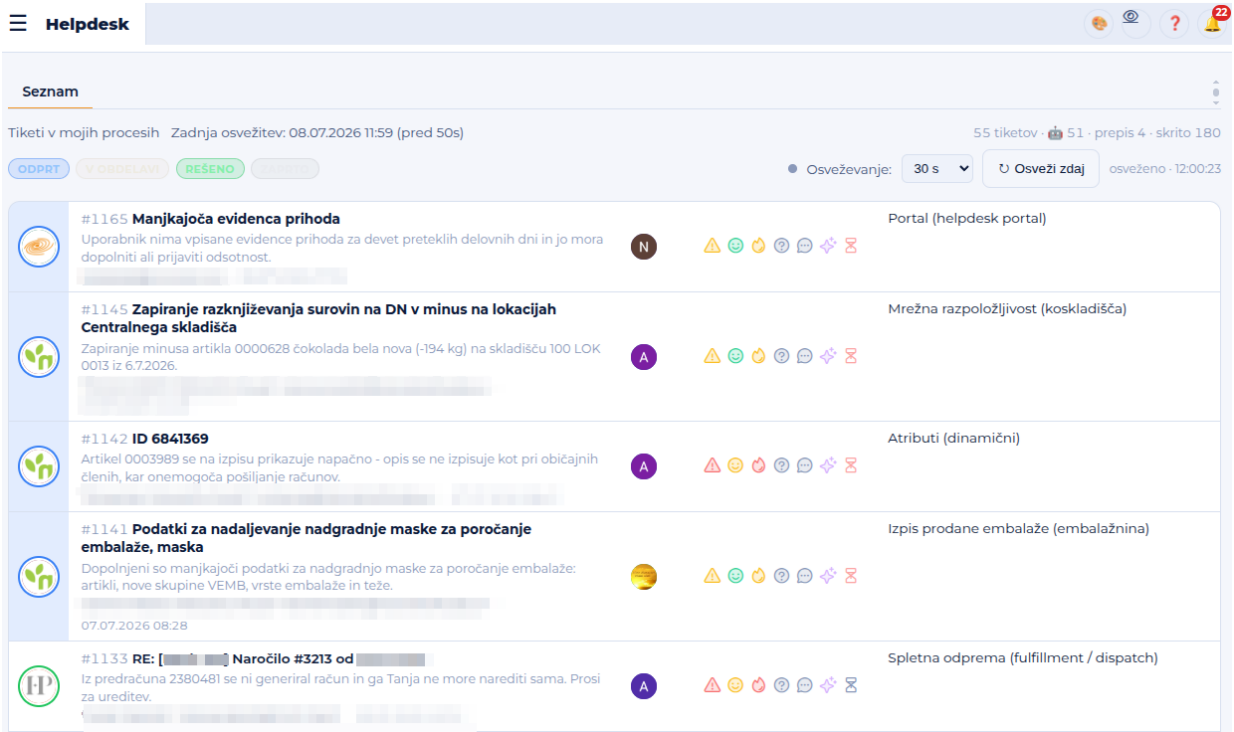

Slika 17: Helpdesk

Pri helpdesku rešitev bere elektronska sporočila, določi, v kateri poslovni proces sodijo, odpre zahtevek za ustrezno osebo, med prejšnjimi rešitvami poišče najustreznejšo ter predlaga odgovor stranki. Pri razvoju sistema za pomoč uporabnikom (helpdesk) smo ugotovili, da potrebuje jasno strukturiran spomin – zbirko rešitev, primerov odgovorov na elektronska sporočila in podobnih smernic. Šele v takšnih jasno začrtanih okvirov deluje zanesljivo; brez njih namreč začne odgovore preprosto ustvarjati sama.

Umetna inteligenca nam je z uporabo orodja Ansible pomagala zgraditi tudi rešitev za samodejno postavitev strežnikov različnih tipov (bazni, aplikacijski, spletni) ter njihovo nastavitev (dostopi do baz, nameščanje aplikacij na aplikacijske strežnike itd.)).

3 Širši pogled: zmožnosti in meje umetne inteligence pri razvoju

Naši izkušnji nista osamljeni. Postavljamo ju v širši okvir razprave o vlogi umetne inteligence pri razvoju programske opreme, in sicer z dveh zornih kotov: inženirskega (kaj orodja danes zmorejo in česa ne) in etičnega (kako naj to tehnologijo odgovorno uporabljamo).

