SUSTAV ZA ANALITIČKU OBRADU PODATAKA ZA ISPLATU POTICAJA U POLJOPRIVREDI

Šćepanović, Ivan

Professional thesis / Završni specijalistički

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Economics and Business / Sveučilište u Zagrebu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:148:575183

Rights / Prava: Attribution-NonCommercial-ShareAlike 3.0 Unported / Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0

Download date / Datum preuzimanja: **2024-07-13**

Repository / Repozitorij:

REPEFZG - Digital Repository - Faculty of Economcs & Business Zagreb

Sveučilište u Zagrebu
Ekonomski fakultet
Poslijediplomski specijalistički studij
Informatički menadžment

SUSTAV ZA ANALITIČKU OBRADU PODATAKA ZA ISPLATU POTICAJA U POLJOPRIVREDI

Poslijediplomski specijalistički rad

Ivan Šćepanović

Zagreb, lipanj 2021.

PODACI I INFORMACIJE O STUDENTU POSLIJEDIPLOMSKOG SPECIJALISTIČKOG STUDIJA

Ime i prezime: Ivan Šćepanović

Datum i mjesto rođenja: 9.12.1969., Split

Naziv završenog fakulteta i godina diplomiranja: Agronomski fakultet u Zagrebu, 1998.

PODACI O POSLIJEDIPLOMSKOM SPECIJALISTIČKOM RADU

Vrsta studija: Poslijediplomski specijalistički studij

Naziv studija: Informatički menadžment

Naslov rada: Sustav za analitičku obradu podataka za isplatu poticaja u poljoprivredi

Naslov rada (engleski jezik): Analytical data processing system for the payment of subsidies in agriculture

UDK (popunjava Knjižnica): _____

Fakultet na kojem je rad obranjen: Ekonomski fakultet Sveučilišta u Zagrebu

POVJERENSTVO, OCJENA I OBRANA RADA

Datum prihvaćanja teme: 30.04.2013.

Mentor: Prof. dr. sc. Mirjana Pejić Bach

Povjerenstvo za ocjenu rada:

1. Prof. dr. sc. Katarina Ćurko — Predsjednik povjerenstva
2. Prof. dr. sc. Mirjana Pejić Bach — Član povjerenstva
3. Professor emeritus Velimir Srića — Član povjerenstva

Povjerenstvo za obranu rada:

1. Prof. dr. sc. Katarina Ćurko — Predsjednik povjerenstva
2. Prof. dr. sc. Mirjana Pejić Bach — Član povjerenstva
3. Professor emeritus Velimir Srića — Član povjerenstva

Datum obrane rada: 09.06.2021.

Sveučilište u Zagrebu
Ekonomski fakultet
Poslijediplomski specijalistički studij
Informatički menadžment

SUSTAV ZA ANALITIČKU OBRADU PODATAKA ZA ISPLATU POTICAJA U POLJOPRIVREDI

ANALYTICAL DATA PROCESSING SYSTEM FOR THE PAYMENT OF SUBSIDIES IN AGRICULTURE

Poslijediplomski specijalistički rad

Student: Ivan Šćepanović
Matični broj studenta: PDS-92-2012
Mentor: Prof. dr. sc. Mirjana Pejić Bach

Zagreb, lipanj 2021.

SAŽETAK I KLJUČNE RIJEČI

SAŽETAK: Cilj rada jest pokazati konkretnu primjenu uvođenja sustava za analitičku obradu podataka za isplatu poticaja u poljoprivredi u jednoj javnoj instituciji. Analizom poslovnoga problema, vezano uz izvještajni sustav, pokazala se potreba za uvođenjem novih tehnologija koji će u izvještavanje uvesti sigurnost, stabilnost i točnost. Uvođenjem sustava za analitičku obradu podataka pokazalo se da se automatizirani i centralizirani sustav analitičke obrade podataka svojim karakteristikama (skalabilnost, brzina, stabilnost, točnost, sigurnost) pokazao kao korisno rješenje za generiranje izvještaja nužnih u upravljanju isplatom poticaja u poljoprivredi.
KLJUČNE RIJEČI: rudarenje podataka, poslovna inteligencija, ETL proces, javna institucija, centralni izvještajni sustav, OLAP model

SUMMARY AND KEY WORDS

SUMMARY: The aim of the paper is to demonstrate the concrete benefits of introducing an analytical data processing system for the payment of agricultural subsidies in a public institution. The analysis of the business problem related to the reporting system showed the need to introduce new technologies that bring security, stability and accuracy to reporting. The introduction of the analytical data processing system proved that the automated and centralized analytical data processing system with its features (scalability, speed, stability, accuracy, security) proved to be a useful solution for the creation of reports necessary for the management of payment of subsidies in agriculture.
KEY WORDS: data mining, business intelligence, ETL process, public institution, centralized reporting system, OLAP model

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je poslijediplomski specijalistički rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija.

Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog izvora te da nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

(vlastoručni potpis studenta)

Zagreb, 08.04.2021.

(mjesto i datum)

SADRŽAJ

1. UVOD 1
1.1 PREDMET ISTRAŽIVANJA 2
1.2 CILJEVI ISTRAŽIVANJA 3
1.3 METODE ISTRAŽIVANJA 3
1.4 STRUKTURA RADA 3
2 POSLOVNA INTELIGENCIJA 4
2.1 DEFINIRANJE POJMA POSLOVNE INTELIGENCIJE 4
2.2 KONCEPT I ZNAČAJKE POSLOVNE INTELIGENCIJE 6
2.3 ŽIVOTNI CIKLUS POSLOVNE INTELIGENCIJE 8
2.4 SUSTAV POSLOVNE INTELIGENCIJE 11
2.5 ČIMBENICI USPJEHA UVOĐENJA POSLOVNE INTELIGENCIJE U POSLOVANJU TVRTKE 48
3 PROCES UVOĐENJA SUSTAVA ZA ANALITIČKU OBRADU PODATAKA ZA ISPLATU POTICAJA U POLJOPRIVREDI 52
3.1 PROCESNI PRISTUP ISPLATI POTICAJA U POLJOPRIVREDI 52
3.2 PODRUČJA PRIMJENE SUSTAVA 53
3.3 PROCES RAZVOJA SUSTAVA 55
3.4 UVOĐENJE SUSTAVA U RAD 58
3.5 VREDNOVANJE SUSTAVA 63
3.6 PRIMJERI KORIŠTENJA SUSTAVA 66
4 STUDIJA SLUČAJA UVOĐENJA SUSTAVA ZA ANALITIČKU OBRADU PODATAKA ZA ISPLATU POTICAJA U POLJOPRIVREDI 71
4.1 OPIS INSTITUCIJE I DJELATNOSTI 71
4.2 POSLOVNI PROBLEM OPISAN KROZ CILJEVE PROJEKTA 73
4.3 KARAKTERISTIKE KONKRETNOGA SUSTAVA 77
4.4 OCJENA USPJEŠNOSTI IMPLEMENTIRANOGA SUSTAVA 91
5 ZAKLJUČAK 93

1. UVOD

Česta promjena zakonske regulative unutar nacionalne i zajedničke poljoprivredne politike EU-a utječe na čestu promjenu postojećih i dodavanje novih poslovnih procesa unutar postojećih sustava institucija Republike Hrvatske (RH) koji su nositelji tih poslova. Oni, osim što utječu na promjene informatiziranoga modela sustava, utječu na stalno povećavanje količine podataka. Stalna promjena vezana uz podatke utječe na izvještavanje koje postaje vrlo dinamičan i kompleksan poslovni proces koji zahtijeva punu pozornost poduzeća.
S obzirom na to da govorimo o velikoj količini podataka, cilj je postaviti one modele izvještavanja koje će u što manjoj jedinici vremena i sa što manje ljudi davati brže, ažurnije i točnije izvještaje. Taj će cilj biti dostižan ako se budu koristile nove tehnologije vezane uz poslovno izvještavanje u koje spada i sustav poslovne inteligencije.

Filozofija tržišno orijentiranih firmi kojima je profit na prvome mjestu vodi se idejom da će oni koji najprije iz velike količine podataka predvide buduće događaje,novim proizvodom ili uslugom ostvariti prednost na tržištu i veći profit.
Organizacijama kojima profit nije primarna stvar, već zadovoljavanje određene usluge za određenu skupinu korisnika, kakav je slučaj u Agenciji za plaćanje u poljoprivredi, ribarstvu i ruralnom razvoju (Agencija), tehnologije poslovne inteligencije u velikoj mjeri pojednostavljuju svakodnevni rad tako da im omogućavaju lakše praćenje ključnih faza poslovnoga procesa i bržu izradu izvještaja.

Povezivanjem poslovnih podataka bitnih institucija vezanih uz poljoprivredu RH, Ministarstvo poljoprivrede osiguralo bi da s jednoga centralnog mjesta dohvaća veće kombinacije pogleda na podatke, što sada nije moguće. To bi omogućilo otkrivanje pozitivnih i negativnih trendova odmah čim se dogode, što znači da bi Ministarstvo moglo puno prije znati koliko neki program ili potpora u poljoprivredi stvarno utječu na ostvarivanje ciljeva samih programa i potpora, što znači i znatno ranije korigirati iste ako ne donose željene učinke.

Kroz ovaj rad pokazat ćemo da je segment isplate poticaja u poljoprivredi, iz ukupnoga portfelja poslova Ministarstva poljoprivrede, a za koje je odgovorna Agencija, zakoračio u fazu uspostave svog BI-a i pokazat ćemo kako jedan takav automatizirani i centralizirani izvještajni sustav utječe kako na poslovanje Agencije, tako i na poslovanje Ministarstva poljoprivrede RH.

1.1 PREDMET ISTRAŽIVANJA

Ovaj rad bavi se problematikom i programskim rješenjima koja se odnose na količinu raznovrsnih podataka i kako se primjenom novih tehnologija može:

- ubrzati proces dohvata podataka
- povećati broj pogleda na podatke
- olakšati izrada izvještaja koji služe svim razinama operativnoga i menadžerskoga upravljanja u jednoj organizaciji.

Neke od činjenica vezanih uz podatke koje sustav izvještavanja i analitičke obrade čine kompleksnim, a kojih smo u Agenciji itekako svjesni jesu sljedeće:

- velika količina podataka koje sustav prikuplja i raznim obradama dodatno stvara
- unutar samoga sustava stvaraju se ili postoje podsustavi sa svojim podatcima koji nisu dio jedinstvenoga integracijskog sustava, ali su bitni za poslovni proces
- ostale srodne ili nesrodne institucije isporučuju ostale potrebne podatke glavnom sustavu koji sudjeluje u kreiranju konačnoga poslovnog rezultata
- nerijetka promjena poslovnih procesa uvjetuje čestu promjenu podataka koji su različiti za drugu poslovnu godinu
- naslijeđeni sustavi otežavaju proces uvođenja sustava poslovne inteligencije.

Predmet našega istraživanja bilo je kako osigurati:

- kvalitetno operativno i analitičko izvještavanje koje prati segmente poslovnoga procesa
- buduće projekcije koje poslovni proces nudi
- kvalitetno izvještavanje o krajnjim rezultatima samoga poslovnog procesa
- pokušati prepoznati, a zatim i povezati podatke srodnih sustava pri čemu će se moći donositi zaključci i kreirati informacije koje uslijed velike količine podataka zbog kompleksnosti sustava na „prvu“ nisu uočljivi.

U implementaciju rješenja sustava poslovne inteligencije krenuli smo zbog velike količine podataka koje prikupljamo kroz svoje sustave, zbog kompleksnosti procesa, kao i zbog problema upravljanja i izvještavanja s tim podatcima, kao što su nedostupnost informacija, nepovjerenje u podatke, netransparentnost tokova podataka i odgovornosti za podatke, nemjerljivost procesa, pristup povjerljivim informacijama bez nadzora i izazovi IT-a vezano uz zahtjeve za pravovremenu isporuku izvještaja. Na kraju projekta, željeni rezultati bili su: centralizirano upravljanje izvještavanjem, dostupnost informacija, jedna verzija istine, konsolidacija izvještajnih procesa radi povećanja kvalitete informacija, mogućnost mjerenja učinkovitosti procesa, ograničenje pristupa povjerljivim podatcima te smanjenje opterećenja na IT.

1.2 CILJEVI ISTRAŽIVANJA

Iz navedenoga predmeta proizlaze sljedeći ciljevi ovoga specijalističkog poslijediplomskog rada:

1. korištenjem sekundarnih izvora literature analizirat će se proces uvođenja sustava za analitičku obradu podataka, pri čemu će se istražiti najbolja praksa u ovom području
2. izradom studije slučaja prikazat će se konkretna primjena uvođenja sustava za analitičku obradu podataka za isplatu poticaja u poljoprivredi u Agenciji, gdje će se analizirati prednosti i nedostatci konkretnoga rješenja kroz ocjenu uspješnosti studije slučaja.

1.3 METODE ISTRAŽIVANJA

Stručnom i znanstvenom literaturom koristit ćemo se za teorijsko istraživanje koje obuhvaća predmet i ciljeve istraživanja, tj. područje sustava za analitičku obradu podataka. Za potrebe izrade praktičnoga dijela koristit će se iskustva i spoznaje stečene kroz studiju slučaja Agencije prilikom uspostave sustava za analitičku obradu podataka za isplatu poticaja u poljoprivredi. Na temelju tih spoznaja doći ćemo (metodom deduktivnoga zaključivanja) do saznanja potvrde ili odbacivanja prethodnih teorijskih postavki.

1.4 STRUKTURA RADA

Rad ima pet međusobno povezanih dijelova. U uvodu će se definirati predmet istraživanja, problem istraživanja, pojasnit će se svrha i cilj istraživanja, kao i korištene metode istraživanja. Drugi dio nosi naziv „Poslovna inteligencija“. U tom dijelu pojasnit će se pojam, koncept i ostale značajke poslovne inteligencije. Proces uvođenja sustava za analitičku obradu podataka za isplatu poticaja u poljoprivredi predstavlja treći dio rada. U tom dijelu pojasnit će se proces isplate poticaja u poljoprivredi. Pokazat ćemo za koji smo dio toga procesa uveli sustav, pojasnit ćemo model uvođenja sustava za analitičku obradu podataka i pokazati na primjerima kako se sustav koristi. Četvrti dio rada jest studija slučaja uvođenja sustava za analitičku obradu podataka za isplatu poticaja u poljoprivredi. Ovaj dio dokazat će potrebu tih sustava i nužnost njihova korištenja. Definirat ćemo poslovni problem opisan kroz ciljeve projekta, a zatim ćemo opisati instituciju i djelatnosti kojima se ona bavi. Na kraju ćemo ocijeniti uspješnost implementiranoga sustava za analitičku obradu podataka za isplatu poticaja u poljoprivredi. Zadnji, peti dio, jest zaključak u kojem će se iznijeti spoznaje koje proizlaze iz ovoga rada.

2 POSLOVNA INTELIGENCIJA

2.1 DEFINIRANJE POJMA POSLOVNE INTELIGENCIJE

Moderna poslovna inteligencija razvijena je u 17. stoljeću, kada su razvojem međunarodne trgovine otkriveni novi teritoriji i morski putovi. Da bi došli do potrebnih informacija, mnogi su pomorski osiguravatelji počeli posjećivati tada popularnu krčmu koju je u Londonu držao stanoviti Edward Lloyd. Bilo je to mjesto gdje su novi poduzetnici mogli međusobno i s pomorcima razmjenjivati i dijeliti informacije, stečena iskustva i spoznaje. Danas možemo ustvrditi: bilo je to mjesto gdje je stvorena prva osiguravajuća kompanija, koju je osnovalo 79 poduzetnika, prvih dioničara kompanije Lloyd's. Isto tako, možemo reći da je to bilo mjesto gdje je rođena poslovna inteligencija, koju je stvorila masa znanih i neznanih poduzetnika, pomoraca i pijanaca[1].

U samoj srži poslovne inteligencije leži osnovna paradigma poslovne inteligencije, a to je sposobnost prikupljanja informacija prije drugih i djelovanje na temelju dobivenih informacija, u čemu je bankar sir Henry Furness zablistao već šezdesetih godina 19. stoljeća i na tom konceptu ostvario veliku poslovnu dobit. Zaključujemo da su prije informatizacijske ere tvrtke podatke prikupljale iz neautomatiziranih izvora. Poslovne odluke donosile su se na temelju procjena temeljenih na osjećaju, intuiciji, prethodnom iskustvu, savjetu i sl. U to vrijeme tvrtke nisu posjedovale tehnologiju koja bi osigurala kvalitetnu analizu podataka, međutim, i danas, unatoč velikom napretku tehnologije i alata koji pomažu u donošenju odluka, još uvijek previše ljudi i dalje donosi odluke na starinski način, što često dovodi do odluka loših za poslovanje tvrtke.

Poslovna inteligencija razvila se iz sustava za podršku odlučivanju koji se koristio u američkim poduzećima šezdesetih godina 20. stoljeća.[2] Howard Dresdner iz Gartner Grupe predložio je 1989. godine po prvi put pojam "Business Intelligence" (BI). Dresdner opisuje BI kao skup metoda u svrhu poboljšanja poslovnoga odlučivanja utemeljenoga na činjenicama tj. podatcima.

Što je poslovna inteligencija? Postoji puno definicija i opisa što poslovna inteligencija jest ili bi trebala biti. Razlog tome je što ona zahtijeva poznavanje i objedinjavanje stručnih znanja iz širokoga spektra poslovnih područja: informatike, matematike, statistike, ekonomije.

Osnovna definicija govori da je BI pojam koji objedinjuje teorije, metodologije, računalne procese, arhitekture i tehnologije za prepoznavanje, prikupljanje, pohranu i analizu poslovnih podataka tvrtke ili organizacije (poput prodaje, proizvoda, troškova i prihoda) te pretvaranja u informacije i znanje kojima se koristimo u procesima donošenja odluka i rješavanja problema.

---

[1] Panian, Ž., Klepac, G. (2003). Poslovna Inteligencija. Zagreb: Masmedia.
[2] https://hr.wikipedia.org/wiki/Poslovna_inteligencija, 23.4.2019.

Gartner IT Glossary[3] - Poslovna inteligencija (BI) krovni je pojam koji uključuje aplikacije, infrastrukturu i alate te najbolje prakse koje omogućavaju pristup informacijama i njihovu analizu radi poboljšanja i optimizacije poslovnih odluka i performanci.

Kako bismo definirali poslovnu inteligenciju, možemo se koristiti njezinim mikro i makroaspektom.

Panian i Klepac[4] opisuju poslovnu inteligenciju s makroaspekta:

„Razmatrana s makroaspekta, poslovna inteligencija je složena, agregirana kategorija koja se stvara sustavnim, ali unaprijed naciljanim prikupljanjem podataka o makroekonomskim kretanjima u određenoj geopolitičkoj sredini, njihovim organiziranim i strukturiranim bilježenjem odnosno pohranjivanjem, pretraživanjem te logičkom i računalnom obradom poradi otkrivanja makroekonomskih trendova ili tendencija te predviđanja i prognoziranja procesa i događaja u makroekonomskim sustavima i njihovih budućih stanja."

Neke od definicija poslovne inteligencije promatrane s mikroaspekta jesu sljedeće:

Rud, Olivia[5] - „Poslovna inteligencija (BI) je transformacija sirovih podataka u smislene i korisne informacije za potrebe poslovne analize. Poslovna inteligencija (BI) može manipulirati ogromne količine nestrukturiranih podataka kako bi pomogao identificirati, razvijati i na drugi način stvarati nove strateške poslovne mogućnosti. Poslovna inteligencija (BI) omogućuje jednostavno tumačenje količine podataka. Identificiranje novih mogućnosti i provedba učinkovite strategije može dati konkurentnu prednost na tržištu i dugoročnu stabilnost."

Liautaud, Bernard opisuje značenje pojma inteligencije unutar organizacije i, između ostaloga, kaže[6] je da je inteligencija izvedena iz informacija poduzeća i stoga pridonosi stvaranju kolektivne inteligencije poduzeća kao vrlo moćne snage.

Međutim, pregledom i sumiranjem različitih definicija, poslovnu inteligenciju možemo opisati kao sustav koji je sastavljen od nekoliko usko povezanih aktivnosti, metodologija i platformi za: skladištenje podataka (Data Warehousing (DW)), analitičku obradu podataka u stvarnom vremenu (On-line Analytical Processing (OLAP)), rudarenje podataka (Data Mining (DM)), vizualizaciju podataka, sve u svrhu boljeg razumijevanja što se trenutno događa, ali i u svrhu predviđanja što bi se moglo iduće dogoditi u društvu, na tržištu ili u samoj tvrtki.

---

[3] https://www.gartner.com/it-glossary/business-intelligence-bi/ 3.7.2019.
[4] Panian, Ž., Klepac, G. (2003). Poslovna Inteligencija. Zagreb: Masmedia.
[5] Rud, Olivia (2009). Business Intelligence Success Factors: Tools for Aligning Your Business in the Global Economy. Hoboken, N.J: Wiley & Sons
[6] Liautaud, B. (2001). E-Business Intelligence: Turning Information into Knowledge into Profit. McGraw-Hill, New York

2.2 KONCEPT I ZNAČAJKE POSLOVNE INTELIGENCIJE

Šezdesetih godina prošloga stoljeće pojavila su se velika i moćna računala kojima se mogla prikupiti velika količina podataka. Osamdesetih godina dogodio se razvitak relacijskih baza podataka što je osiguralo da se velika količina podataka mogla bolje organizirati i strukturirati a samim time i lakše dohvaćati za korištenje. Devedesetih godina dogodio se razvoj klijentsko - poslužiteljske arhitekture, što je otvorilo put dohvata podataka iz relacijskih baza svim poslovnim korisnicima poduzeća. Ta su tehnološka rješenja osigurala da se počne razmišljati o sustavima za podršku odlučivanju koja su se zatim tijekom vremena razvila u koncept poslovne inteligencije.