3.1. Inženirski pogled: kje pomaga in kje ne

Koristno izhodišče je razumevanje razvoja programske opreme kot sklopa treh plasti: odločanja (kaj zgraditi), izvedbe (kako to zapisati v kodo) in dostave (kako to preoblikovati v zanesljivo delujoč izdelek). Umetna inteligenca najizraziteje pospešuje srednjo, izvedbeno plast, medtem ko se odločanje in dostava avtomatizaciji izmikata [2]. To pojasnjuje, zakaj kljub hitremu napredku zmogljivosti ni prišlo do napovedanih množičnih odpuščanj razvijalcev; številni odmevni primeri, ki so jih mediji pripisali umetni inteligenci, so bili v resnici posledica drugih dejavnikov, predvsem finančnih pritiskov [2]. V nekaterih primerih [12] so podjetja celo znova zaposlila inženirje, saj kakovost rešitev, ki jih je zagotavljala umetna inteligenca, ni dosegala zahtevanih standardov. Enako se je pokazalo v obeh naših primerih: umetna inteligenca je bila najbolj koristna pri izvedbi, torej pri pisanju kode, medtem ko smo odločitve o zasnovi in merila za sprejemljivost rezultata obdržali v lastnih rokah.

Zmogljivosti teh orodij ob tem hitro naraščajo. Podjetje Anthropic poroča, da razvoj umetne inteligence vse bolj poganja umetna inteligenca sama; njihovi inženirji danes v povprečju oddajo približno osemkrat več kode na četrtletje kot v obdobju 2021–2025, v skrajni obliki pa se tak trend približuje t. i. rekurzivnemu samoizboljševanju [9]. Prav zato postajajo veščine, ki niso neposredno pisanje kode – razumevanje pravega problema, zasnova rešitve, presoja in dostava – za razvijalca še pomembnejše, ne manj [10].

Ena pomembnejših praktičnih omejitev je t. i. razpadanje konteksta (context rot): kakovost odgovorov modela tiho upada, ko se kontekstno okno polni, saj je pozornost modela omejen vir, ki se z več žetoni razprši [3]. Napaka se ne pokaže kot izjema ali na nadzornih ploščah, temveč kot postopno izgubljanje natančnosti.

Zavedati se velja tudi, da konteksti, navodila in datoteke za usmerjanje agentov predstavljajo svojevrstno vrsto tehničnega dolga. Za razliko od kode, ki ostaja stabilna, dokler se je ne dotikamo, lahko vsaka nova različica modela tiho razvrednoti prej skrbno izdelana navodila [4]. Navodila naj zato temeljijo na konkretnih in preverljivih dejstvih o projektu, izogibamo pa se splošnemu »usmerjanju vedenja« modela.

Spodbudna je ugotovitev, da koda, ki je dobro vzdrževana in razumljiva za človeka, hkrati ostaja bolj zanesljiva tudi za urejanje z umetno inteligenco. Raziskava na 5.000 datotekah je pokazala pomembno povezavo med metriko zdravja kode (CodeHealth) in ohranitvijo pomena po preoblikovanju z jezikovnim modelom [5]; organizacije lahko take metrike uporabijo za presojo, kje je poseg umetne inteligence manj tvegan in kje je potreben dodaten človeški nadzor. Hkrati pa agentno programiranje zahteva več, ne manj discipline – več strukture, jasnejša merila kakovosti in nadzorne mehanizme [6].

Nazadnje ne gre prezreti, da jezikovni modeli ostajajo nezanesljivi na načine, ki niso vedno očitni: slabo obvladujejo zanikanja [7], vrhunski modeli pa si pri preverjanju dejstev pogosto nasprotujejo. Za nas to pomeni, da preverjanje rezultatov proti obstoječi, dokazano pravilni implementaciji ni neobvezen dodatek, temveč nujen del postopka.

Ne smemo pa spregledati stroškov umetne inteligence. Vlagatelji si bodo namreč na dolgi rok želeli povrniti stotine milijard dolarjev, ki jih trenutno vlagajo v podjetja, ki (še) ne poslujejo z dobičkom. Stroške lahko znižamo z naslednjimi ukrepi:

- **Uravnavanje vloženega napora (angl. effort)**. Manjši vloženi napor lahko prinese boljše razmerje med kakovostjo in ceno; model Fable 5 pri nastavitvi low doseže boljši rezultat (60 % pri 3,76 USD) kot Opus 4.8 pri nastavitvi max (59 % pri 13 USD) [13],
- **Prilagajanje modela zahtevnosti naloge**. Za vse naloge ni treba uporabljati najzmogljivejšega modela. Fable 5 lahko uporabimo za arhitekturo in načrtovanje, samo izvedbo pa glede na njeno zahtevnost prepustimo cenejšim modelom (Opus, Sonnet ali celo kateremu od modelov GPT),
- **Zmanjševanje porabe žetonov (angl. tokens)**. Z uporabo namenskih veščin (angl. skills) za zmanjšanje porabe žetonov, kot sta Ponytail [14] in Caveman [15], dosežemo enak rezultat ob manjši porabi.