Razvoj koncepta poslovne inteligencije pratimo kroz razvoj rješenja analitičkih aplikacija:

- analitičke aplikacije – namijenjene poslovnim područjima financijskoga upravljanja, npr. analizi klijenata, analizi prodaje – pokrivale su samo dio potreba cjelokupnoga poduzeća
- specijalizirane analitičke aplikacije – različiti odjeli skladište svaki svoje podatke, pri čemu nisu osiguravali razmjenu podataka s ostalim poslovnim vertikalama tvrtke.
- Međutim, uvidjelo se da kompanije trebaju rješenja za puno šire probleme poduzeća – bila su potrebna rješenja koje su se odnosila i na samu strategiju kompanije. Posljedica te ideje jest nastajanje tzv. sveobuhvatne analitičke aplikacije koja se jednoobrazno koristila posvuda u poduzeću. Ključne značajke sveobuhvatne analitičke aplikacije bile su:
    - umjesto oslanjanja na intuiciju, prilikom donošenja odluka sveobuhvatne analitičke aplikacije omogućuju da analiza postane sastavnim dijelom automatiziranih poslovnih procesa na osnovu kojih će se donositi poslovne odluke
    - rezultirale su jednom istinitom verzijom vezano uz izvještavanje iz sustava.

Taj koncept doveo je do sad već tradicionalnoga koncepta poslovne inteligencije (Slika 1.)

Slika 1. Tradicionalni koncept poslovne inteligencije[7]

Vidimo da je u početku opći cilj većine sustava poslovne inteligencije bio pristupiti podatcima iz različitih izvora, zatim transformirati te podatke u informacije i nakon toga u znanje. Zadnja faza

[7] Michalewicz, Z., Schmidt, M., Michalewicz, M., Chiriac, C., (2006). Adaptive Business Intelligence. Springer

koncepta bila je preko jednostavnoga grafičkog sučelja prikazati dobiveno znanje, čime je poboljšana sposobnost krajnjega korisnika za donošenje dobrih odluka. Budući da je znanje bitna komponenta svakoga procesa donošenja odluka (kao što kaže stara izreka: "Znanje je snaga!"[8]), mnoga su poduzeća znanje smatrala konačnim ciljem.

No činilo se da znanje više nije bilo dovoljno pa je temeljni koncept prešao jednu svoju razvojnu fazu i razvio se korak dalje u „Adaptive Business Intelligence“ (Slika 2.).

Slika 2. Koncept „Adaptive Business Intelligence“[9]

Rezultat je bilo poznavanje sklonosti kupaca, a tvrtka je mogla imati stotine grafikona koji organiziraju kupce prema dobi, sklonostima, zemljopisnom položaju i povijesti prodaje, ali uprava još uvijek nije mogla biti sigurna koju odluku donijeti. U tome leži razlika između „podrške odlučivanju“ i „donošenja odluka“ jer sve znanje na svijetu neće jamčiti ispravnu ili najbolju odluku. Veće znanje samo povećava naše samopouzdanje, ali ne poboljšava točnost naših odluka. Sadašnjost i budućnost poslovne inteligencije leži u sustavima koji mogu donositi odluke što znači da mogu pružiti odgovore i preporuke, umjesto velike količine znanja u obliku izvještaja. Kao rezultat toga, na tržištu se pojavio trenutno važeći koncept poslovne inteligencije koji nazivamo „Adaptive Business Intelligence“. On uz obavljanje uloge tradicionalne poslovne inteligencije (pretvaranje podataka u znanje), uključuje i postupak donošenja odluka koji se temelji na predviđanju i optimizaciji što predstavlja korak dalje u evoluciji s tradicionalnoga koncepta poslovne inteligencije.

Kada govorimo o poslovnom odlučivanju unutar neke kompanije razlikujemo, prema Panianu i Klepcu[10], tri razine odlučivanja, tj. strategije unutar kompanije: korporacijsku, poslovnu i funkcionalnu strategiju. Funkcionalna strategija dohvaća podatke iz poduzeća, poslovna strategija koristi se informacijama iz užeg okruženja (konkurencija) dok se korporacijska strategija koristi

[8] Michalewicz, Z., Schmidt, M., Michalewicz, M., Chiriac, C., (2006). Adaptive Business Intelligence. Springer
[9] Michalewicz, Z., Schmidt, M., Michalewicz, M., Chiriac, C., (2006). Adaptive Business Intelligence. Springer
[10] Panian, Ž., Klepac, G. (2003). Poslovna Inteligencija. Zagreb: Masmedia.

globalnim svjetskim podatcima. Znači, tvrtka koja na tržištu želi biti konkurentna treba poznavati i razumjeti unutarnja zbivanja u firmi, događaje iz užega okruženja kompanije, kao i globalne svjetske podatke.

Koncept poslovne inteligencije upravo to i omogućava. Na primjer, iako vam je pozornost na podatcima iz okoline jer pripadate višem menadžmentu, vrlo lako ostajete upućeni u sva zbivanja koja se događaju u unutrašnjosti kompanije koja vam možda trenutno i nisu primarna.

2.3 ŽIVOTNI CIKLUS POSLOVNE INTELIGENCIJE

Mehmet T. Oguz, glavni savjetnik u kompaniji DCS Solutions rekao je[11]: „Pri implementacijama poslovne inteligencije, tvrtka koja pokreće projekt mora u njemu biti duboko involvirana. Razlog tome je činjenica da poslovna inteligencija nije samo tehnička komponenta već poslovno rješenje koje iziskuje aktivno uključivanje poslovnih korisnika u njegov dizajn, razvoj, testiranje, implementaciju, održavanje i rast. Isporučitelj tehnologije odgovoran je da tehnologija funkcionira na željeni način. Integratori su odgovorni za prijenos znanja. A kompanija sama odgovorna je za korektnu primjenu stručnih znanja iz područja poslovanja kojim se bavi u sustav poslovne inteligencije. Konačni uspjeh implementacije ovisi o angažmanu i suradnji svih triju strana.“

Upravo zbog toga što poslovna inteligencija nije samo tehnička komponenta već i poslovno rješenje, sam životni ciklus poslovne inteligencije promatramo upravo na ta dva načina: kao cjelokupno poslovno rješenje kroz niz tehničkih komponenti (aplikativnih i infrastrukturnih).

Prema Panian i suradnici[12], životni ciklus kvalitetnoga sustava poslovne inteligencije objedinjuje četiri osnovne faze: fazu mjerenja, analize, planiranja i fazu dodavanja vrijednosti (Slika 3.)

Slika 3. Životni ciklus sustava poslovne inteligencije (skica autora)

[11] Panian, Ž., Klepac, G. (2003). Poslovna Inteligencija. Zagreb: Masmedia

[12] Panian, Ž., i suradnici. (2007). Poslovna inteligencija – studije slučajeva iz Hrvatske prakse. Zagreb: Narodne novine d.d.

1. *Faza mjerenja*

U životnom ciklusu poslovne inteligencije faza mjerenja najdugotrajnija je faza. Fazom mjerenja zapravo mjerimo uspješnost poslovanja na temelju svojih ključnih pokazatelja - prodaje ili profita, gdje na temelju tih pokazatelja uspoređujemo razliku između dobivenih i očekivanih vrijednosti. Koristeći se sustavima poslovne inteligencije, osim glavnih pokazatelja uspješnosti poslovanja (profit), tvrtka kombinirajući razne podatke dolazi i do drugačijih pokazatelja uspješnosti, skrivenih u dubljim slojevima analiza, npr. koliko je utjecaj popusta (akcija) utjecao na trend povećanja prodaje proizvoda, je li povećana reklama u nekom razdoblju dovela do povećanja potražnje za našim proizvodom ili uslugom. Upotrebom sustava poslovne inteligencije vidimo da se povećava broj novih pokazatelja koji nam segmentiraju prodaju i utvrđuju koji je od tih segmenata prodaje bilo uspješniji od drugih. Ovi nam pokazatelji zapravo daju odgovore na pitanja: Napreduje li naše poslovanje? Jesmo li u uzlaznom trendu? Je li stanje našega poslovanja dobro ili loše? U Agenciji, a time i u državi, pokazatelji uzlaznih trendova jesu npr. jesmo li poticaje isplatili ranije nego prošle godine, je li isplaćeno više ili manje novaca u odnosu na prošlu godinu, koliko je povećanje ugovorenih sredstava za mjere ruralnog razvoja itd.

2. *Faza analize*

U ovoj fazi pokušat ćemo odgovoriti na pitanja: Zašto je nešto takvo kakvo jest? i Zašto se to što se dogodilo, dogodilo na takav način? Tim pristupom otkrit ćemo razloge zašto se stvari događaju na način kako smo to utvrdili u prvoj fazi. Analizirajući podatke na takav način dobit ćemo skriveno znanje koje će nam omogućiti da svjesnije odaberemo neku buduću poslovnu akciju koja će nam poboljšati poslovanje, odnosno svjesno ćemo napustiti neke poslovne akcije s čijim rezultatima nismo bili zadovoljni. Također možemo i ostati na nekim akcijama uz dodatne preinake do kojih smo došli upravo na temelju ove analitičke faze na našim podatcima. Alati koji nam omogućuju takve postupke jesu OLAP alati i alati za *ad hoc* upite.

3. *Faza planiranja*

Podloga za ovu fazu jesu podatci koje smo prikupili u prethodnim fazama. Glavno pitanje ove faze jest: „Što će se dogoditi s našim poslovanjem ako se odlučimo za ovaj korak?“ U ovoj fazi glavni cilj bio bi prepoznati one scenarije koji će uz najmanje rizika odvesti poslovanje tvrtke u najpovoljnijem smjeru. Softver koji se koristi u ovoj životnoj fazi sustava poslovne inteligencije jest softver namijenjen podršci planiranja, budžetiranja i prognoziranja. Tim alatima pokušat će se simulirati različiti scenariji s ciljem predviđanja budućih ishoda na temelju kojih bi se utvrdilo je li to željeni smjer u kojem tvrtka želi ići. Primjeri tih scenarija bili bi npr. hoće li se povećanjem

cijene nekog proizvoda tj. kolikim će se povećanjem cijene nekoga proizvoda dogoditi pad u količini prodaje tog proizvoda. Zatim otkriti hoće li npr. uslijed povećanja cijene nekog proizvoda količina zarađenoga novca ostati ista, povećati se ili pasti. Kod svih ovih scenarija čimbenik uspješnosti postavljenoga cilja koji je proizašao iz nekoga scenarija uvijek nosi određeni rizik. Međutim, vrijednost alata poslovne inteligencije ogleda se upravo u tome da se stalnim ažuriranjem podataka u sustave tvrtke i stalnim praćenjem prodaje loše posljedice nekoga scenarija mogu na vrijeme otkriti, pri čemu tvrtka reagira odmah i to promjenom smjera scenarija i raznim modifikacijama što uvelike smanjuje rizik poslovanja.

Faza dodavanja vrijednosti

Ako pristup povrata ulaganja primijenimo na poslovnu inteligenciju, predstavljat će veliki izazov, ističe Vinod Badami. Badami tvrdi[13] da poslovnu inteligenciju moramo razmotriti i u smislu vrijednosti i utjecaja koji može stvoriti povećanjem operativne djelotvornosti, omogućavanjem boljega razumijevanja ponašanja klijenata i identificiranja novih mogućnosti ostvarivanja prihoda. Faza dodavanja vrijednosti najvažnija je faza životnoga ciklusa poslovne inteligencije. Na temelju svih informacija dobivenih iz prethodnih faza, u ovoj fazi donose se odluke jer se odgovara na pitanje kako primijeniti znanja dobivena iz prethodnih faza. U ovoj će fazi ključne osobe u organizaciji i stručnjaci raspravljati s ciljem odabiranja budućih akcija kojima će se djelovati na segmente poslovanja koja su odabrana s ciljem poboljšanja. Softveri poslovne inteligencije, upravo stoga što je potreba za suradnjom ključnih osoba ključan preduvjet uspješnosti poslovne inteligencije, podržavaju u sebi funkcionalnosti za kolaboraciju između menadžera, stručnjaka, analitičara, klijenata. To znači da će se svaki dokument, mišljenje, komentar, anketa ili prijedlog moći uzeti u obzir prilikom donošenja konačne odluke. U ovoj fazi otkrit će se nove metrike uspješnosti, nove dimenzije i atributi koji predstavljaju novu vrijednost sustava poslovne inteligencije. S tim novim vrijednostima započet ćemo njezin novi životni ciklus.

Možemo zaključiti da je životni ciklus poslovne inteligencije jedan kontinuiran proces, unutar kojeg se teži neprestanom dodavanju nove vrijednosti s ciljem unaprjeđenja poslovanja tvrtke. Dostići perfekciju jedan je utopistički cilj, međutim sam proces BI sustava trenutno je poslovna perfekcija jer nam osigurava neprestano prepoznavanje nužnosti promjene nas samih uslijed promjena na tržištu. Biti u sustavu poslovne inteligencije bitno je jer nam sustav ne dozvoljava da živimo u pogrešnom izboru dulje vrijeme jer stalna ažuriranja BI sustava pravim podatcima iz poduzeća i iz njegove okoline to osigurava.

[13] Panian, Ž., i suradnici. (2007). Poslovna inteligencija – studije slučajeva iz Hrvatske prakse. Zagreb: Narodne novine d.d.

2.4 SUSTAV POSLOVNE INTELIGENCIJE

Iz tehnološke perspektive, poslovna inteligencija kompleksan je sustav koji obuhvaća niz komponenata, a to su: skladište podataka (eng. Data Warehouse) – DW, analitička obrada podataka (eng. Online Analytical Processing) – OLAP, ekstrahiranje, transport i čišćenje podataka (eng. Extract, Transform and Load) – ETL i rudarenje podataka (eng. Data Mining) i ostale aplikacije i metodologije. Prvotni je cilj prepoznati izvore naših podataka. U drugoj fazi podatci se čitaju, transformiraju i učitavaju u skladište podataka. Nakon toga podatci se modeliraju i transformiraju u informaciju koristeći OLAP analitičke upite. Na kraju se te informacije „rudare“ (analiziraju) i vizualiziraju korisniku kroz razne alate.

Važnost podataka za sustav poslovne inteligencije

Koncept poslovne inteligencije temeljen je na podatcima. Srića, V.,[14] pojašnjava važnost podatka za poslovno odlučivanje kada kaže da su menadžeri svakodnevno okruženi brojnim podatcima, informacijama, znanjem i mudrošću. Pojašnjava razliku između tih pojmova, a kada pojašnjava njihovu hijerarhijsku povezanost kaže da prikupljanjem podataka i njihovom analizom dolazimo do informacija čijom sintezom otkrivamo znanja koja se tijekom dužega razdoblja korištenja akumuliraju u mudrost. Ističe da je znanje moguće predati inteligentnim strojevima, no mudrost ostaje u posjedu čovjeka. Također tvrdi da se podatci sastoje od činjenica, brojki ili pojmova, te da informacija nastaje kao rezultat obrade tih podataka i da svojstvo koje ima uklanja neizvjesnost i pomaže u odlučivanju. Znanje je kao rezultat sinteze raspoloživih informacija proizvod pojedinca, skupina ili čitavih kultura, a postaje mudrost kada se dovede u vezu s moralnim sudovima, iskustvom i stručnim saznanjima. Zaključuje da se znanje, između ostalih izvora: knjiga, časopisa, mrežnih stranicama itd., nalazi i u bazama podataka.

Panian Ž., Ćurko K., i dr.,[15] kažu da su poslovni podatci koje poduzeća prikupljaju heterogeni te ističu da postoje vanjski i unutarnji izvori takvih podataka. Vanjski izvori podataka dolaze s tržišta na kojima tvrtka djeluje pa govorimo o tržišnoj inteligenciji, dok unutarnji izvori podataka nastaju kao posljedica poslovnih procesa tvrtke pa govorimo o unutarnjoj inteligenciji tvrtke. Glavni izvori podataka za tržišnu inteligenciju jesu klijenti tvrtke, konkurencija tvrtke i poslovni partneri tvrtke u vrijednosnom lancu pa govorimo o klijentskoj, kompetitivnoj i inteligenciji poslovnoga lanca. Izvori podataka za unutarnju inteligenciju tvrtke dolaze iz operativnih i upravljačkih poslovnih procesa pa govorimo o inteligenciji poslovnih procesa i inteligenciji menadžmenta. Konačno, ako

[14] Srića, V. (2004). Inventivni menadžer u 100 lekcija, 2. izdanje. Zagreb, Delfin; Znanje
[15] Panian, Ž., Ćurko, K., i dr. (2010). Poslovni informacijski sustavi. Zagreb. Element

uzmemo u obzir sve navedeno, možemo ustvrditi da ukupnu poslovnu inteligenciju tvrtke čine izvori podataka unutar klijentske, kompetitivne, inteligencije opskrbnoga lanca i unutarnje inteligencije tvrtke. Omjer vanjskih izvora podataka i unutarnjih ovisi o razini odlučivanja. Ako je razina odlučivanja viša, udio vanjskih podataka je veći[16]. Podatke prema strukturi dijelimo na nestrukturirane, strukturirane i polustrukturirane podatke. Budućnost pripada nestrukturiranim i polustrukturiranim podatcima jer se u njima nalaze vrijedne poslovne spoznaje koje u tim oblicima kolaju internetom. Zbog toga tvrtke i razvijaju sustav poslovne inteligencije u koji uključuju nestrukturirane podatke da bi otkrile njihovu poslovnu vrijednost. Na taj se način događa pretvorba nestrukturirane u strukturiranu informaciju koju smještamo unutar baze podataka.

Važnost baza podataka za sustav poslovne inteligencije

Nepostojanjem koncepta baze podataka, veliku količinu podataka bilo bi vrlo teško skupljati i održavati. S obzirom na to da su baze podataka zbirka određene količine podataka iz određenoga poslovnog područja, idealne su za proizvodnju informacija i znanja. Sustav poslovne inteligencije sa svim metodologijama, tehnologijama i alatima upravo je koncipiran da pomogne te olakša i ubrza ovaj postupak jer se zna da prvi koji dođe do novoga znanja ostvaruje poslovnu prednost i veći profit. Bez baza podataka koje podatke čuvaju u lako upotrebljivom obliku ovaj koncept ne bi bio održiv. On je osnova svih informacijskih tehnologija, npr. kod izvještajnoga sustava i *data mining*a. I u jednom i drugom konceptu podloga je ista, baza podataka, samo su metode kojima se koristimo u analizi različite. Transakcijske (relacijske) baze podataka tvrtke kolektor su svih unutarnjih i vanjskih podataka koje danas ima svaka ozbiljnija tvrtka koja želi uspjeti na tržištu. Bitno je naglasiti da su transakcije zapisane unutar baza podataka poslovni događaji koji su se stvarno i dogodili i kao takvi predstavljaju stvarni uzorak koji se događa na tržištu, koji ne spada u kategoriju „odokativne metode odlučivanja“, stoga takav podatak u sebi ima kvalitetu za točna predviđanja ponašanja kupca, otkrivanje novih trendova i slično. Trenutni izazov nije manjak podataka ili njihova nedostupnost, koliko činjenica da podatke koje imamo ne iskorištavamo optimalno. Tehnologija koja povećava optimalnost iskorištavanja podataka zove se rudarenje podataka (eng. *data mining*). Razvila se iz spoznaje da izvještajni poslovni sustavi nisu dovoljni da prepoznaju skriveno znanje koje se krije unutar raspoložive mase podataka koja se nalazi u transakcijskim bazama podataka. Izvještajni sustavi daju odgovor na pitanja što se, kada, gdje, koliko i kod koga se nešto dogodilo. Koncept rudarenja podataka odgovara na dublja pitanja, npr. Zašto se nešto dogodilo? ili Što bi se moglo dogoditi ako ...? *Data mining* proces ne može se u

[16] Ćurko, K. (2001). Skladište podataka – sustav za potporu odlučivanju. Ekonomski pregled, 52 (7-8) 840-855

cijelosti automatizirati zato što analitičar s jasnim analitičkim ciljem mora razraditi potrebne modele i analize.

Koncept relacijskih baza podataka razlikuje se od koncepta skladišta podataka i po namjeni i po funkciji. Možemo reći da je koncept skladišta podataka nastao kao nadogradnja koncepta relacijske baze podataka čiji je cilj što brže pokupiti i spremiti što više podataka na jedan optimiziran i strukturirani način. Koncept skladišta podataka rješava „nedostatak" relacijske baze, a to je da iz velike količine podataka dolazimo do poslovnih informacija brže. Transakcijski sustavi su sustavi koji se bave dnevnim operacijama i vođenjem poslovnoga sustava. Oni trebaju biti i ostati visoko dostupni. Kompleksni analitički upiti kojim dolazimo do informacija usporavaju rad transakcijskoga sustava što je i razlog da se za kvalitetno rješavanje kompleksnih i kompletnih izvještajnih mogućnosti morao pronaći drugi koncept. Taj drugi koncept jest skladište podataka i predstavlja jedan integrirani repozitorij svih interesantnih transakcijskih podataka poduzeća. On dozvoljava redundantnost podataka pa troši više diskovnoga prostora, ali time posjeduje niz prednosti za analitiku nad podatcima.