3.2. Etični pogled: enciklika Magnifica Humanitas

Razprava o umetni inteligenci ni le tehnična, temveč tudi etična. Dober okvir ponuja prva enciklika papeža Leona XIV. z naslovom Magnifica Humanitas: o varovanju človekove osebe v času umetne inteligence, objavljena 25. maja 2026 ob 135-letnici enciklike Rerum Novarum [8]. Enciklika tehnologije ne obravnava kot sovražne ali same po sebi zlonamerne, opozarja pa, da »tehnologija nikoli ni nevtralna, saj prevzame značilnosti tistih, ki jo zasnujejo, financirajo, urejajo in uporabljajo«. Poziva, naj umetna inteligenca služi človeku in skupnemu dobremu ter naj ne koncentrira moči; med drugim izpostavlja dostojanstvo dela in poziv, naj »ostanemo človeški« [8].

Za razvijalce iz tega sledi konkretna drža. Umetna inteligenca naj bo orodje, ki razvojno ekipo razbremeni rutinskih opravil in ji omogoči osredotočenost na zahtevnejše, ustvarjalne naloge – ne pa nadomestek za človeško presojo in odgovornost. Ta drža se ujema z našo osrednjo ugotovitvijo: pri obeh primerih je vodilno vlogo – odločanje, presojo in končno odgovornost za rezultat – ohranil razvijalec.

Ta drža postaja še pomembnejša, ker razvoj umetne inteligence vse bolj poganja umetna inteligenca sama, s čimer se povečuje tudi tveganje izgube človeškega nadzora [9]. Toliko bolj velja poziv enciklike, naj človek ostane v središču odločanja in odgovornosti.

4 Zaključek in nadaljnji koraki

Naša izkušnja kaže, da je umetna inteligenca lahko resnična pomoč pri razvoju in vzdrževanju internih orodij, če nalogo dobro omejimo, jo razdelimo na preverljive enote in rezultate dosledno preverjamo. Pri implementaciji internih orodij je bila najbolj produktivna pri izvedbi, medtem ko sta zasnova in nadzor ostala v rokah razvijalca.

Ker se je pilotni prepis QueryTool-a izkazal za uspešnega, smo s pomočjo umetne inteligence na podoben način na sodobnejšo tehnološko osnovo prenesli tudi nekatera druga interna orodja. V prihodnje načrtujemo širšo uporabo umetne inteligence, in sicer za samostojno programiranje in podporo ter za njeno vpeljavo, po potrebi tudi za nadzor, neposredno v procese sistema ERP. Prispevek tako predstavlja prvi korak v širšem premisleku o tem, kako naj se uveljavljene interne razvojne prakse soočijo z orodji, ki postajajo iz dneva v dan zmogljivejša.

Literatura

[1] BIZJAK Tomaž, KOVAČ Gregor, KOZLAR Tomaž: Implementacija prilagodljivega ERP sistema z malo ali nič kode. Sodobne informacijske tehnologije in storitve OTS 2025: Zbornik 28. konference, Maribor, 2025.

[2] NARAYANAN Arvind, KAPOOR Sayash: Why AI hasn't replaced software engineers, and won't. normaltech.ai, 11. 6. 2026.

[3] BHATKOTI Vineet: Understanding Context Rot - Why Your AI Agent Gets Worse the Longer It Works. DZone, 18. 6. 2026.

[4] GOEDECKE Sean: Prompts are technical debt too. seangoedecke.com, 2026.

[5] BORG Markus, HAGATULAH Nadim, TORNHILL Adam, SÖDERBERG Emma: Code for Machines, Not Just Humans: Quantifying AI-Friendliness with Code Health Metrics. arXiv:2601.02200, 2026.

[6] TORNHILL Adam: Agentic AI Coding Practices for Speed with Quality (predstavitev), 2026.

[7] MAYNE Harry, McKINNEY Lev in dr.: Negation Neglect: When models fail to learn negations in training. arXiv:2605.13829, 2026.

[8] LEON XIV.: Magnifica Humanitas - enciklika o varovanju človekove osebe v času umetne inteligence. Vatikan, 15. 5. 2026.

[9] ANTHROPIC INSTITUTE: When AI builds itself. anthropic.com, 2026.

[10] ARJANCODES: AI Writes Code Faster Than You. Now What? (video), 2026.

[11] ANTHROPIC: Models overview. platform.claude.com/docs/en/about-claude/models/overview

[12] BBC: Ford rehires human engineers after AI fails to match quality checks, https://www.bbc.com/news/articles/cgrkd41n2v9o

[13] https://deepswe.datacurve.ai

[14] https://ponytail.dev/

[15] https://caveman.so/