Skladište podataka

Korištenjem skladišta podataka možemo prikupljati velike količine podataka u strukturiranom obliku, čime se ubrzava proces analiza i izvještavanja, a time i bržeg donošenja poslovnih odluka, čime se ostvaruje strateška prednost na tržištu. Ideja skladišta podataka je u tome da želimo odvojiti transakcijski sustav od sustava za podršku odlučivanju. To želimo napraviti kako bismo povećali operativnu funkciju transakcijskih sustava jer više neće biti opterećena raznim upitima. To znači da smo iz transakcijskih sustava povijesne podatke preselili u skladište podataka i na taj način informacijski sustav podijeljen je na dva dijela jer smo dva različita poslovna procesa prikupljanja podataka odijelili od generiranja izvještaja, analiza i ostalih oblika koji su u službi stvaranja informacija poslovnoga odlučivanja i izvještavanja.

Pionir koncepta skladišta podataka, William H. Inmon[17] definira skladište podataka i kaže: „Skladište podataka je subjektno orijentiran, integriran, postojan i vremenski različit skup podataka koji služi kao potpora odlučivanju". Subjektno orijentiran znači da je organiziran oko djelatnika, kupaca, izvođača, oko subjekata koji se pojavljuju u informacijskom sustavu. Integriran znači, s obzirom na to da podatci dolaze iz raznih izvora treba uskladiti nazive i strukture varijabli: npr. uskladiti format datuma, oznake spola itd. Postojanost skladišta podataka ogleda se u činjenici da se unutar skladišta podataka samo dodaju novu podatci, nema brisanja ili izmjene podataka,

[17] Inmon, W.H. (1996). Building the Data Warehouse (Second Edition). New York: John Wiley & Sons.

kako se to događa u operativnim sustavima. Podatci se u skladištu podataka sagledavaju u vremenu kada su se dogodili, što znači da je to vremenski različit skup podataka jer može prikazivati razne poslovne događaje sumarno po godinama, kvartalima i mjesecima.

Suvremenik Williama H. Inmona, Ralf Kimball[18] kaže da je skladište podataka: „Kopija transakcijskih podataka specijalno strukturirana za upite i analize“. Kimball 1996. godine također jasno govori da je glavni smisao uspostavljanja skladišta podataka taj što korisnik pomoću svojega računala pristupa podatcima u skladištu na pouzdan, brz i jednostavan način. Govori da podatci u skladištu moraju biti konzistentni. Konzistentnost znači da npr. ako dva korisnika s dva različita mjesta u različito vrijeme postave isti upit, rezultat tih upita treba biti jednak. Ralph Kimball dalje u svojoj knjizi[19] navodi da cijeli sustav skladišta podataka uključuje nekoliko komponent, (Slika 4.), svaki s vlastitim paketom dizajna, tehnika, alata i proizvoda. Najbitnije je shvatiti da nijedna stvar sama za sebe ne čini skladište podataka.

Slika 4: Prikaz procesa i strukture skladišta podataka (skica autora)

Susrećemo se s tri paradigme modeliranja skladišta podataka:

- paradigma Billa Inmona govori da je skladište podataka jedno centralno mjesto za sve podatke jednog poduzeća. U tom pristupu poduzeće prvo kreira normalizirano skladište podataka. Iz toga normaliziranog skladišta podataka kreiraju se dimenzionirana tržišta podatka prema poslovnim područjima. Ovo je poznato i kao pristup „odozgo – dolje“.
- paradigma Ralpha Kimballa naglašava važnost tržišta podataka koja su repozitoriji podataka koja pripadaju određenim područjima poslovanja. Govori da je skladište podataka kombinacija tržišta podataka, čime se olakšava izvještavanje i analiza. Podatci se pohranjuju uvijek u dimenzijskom modelu. Kimball koristi pristup „odozdo – gore“.
- postoji i tzv. „hibridni pristup“, koji u sebi sadrži oba koncepta. U hibridnom pristupu prvo stvorimo cjelokupan koncept skladišta podataka na temelju cjelokupne slike poslovanja,

[18] Kimball, R., Ross, M. (2002). The Data Warehouse Toolkit: The Complete Guide to Dimensional Modeling (Second Edition). New York: John Wiley & Sons.
[19] Kimball, R., Ross, M. (2002). The Data Warehouse Toolkit: The Complete Guide to Dimensional Modeling (Second Edition). New York: John Wiley & Sons.

što je pristup odozgo prema dolje i onda gradimo područna skladišta podataka prema principu odozdo prema gore prema prioritetima koja je postavila šira slika koncepta.

Transakcijske baze podataka koriste se relacijskim modelom. Pri oblikovanju skladišta podataka koristimo se dimenzijskim modelom. Taj model je razumljiviji korisnicima jer je jednostavniji i pregledniji s obzirom na samu strukturu podataka. Relacijski model (normaliziran model) ne trpi redundanciju podataka, što ga čini bržim i učinkovitijim kod izmjene nekog podatka u sustavu. Upravo ti operacijski sustavi i trebaju biti brzi da udovolje unosu dnevnih operacija i transakcija u sustav. Relacijski modeli imaju stotine, nekad i tisuće relacija među sobom, što ih čini presloženim za shvaćanje i pregledavanje od strane krajnjega korisnika, dok s druge strane osiguravaju točnost unesenih podataka i brzinu unosa podataka, a optimizacija rada tih baza na visokoj je razini jer nema redundancije podataka. Da bi se riješio problem relacijskih baza koji one imaju u analitičkom smislu, pojavio se dimenzijski model, i to upravo kao odgovor na tu kompleksnost pri analitici, svojom jednostavnošću i razumljivošću krajnjem korisniku. Dimenzijski model nije normaliziran kao relacijski model, što znači da trpi redundantne podatke. To u skladištu nije problem jer se tu ne trebaju događati brze izmjene nekoga podataka kako se to događa u transakcijskom sustavu, događa se samo dodavanje novih podataka. Stoga je taj model jednostavan i osigurava intuitivan i učinkovit pregled podataka što je nedostatak relacijskoga modela. U dimenzijskom modelu obrađuje se i analizira istovremeno i do nekoliko milijuna zapisa. Relacijski model napravljen je tako da postiže velike brzine s manjom količinom zapisa odjednom (do nekoliko desetaka zapisa). Ova razlika čini dimenzijski model prikladniji za potrebe analitike i obrade podataka koja se događa na skladištu podataka te možemo reći da je to glavni razlog zašto se u većini poduzeća koristi dimenzijski model kojeg zastupa Ralph Kimball. Dimenzijski model prikazuje se kockom. Glavni termine i karakteristike dimenzijskoga modela (Slika 5.):

Slika 5. Glavni termini dimenzijskoga modela i njihova međusobna povezanost[20]

[20] https://docs.oracle.com/cd/E29633_01/CDMOG/GUID-428F33D4-04D0-4EDA-BA60-96EF3988C803.htm, 12.5.2020

- Kocka (eng. *cube)* – multidimenzionalni skup podataka koja sadrži tri ili više dimenzija. Na presjecima dimenzija kocke nalazimo kvantitativne podatke. Te kvantitativne podatke nazivamo mjere koje imaju iste dimenzije i zbog toga se lako mogu analizirati i sumirati. Ako je broj dimenzija veći od 3, takva kocka naziva se hiperkocka. Kocka obično odgovara jednoj činjeničnoj tablici (eng. *fact table*).
- Dimenzija (eng. *dimension*) - kvalitativno obilježje podatka. Dimenzije kategoriziraju podatke. Budući da su mjere obično višedimenzionalne, vrijednost jedne mjere određena je članom, tj. pozicijom svake dimenzije da bi sve imalo smisla. Npr. mjera prodaje ima četiri dimenzije: vrijeme, kupac, proizvod i prodajni kanal. Određena prodajna vrijednost (npr. 450,00 kn) ima značenje samo ako je određena prema određenom vremenskom razdoblju (npr. siječanj 2020.), kupcem (npr. Ivan Ivić), proizvodom (npr. mobitel) i prodajnim kanalom (npr. *web shop*). Vrijednosti dimenzija na razini baze odgovaraju jedinstvenim ključevima tablice činjenica. Primjeri dimenzija, osim dimenzije vremena, jesu npr. dimenzija proizvoda ili zemljopisna dimenzija koja može uključivati hijerarhiju s razinama za državu, županiju, grad.
- Atribut (eng. *attribute)* – razina unutar dimenzije koja ima svoje članove ili pozicije, npr. godina je atribut (kategorija) u vremenskoj dimenziji, a pozicije (članovi) su 2010., 2011., 2012., 2013., itd. Osim godine, u vremenskoj dimenziji atributi ili kategorije još su i dan, tjedan, mjesec, kvartal, polugodište.
- Član je stavka u hijerarhiji, npr. u vremenskoj dimenziji, godine 2013. i 2014. jedinstveni su članovi na razini godine. Veljača je npr. nejedinstveni član na razini mjeseca jer u vremenskoj dimenziji s podatcima za više godina može biti više od jedne veljače.
- Izračunati član je vrijednost koja se računa iz vrijednosti ostalih članova. Npr. izračunati član „Profit“ računa se kad se od člana „Trošak“ oduzme vrijednost člana „Prodaja“.
- Mjere (eng. *measure)* – izmjerene količine i kao takve su kvantitativno obilježje, što znači da su uvijek brojčana vrijednost. Na mjerama izvodimo potrebne matematičke operacije koje zahtijevaju poslovne analize.
- Hijerarhija (eng. *hierarchy)* – specifikacija razine odnosa između atributa (kategorija) unutar dimenzije, npr. Godina>polugodište>kvartal>mjesec>tjedan>dan u vremenskoj dimenziji. Hijerarhiju promatramo kao logičku strukturu stabla povezanih po modelu roditelj – dijete. Svaka kategorija (roditelj) unutar sebe može imati ni jednog člana ili više članova (dijete). Npr. u vremenskoj dimenziji „roditelj“ (kategorija) mjesec ima „djecu“ (članove): siječanj, veljača, ožujak itd.

- Razina (eng. *level*) – unutar npr. vremenske hijerahije, podatci se mogu organizirati u sljedeće kategorije: godina, tromjesečje, mjesec i dan. Ako dimenziju prikazujemo prema osnovnoj kategoriji, npr. dani, govorimo o analitičkom (detaljiziranom) pogledu, dok kod prikaza po svim kategorijama iznad govorimo o sumiranim prikazima za određenu razinu.
- Činjenična tablica (eng. *fact table*) – tablica koja sadrži ključeve dimenzijskih tablica i mjere koje želimo pratiti npr. prodano_kune, prodano_količina. Normalizirana je tablica i često je jednaka tablici iz relacijskoga modela.
- Dimenzijska ili *lookup* tablica (eng. *lookup table*) – tablica koja daje detaljne informacije o atributima, tj. objašnjava i opisuje činjenice pohranjene u činjeničnoj tablici. Npr. dimenzijska tablica za kvartal sadržavat će sve dostupne kvartale u skladištu podataka. Svaki redak (svaki kvartal) može imati nekoliko zapisa (atributa), vrijednost koja će se prikazivati u izvješću „1 kvartal 2014“ ili samo „prvi kvartal“ i sl.
- Vremenska dimenzija – podatci se u skladištu uvijek promatraju u vremenskom kontekstu. To je i razlog zašto se u tom modelu pozornost posvećuje vremenskoj dimenziji pa se stvaraju posebne tablice koje opisuje vremenski kontekst. Npr., dimenzija datum prisutna je u svakom skladištu podataka. Generira se unaprijed za vremensko razdoblje u kojem pratimo poslovanje i na taj način ubrzavamo upite na bazu jer se izračunavanje vremena ne događa istodobno s postavljanjem upita.

Slika 6. Prikaz dimenzijskih modela podataka u obliku kocke (slika autora)

Prikaz višedimenzionalnoga modela kockom vizualno je lakše razumljiv korisniku kada se radi o tri dimenzije (Slika 6.), no u primjeru gdje smo se koristili s pet dimenzija (Slika 7.), vidimo da je već teže napraviti grafički prikaz kockom te se stoga za prikaz višedimenzionalnoga sustava koristi zvjezdasti dijagram (eng. *star shema*). Koristeći se zvjezdastim dijagramom, bez obzira na broj dimenzija, još je uvijek sve lako shvatljivo i razumljivo, osobito krajnjim korisnicima.

Slika 7. Prikaz dimenzijskoga modela u obliku zvijezde, *star shema* (slika autora)

Dimenzijski modeli ili sheme kod izrade skladišta podataka daju jedan logičan opis cijele baze podataka i prikazuju nazive i opise svih vrsta zapisa. Dvije najkorištenije sheme jesu:

Zvjezdasti model ili „Star“ shema (više se koristi) – model ima jednu tablicu s primarnim ključem. Tu tablicu zovemo činjenična tablica (eng. fact table). Ona je centralna tablica na koju se vežu tablice koje se zovu dimenzijske tablice (eng. dimension table). Sve dimenzijske tablice sadrže atribute i primarni ključ. Primarni ključ dimenzijske tablice jednak je atributu primarnoga ključa činjenične tablice. Činjenična tablica uz vrijednosti sadrži i opis vrijednosti npr. valutu (kn, euro, dolar) ili mjernu jedinicu (metar, centimetar i sl.).

Pahuljasti model ili „Pahuljica“ shema (manje korišten model) – u pahuljica shemi u sredini se također nalazi činjenična tablica. U modelu se nalaze i dimenzijske tablice gdje su jedna ili više njih normalizirane. Normalizacija znači podijeliti podatke u dodatne tablice čime se smanjuje redundancija, u biti ide se k relacijskom modelu, što je i razlika u odnosu na „star“ shemu.

Arhitektura skladišta podataka ovisi o kompleksnosti projekta i potrebama poslovanja. Sve te arhitekture imaju neke zajedničke principe, pojmove i zajedničke dijelove od kojih su izgrađene:

- izvori podataka – transakcijske, operativne relacijske baze podataka poduzeća, više ili manje strukturirane datoteke (txt, exel, web stranice), web servisi, itd.
- pripremno područje (eng. *data staging area*) – radni prostor skladišta podataka. To je mjesto gdje se sirovi podatci uvoze, čiste, kombiniraju, arhiviraju i nekada eksportiraju prema tržištima podataka. To je baza podataka u kojoj se događaju sve transformacije i

integracije iz izvornih podataka do samoga skladišta podataka. Znači, to je jedna „tehnička“ baza podataka kojoj krajnji korisnik nema pristup.

- ODS (eng. *operational data store*) – baza podatka koja sadrži dnevne, ažurne podatke koji minimalno kasne sa stvarnim stanjem u transakcijskim bazama. Stoga se ta baza i koristi za operativno izvještavanje, za razliku od skladišta podataka koji koristimo za „taktičko“ izvještavanje jer se tamo nalaze podatci s većim odmakom od trenutnoga stanja. Toj bazi krajnji korisnici imaju pristup.
- Skladište podataka – baza podataka u kojoj su podatci transformirani, čisti, točni i spremni za analitičku obradu i izvještavanja.
- OLAP – sustav za upravljanje podatcima s većim brzinama obavljanja upitima.
- Alati za analitiku – razni alati za vizualizaciju, pregled i analizu podataka (MS Excel, Power BI, Tableau software itd.).

S obzirom na to da se pokazala kao najkvalitetnije rješenje, u praksi se najviše koristi troslojna arhitektura koja ima zajedničko skladište podataka i veći broj *data mart* skladišta (Slika 8.).

Slika 8. Dijagram troslojne arhitekture skladišta podataka[21]

[21] https://panoply.io/data-warehouse-guide/data-warehouse-architecture-traditional-vs-cloud/, 20.11.2020.

Iz dijagrama troslojne arhitekture skladišta podataka možemo vidjeti da postoje tri glavna sloja navedene arhitekture:

1. Prvi ili donji sloj (eng. *bottom tier*) – označava nam sustav za izvlačenje i pohranu podataka iz transakcijskih baza podataka (relacijska baza podataka). U ovom dijelu koristimo ETL alate za dohvat, manipulaciju i pohranu podataka.
2. Drugi ili srednji sloj (eng. *middle tier*) – sadrži OLAP poslužitelj, koji podatke pretvara u strukturu pogodniju za analizu i složene upite. OLAP poslužitelj može raditi kao relacijski OLAP (ROLAP ili kao višedimenzionalni OLAP (MOLAP) model.
3. Treći ili gornji sloj (eng. *front-end*) – predstavlja „klijenta“, sloj koji sadrži alate za: izvještavanje na temelju kreiranih upita, analizu podataka i rudarenje podatak.

Nestrukturirani i polustrukturirani podatci, kojih je danas prepun internet, veliki su izvor podataka koji skrivaju informacije koje mogu pospješiti donošenje boljih poslovnih odluka. Tehnologija koja rješava taj poslovni problem zove se *Data Lake* (podatkovno jezero). *Data Lake* arhitektura bolje odgovara današnjim zahtjevima i potrebama za podatcima nego tradicionalne tehnologije poput relacijskih baza podataka i skladišta podataka.

ETL i ELT proces

Ž. Panian i G. Klepac[22] kažu kako ETL procesi imaju za cilj ekstrahirati, odnosno zahvaćati ili vaditi (engl. *extract*), transformirati odnosno preoblikovati (engl. *transform*), puniti ili unositi (engl. *load*) podatke iz jednog ili više transakcijskih sustava u skladište podataka.

Općenitiji pojam za ta tri procesa koja čine ETL proces jest integracija podataka (eng. *Data Integration*) za potrebe skladišta podataka. Kada govorimo o integracijskim procesima za skladišta podataka, u stvarnosti se susrećemo s dva koncepta: ETL (Extract, Transform, Load) i ELT (Extract, Load, Transform). Oba koncepta imaju iste korake, drugačiji je redoslijed izvođenja tih koraka. Pitanje koje se nameće glasi: Želimo li transformaciju podataka raditi prije ili poslije učitavanja podataka u repozitorij podataka? Dosta čimbenika utječe na izbor između tih dviju opcija.

ETL: Ekstrakcija => Transformacija => Učitavanje => Analiza (Slika 9.)

ELT: Ekstrakcija => Učitavanje => Transformacija => Analiza (Slika 10.)

[22] Panian, Ž., Klepac, G. (2003). Poslovna Inteligencija. Zagreb: Masmedia.

Slika 9. ETL proces[23]

ETL proces je vrlo kompleksna komponenta skladišta podataka. Jedino kvalitetno dizajniran i razvijen ETL osigurava svoju glavnu svrhu, a to je osiguravanje kvalitetnih podataka s kojima punimo skladište podataka. Kompleksnost poslova integracije podataka kroz dizajn ETL-a promatra se kroz karakteristike izvora podataka i karakteristike samih podataka. **Karakteristike izvora podataka** govore o tome da su izvori podataka različiti i raznoliki, nalaze se na različitim platformama i na različitim operativnim sustavima, razvijeni su na tehnologijama koje se više ne koriste i kao takvi ne predstavljaju podatke u formatima i tipovima koji su čitljivi krajnjim korisnicima jer su kriptirani i dvosmisleni. To su razni transakcijski sustavi (MS SQL, Oracle, My SQL, Fox Pro, MS Access, itd.), internetske stranice i razni datotečni sustavi (cvs, xlsx, txt). Što je više raznorodnih izvora podataka, kompleksnost i količina ETL poslova se povećava. **Karakteristike podataka** jesu upitne kvalitete zbog starih sustava izvora podataka koji su se razvijali u prošlosti. Također, izvori podataka nemaju povijesne podatke o promjenama u vrijednostima, što je bitno kod skladišta podataka. Zatim, podatci su nekonzistentni pa je vjerojatnost da će isti podatci biti zastupljeni različito u različitim sustavima izvora podataka velika. Postaviti ih konzistentnima, kada se otkriju, također čini dizajn ETL procesa kompleksnim. Sve nabrojano čini razvoj ETL procesa izazovnim pa se, posljedično tome, troši dosta vremena. Prema statistikama, 60 – 80% vremena otpada upravo na dizajn i razvoj ETL-a.

Glavna svrha ETL procesa jest da popunjava i osvježava podatke u skladištu podataka. To znači da svaki put kad se na izvoru podataka promijene podatci, ETL proces zadužen je da se promijenjeni podatci nađu u skladištu podataka. Tri glavna ETL procesa koji osiguravaju svrhu ETL-a jesu:

1. ekstrahiranje podataka (eng. *extract*) – podrazumijeva izdvajanje potrebnih podataka iz izvora podataka i njihovo prebacivanje u područje gdje će se ti podatci obrađivati

[23] https://www.xplenty.com/blog/etl-vs-elt/#etl, 2.5.2020

2. transformacija podataka (eng. *transform*) – znači stvaranje kvalitetnih podataka:
    a. potvrđivanjem podataka koji su u skladu s poslovnim pravilima
    b. izolacija i čišćenje podatka koji ne zadovoljavaju postavljena poslovna pravila
    c. izračunavanje novih vrijednosti koje poštuju relacije u skladištu podataka
3. učitavanje podataka (eng. *load*) – podrazumijeva učitavanje i spremanje očišćenih, transformiranih i u startu prihvatljivih podataka u relacije skladišta podataka
4. R. Kimball[24] u svojoj knjizi, osim ovih triju glavnih procesa ETL-a, naglašava i proces usklađivanja podataka, gdje navodi da će taj proces trebati u slučaju kad se radi o raznovrsnim izvorima podataka, gdje će na razini tvrtke najprije trebati postaviti poslovna pravila koja će iste ili slične podatke iz raznih izvora smisleno i poslovno povezati.

Data Lakes su drugačija vrsta skladišta podataka od OLAP skladišta podataka jer oni prihvaćaju sve vrste strukturiranih i nestrukturiranih podataka, kao i ostalih „sirovih“ informacija, bez obzira na njihov format ili nedostatak. Ova nova tehnologija svoju vrijednost temelji na tehnologijama u oblaku gdje se koristi brzim serverima koji nude beskrajne mogućnosti pohrane i skalabilnu moć obrade. Primjeri za to su Amazon Redshift i Google BigQuery. Čim podatci negdje postanu dostupni, a nama su poslovno zanimljivi, ova tehnologija ih odmah „usisa“ u jezero podataka, što predstavlja centralni repozitorij podataka, gdje čekaju na transformaciju i čišćenje ,ako se nekom kasnijom analizom utvrdi da uvezeni podatci mogu pomoći kod donošenja poslovnih odluka. Znači, kod ELT koncepta transformacija i čišćenje podataka ne događa se odmah prilikom ulaza podataka u repozitorij nego kasnije, kada se samo prepoznati važni podatci transformiraju i pripremaju za analizu koju provode poslovni korisnici raznim BI alatima (Slika 10.).

Slika 10. ELT proces[25]

[24] Kimball, R., Caserta, J. (2004). The Data Warehouse ETL Toolkit: Practical Techniques for Extracting, Cleaning, Conforming and Delivering Data, Wiley
[25] https://www.xplenty.com/blog/etl-vs-elt/#etl, 2.5.2020.

Možemo zaključiti da se glavne prednosti ELT-a u odnosu na ETL odnose na fleksibilnost i lakoću pohrane bilo kojeg tipa podataka, pri čemu nam je omogućen pristup tim podatcima kad god to želimo pri čemu prije korištenja tih podataka ne moramo razvijati složene ETL procese. Tako štedimo početno vrijeme programerima i BI analitičarima jer se od nas ne traži da odmah postavljamo procese čišćenja i transformacije. Međutim, kad i ako krenemo u taj proces, radimo na točno definiranim potrebama zahtijevanim od poslovnih korisnika. Na spoznaji da je borba za znanjem dobivenim iz podataka velika, zanimanje budućnosti, koja se već događa, upravo je *Data Scientist* (znanstvenik podataka) koji će iz mase uvezenih podataka prvo otkriti što sve možemo analizirati od uvezenih podataka i onda taj spektar mogućnosti ponuditi poslovnim korisnicima koji će odabrati što će im od svega toga koristiti za bolje poslovno odlučivanje.

Stage[26] *– komponenta ETL-a za prihvat izvornih podataka*

Stage (*staging area*) ili međuprostor ili sabiralište (eng. *Landing zone*) jedan je međuskladišni prostor unutar ETL procesa između izvorišnih sustava i skladišta podataka. To je baza podataka unutar koje se privremeno zadržavaju podatci, znači isti se brišu, nakon što se prebace u skladište podataka. *Stage* koristimo kod kompliciranijih skladišta podataka, dok kod jednostavnijih projekata sama memorija računala (*text file, xml file*) služi kao *staging area*, kao međuprostor iz kojeg se puni skladište podataka. Kod kompliciranijih projekata *stage* se implementira kao baza podataka (relacijska, nerelacijska baza) ili kao dio baze.

Glavni razlozi za uspostavom takvog međuprostora (*stage*) jest povećanje učinkovitost ETL procesa čime se jače osigurava integritet i kvaliteta potrebnih podataka, dok s druge strane i sama činjenica da, ako bi se procesi sortiranja, filtriranja, reformatiranja, usklađivanja, čišćenja i agregiranja radili na transakcijskim sustavima, dovelo bi do problema kod obavljanja redovnih poslova, što otvara prostor za povećanje rizika poslovanja.

Glavne funkcije *stag-a* su sljedeće:

1. sređivanje podataka (eng. *Consolidation*) – podatci dolaze iz različitih izvora u *stage* i upravo zbog te činjenice, prije nego idu na daljnju obradu, podatcima se:
    a. dodjeljuju metapodatci (podatci o podatcima), npr. iz kojeg su izvora došli podatci ili npr. datum kada su podatci došli na *stage*
    b. ako se podatci nalaze u različitim formatima, iste treba standardizirati i validirati, tj. prikazati ih jedinstvenim formatima

[26] https://en.wikipedia.org/wiki/Staging_(data), 16.04.2020.

2. usklađivanje podataka (eng. *Alignment*) – s obzirom na to da se u praksi javlja redundancija podataka, događa se da njihove vrijednosti na svim mjestima nisu jednake zbog neažuriranja. To usklađivanje događa se na *stageu* unutar ETL procesa.
3. funkcija smanjivanje grešaka na minimum (eng. *Minimizing contention*) – ta je funkcija moguća zato što se podatci iz izvornih sustava mogu kopirati u *stage* odjednom, što je svakako učinkovitije od jednokratnoga preuzimanja pojedinih zapisa (ili malih skupova zapisa). Zbog postupka kopiranja podataka, ETL postupak ima veliku kontrolu u slučaju ponavljanja istih podataka.
4. nezavisno planiranje punjenja i obrade podataka i slanje u skladište podataka i drugim segmentima ETL procesa (eng. Independent scheduling/multiple targets) – npr. u nekim se slučajevima podatci mogu uvući u *stage* u različito vrijeme da bi se istovremeno održavali i obrađivali i nakon toga slali u skladište podataka. Ova se situacija može dogoditi, na primjer, kod poduzeća koje svoje poslovanje obavlja u više vremenskih zona. U drugim slučajevima, podatci se mogu unijeti u *stage* istovremeno, ali obrađivati u različito vrijeme. Također se *stage* može koristiti za slanje podataka u više ciljnih sustava. Na primjer, dnevni operativni podatci mogu se prebaciti u operativno spremište podataka (ODS), dok se isti podatci mogu poslati u zbirnom obliku mjesečno u skladište podataka.
5. funkcija detekcije promjena (eng. *Change detection*) – *stage* podržava učinkovite postupke otkrivanja promjena u odnosu na skladište podataka. Ova je funkcionalnost osobito korisna kada izvorni sustavi ne podržavaju pouzdane oblike otkrivanja promjena, poput vremenskoga označavanja koje primjenjuje sustav, praćenja promjena na podatcima ili snimanja podataka.
6. funkcija čišćenja podataka (eng. *Cleansing data*) – čišćenje podataka uključuje identifikaciju i uklanjanje (ili ažuriranje) nevažećih podataka iz izvornih sustava. ETL proces kojim se koristi *stage*, služi upravo za primjenu poslovne logike za prepoznavanje i rukovanje "nevaljanim" podatcima. Nevažeći podatci često se definiraju kombinacijom poslovnih pravila. Takvi podatci nastanu kao greške u radu informacijskih sustava, ako neki testni ili simulacijski podatci nisu uklonjeni iz sustava ili ako su u sustav ubačeni neki lažni podatci uslijed npr. računalnih virusa.
7. funkcija zbirnih izračuna (eng. *Aggregate precalculation*) – složeni izračuni zbog primjene složene poslovne logike mogu se obavljati i u *stag-u* kako bi se napravili izvještaji zbog poštivanja SLA ugovora.
8. Funkcija arhiviranja podataka i rješavanje problema (eng. *Data archiving and troubleshooting*) – *stage* se može koristiti za održavanje povijesnih podataka tijekom

procesa učitavanja podataka ili se može koristiti za prebacivanje podataka u arhivski dio baze podataka. Također, podatci se mogu držati unutar *stagea* i kroz duže razdoblje, kako bi se podržalo tehničko rješavanje problema ETL procesa.

S obzirom na to da se *stage* koristi privremeno, postoje poslovne preporuke i ponašanja kojih se treba pridržavati, a vezani su uz korištenje podataka na *stageu*. *Stage* podatci dostupni su samo ETL timu i samo ETL procesi pišu i čitaju iz *stagea*. Korisnici nemaju pristup *stage* području zato što poslovni izvještaji ne smiju koristiti podatke sa *stagea*.

Ekstrahiranje podataka (eng. Extract) – dohvaćanje ili čitanje izvornih podataka

Nakon što smo identificirali izvor podataka i njihovu postojeću strukturu, pristupamo ekstrahiranju podataka iz izvorišnih sustava. To je postupak kojim izdvajamo potrebne podatke iz transakcijske baze podataka poduzeća. Generalno, cilj je izvaditi podatke iz transakcijskih sustava tako da operativni poslovi što manje trpe. Ova paradigma zahtijeva pozornost na sljedećem:

1. izvor podataka treba što manje opteretiti
2. pobrinuti se da proces ekstrakcije ne utječe bitno na konfiguraciju izvornih sustava
3. treba odabrati adekvatan način ekstrakcije podataka iz izvornih sustava
    i. ažuriranje svih podataka prilikom svakoga osvježavanja skladišta podataka
    ii. ažuriranje samo podataka koji su se mijenjali nakon zadnjega osvježavanja (inkrementalno ažuriranje).

Ekstrakciju radimo pomoću komercijalnih alata ili vlastito izrađenih skripti. Praksa je pokazala da je najučinkovitija kombinacija tih dvaju postupaka. Komercijalni alati su skuplji, ali fleksibilniji i lakši za održavanje ako mijenjamo izvorišne sustave.

Današnje poslovanje teži brzini, stoga se u fazi ekstrakcije nakon inicijalnoga punjenja treba odrediti za strategiju naknadnih sinkronizacija. Koji će se princip odabrati, ovisi o poslovnim potrebama poduzeća, tj. o vrsti posla kojim se poduzeće bavi. Moguće je da se neki sustavi unutar poduzeća preuzimaju češće od drugih jer tempo diktira tržište ili neki drugi unutarnji čimbenici, kao što su praćenje korištenja kreditnih kartica, praćenje događanja na tržištu dionica ili praćenje vitalnih znakova bolesnika gdje će se tražiti češća osvježavanja skladišta podataka.

Razlikujemo tri pojma u načinima sinkronizacije podataka nakon inicijalnoga punjenja:

1. potpuno ažuriranje (eng. *Full reload*) – punjenje se odvija isto kao inicijalno punjenje. Nakon završetka *full reloada,* uspoređuju se rezultati s trenutnim stanjem u skladištu

podataka i određuju se promjene koje treba napraviti. Ulaže se manji napor u razvoj ETL procesa zato što se u ovom slučaju razvija samo jedan ETL proces.

2. inkrementalno ažuriranje – promjena se događa tako da se vidi razlika promjena od zadnje sinkronizacije, što čini novu ekstrakciju na *stageu*. Ažuriranje se može odvijati i nekoliko puta dnevno, međutim u praksi se to uglavnom događa jednom dnevno (noć), kad je OLTP sustav (transakcijske baze poslovanja) puno manje opterećen jer se tada ne odvija redovno poslovanje. Zadovoljavajuća je za većinu poslovanja, brža je i učinkovitija od potpunoga ažuriranja, ali se ulaže veći napor u razvoj procesa jer se treba razviti i proces za inicijalno punjenje i ETL proces za inkrementalno ažuriranje.
3. stvarnovremensko ažuriranje – događa se u slučajevima kod vrlo bitnih poslovnih procesa kada je osvježavanje podataka potrebno u minutama ili sekundama, npr. praćenje vitalnih znakova bolesnika. Tehnički je vrlo zahtjevan proces jer se ulaže veći napor u razvoj ETL procesa, s obzirom na to da se koriste CDC tehnike (eng. *Change Data Capture*), gdje se sve promjene (unos, izmjena, brisanje) od zadnje sinkronizacije na izvorišnim sustavima moraju zabilježiti. Postoji više vrsta CDC tehnika. Glavno je pitanje koju tehniku upotrijebiti, u kojem slučaju i koja je prikladna za naš specifičan projekt koji ovisi o konkretnom poslovanju poduzeća i tehničkoj podlozi sustava u kojem se tehnika implementira. Tehnika koju svi moraju upotrijebiti jest tehnika dohvata statičkih podataka zato što je to tehnika koja se primjenjuje kod inicijalnoga punjenja. Dohvat podataka pomoću mehanizama postavljenih na bazi i dohvat podataka pomoću dnevnika transakcija dvije su tehnike koje detektiraju sve ključne promjene na podatcima (*insert, update, delete, merge*). Te tehnike spremaju u log tablice prikupljene podatke o svim promjena koje se događaju na podatcima u nekom vremenskom intervalu.

Prema Ponniah[27], kod ekstrakcije podataka, osim gore spomenutih pitanja, treba se riješiti i pitanje redoslijeda obavljanja poslova. Znači treba otkriti uvjetovanost poslova, npr. koji se poslovi događaju paralelno, a koji se događaju jedan nakon drugoga. Također se treba dogovoriti kako će se riješiti problem kada se dogodi greška, tj. kada se ulazni podatak ne može pročitati.

Tri su ključne promjene koji uvjetuju ubrzavanje poslovanja pa samim time i ETL procesa:

1. pojava interneta kao nove vrste izvora podataka – podatci koje se pojave na internetu nisu uvijek dostupni i, ako se ne zabilježi promjena, oni kasnije mogu nedostajati

[27] Ponniah, P., (2001.) Data Warehousing Fundamentals. New York: John Wiley¸& Sons

2. globalizacija gospodarstva – poduzeća imaju svoje ogranke u bilo kojoj vremenskoj zoni, što znači da se transakcijske baze pune i preko noći
3. važnost poslovanja – poslovanja koja su zasnovana na svježim, a ne jučerašnjim podatcima (bolnice, burze, konkurentnost na tržištu….).

PR. Kimball, i M. Ross[28] navode dvije metode za ekstrahiranje podataka iz izvornoga sustava. To su ekstrahiranje podataka u obliku datoteka podataka i ekstrahiranje podataka kao *stream* (tijek podataka). Ako je izvor stariji *mainframe* sustav, podatci se izdvoje u datoteke, premjeste na ETL poslužitelj i na kraju se transformira sadržaj datoteka na *stage*. Ako koristimo ETL alat, a izvorni se podatci nalaze u bazi podataka, ekstrakcija se odvija kao *stream* podataka u kojem podatci izlaze iz izvornoga sustava, putem alata za transformaciju i dolaze na *stage*, kao jedinstven proces.

Kvaliteta podataka u skladištima podataka

Kvalitetu podataka determiniramo i vrednujemo pomoću atributa kvalitete koje zajedničkim imenom nazivamo dimenzijama kvalitete podataka, gdje svaka dimenzija pojašnjava jedan aspekt kvalitete podataka. Glavni odgovor na pitanje da li je podatak kvalitetan ili nije leži u pitanju ispunjava li podatak svoju svrhu koja je definirana od strane vlasnika podataka. Ako je odgovor na to pitanje pozitivan, možemo reći da je podatak u skladu sa standardima postavljene kvalitete.
Dimenzije kvalitete podataka koje u konačnici utječu na pojam kvalitete podatka jesu:

1. točnost podataka – podrazumijeva da je vrijednost koja je pohranjena u sustavu za neki podatak točna vrijednost
2. integritet domene – znači da vrijednost podataka smije biti u dopuštenom rasponu vrijednosti za tu domenu, npr. raspon vrijednosti za spol može biti ili muško ili žensko
3. tip podataka – npr. ako je format podataka „text“ za neki atribut podatka, tada sve instance tog atributa podataka jesu „text“ polje što znači da u sadržaju ne smiju sadržavati brojeve
4. redundancija podataka – podatci se ne smiju pohranjivati na više mjesta u sustavu, a u slučaju da se ipak pohranjuju, trebaju biti jasno označeni kako bi se mogli provjeriti
5. dosljednost podataka – ako je šifra nekoga proizvoda 435, u svim sustavima taj podatak mora imati istu šifru, istu formu i sadržaj
6. potpunost podataka – znači da svi podatci moraju biti ispunjeni, sva polja moraju biti popunjena, npr. svaki kupac u polje telefon treba upisati broj telefona.

[28] Kimball, R., Ross, M. (2013). The Data Warehouse Toolkit: The Definitive Guide to Dimensional Modeling, 3rd Edition, Wiley

7. pravovremenost podataka – pravovremenost znači da se podatci dostavljaju korisnicima u vremenu kada ih korisnik i zahtijeva jer su mu tada aktualni, tj. dovoljno su stari da korisnik može obaviti svoj posao
8. upotrebljivost podataka – podatci u skladištu podataka trebaju biti samo oni podatci za koje je korisnik podataka ustvrdio da su mu korisni
9. pridržavanje pravila integriteta podataka – npr. referentni integritet osigurava da za svaku narudžbu u bazi mora postojati kupac (odnos roditelj – dijete)
10. jasnoća podataka – ako podatak ne nosi pravilno ime, onda nema potrebno značenje i uzalud je što podatak ispunjava sve ostale karakteristike kvalitetnoga podatka
11. anomalije podataka nisu dozvoljene – npr. ako imamo polje koje se zove „Telefon_3“ tim se poljem koristimo samo za upis trećega telefonskog broja nekoga korisnika
12. koristiti prirodnu strukturu podataka – npr. ime, srednje ime, prezime
13. sukladnost s poslovnim pravilima – vrijednost svakoga podatka treba se pridržavati propisanih poslovnih pravila
14. dupliciranje podataka – ako je i dozvoljeno dupliciranje podataka, isti trebaju biti propisno označeni.

Kvalitetan podatak osigurat će se ako je cijeli proces upravljanja kvalitetom dobro osmišljen i postavljen. P. Ponniah[29] navodi bitne korake toga procesa: utvrditi važnost kvalitete podataka u poduzeću, formirati upravljački odbor koje će osiguravati kvalitetu, dodijeliti uloge i odgovornosti djelatnicima u procesu, postaviti proces (alati, postupci, standardi) upravljanja kvalitetom, prioritetne podatke razvrstati u visoku, srednju i nisku kategoriju, osigurati kvalitetne stručnjake koji rade na uspostavi skladišta podataka.

Kod uspostavljanja skladišta podataka ne čekamo 100% da su podatci čisti pa ih onda tek učitavamo u skladište podataka. Ta je razina kvalitete učitavanja podatka rijetka. Podatci se razvrstavaju u kategorije i to u visokoprioritetne koje zahtijevaju 100% ulaznu čistoću podataka od onih koji se trebaju očistiti što je više moguće od onih najnižega prioriteta koji će se očistiti ako bude vremena. Npr. dupliciranje podataka s izvornih sustava primjer je visokoprioritetnoga čišćenja podataka i takvi podatci, dok se ne očiste, ne ulaze u skladište podataka. Ovdje treba spomenuti i podatke dobivene iz javnih izvora. Ako ih plaćamo, onda možemo zahtijevati određenu kvalitetu podataka, međutim kod podataka koje uzimamo iz javnih domena najprije treba

[29] Ponniah, P., (2008). Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.

dobro provjeriti npr. od koga ih uzimamo (državne institucije, privatne tvrtke, pojedinačne aplikacije), čime provjeravamo pouzdanost izvora i, naravno, stupanj kvalitete preuzetih podataka. Formiranje upravljačkoga tijela koje se brine o kvaliteti podataka dobar je korak u osiguravanju kvalitete podataka jer taj odbor organizira revizije kvalitete podataka i na takav način ugrađuje svjesnost djelatnicima poduzeća o važnosti kvalitete podatka na donošenje kvalitetnijih poslovnih odluka. Cilj je stvarati sigurno i prosperitetno poduzeće koji ide u korak s tržištem i potrebama korisnika usluga poduzeća. To je jedan zatvoreni krug kojeg često djelatnici poduzeća nisu svakodnevno svjesni, a revizije ih na to podsjećaju.

Možemo zaključiti da podatak može biti točan, potpun, pravovremen, konzistentan itd., ali uslijed neke greške u postavljanju ETL procesa, podatak možda nije završio u ciljanoj tablici unutar skladišta podataka ili se može dogoditi da zbog greške u dinamici objavljivanja podatka u ETL procesu, podatak nije proslijeđen u očekivano željeno vrijeme korisnicima u tablice skladišta podataka. Zbog tih činjenica možemo zaključiti da, osim dimenzija kvalitete podataka, na kvalitetu podataka utječe i kvaliteta postavljene logike unutar ETL procesa.

Transformacija podataka (eng. Transform) – čišćenje i usklađivanje podataka

Poslovi transformacije i čišćenja podataka mijenjaju podatke, čime osiguravaju kvalitetu podataka jer se samo kvalitetan podatak može koristiti za predviđenu svrhu. Kod procesa transformacije i čišćenja podataka stvaraju se „vrlo snažni“ metapodatci. Snaga metapodataka očituje se u tome što oni govore što nije dobro u izvornim sustavima. U konačnici, loši podatci mogu se popraviti samo promjenom načina na koji izvorni sustavi prikupljaju podatke. Znači, nakon ekstrakcije podataka, podatci se najprije čiste pa onda transformiraju u skladu s relacijama postavljenim u skladištu podataka. Možemo reći da su poslovi čišćenja i transformacije bit ETL procesa.

Prema P. Ponniah[30] kod procesa transformacije podataka razlikujemo osnovne zadatke transformacije podataka i najviše korištene transformacijske funkcije. Osnovni zadatci procesa transformacije podataka jesu: selekcija podataka; razdvajanje/spajanje podataka; konverzija podataka; obogaćivanje podataka; sumiranje podataka – kod nekih poslovnih procesa nećemo trebati prikaz podataka po najnižoj granulaciji, npr. trgovački lanac možda neće trebati granulaciju po svakoj pojedinačnoj kupnji, da bi na osnovu njih radio analize i upite, već će biti dovoljno imati

[30] Ponniah, P., (2008). Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.

u skladištu podataka grupiranu prodaju po proizvodu, po danu i za svaku trgovinu. To znači da sumiranje, kao osnovna funkcija transformacije podataka, uključuje prvo grupiranje podataka po proizvodu, danu i prodajnom mjestu i onda njihovo sumiranje.

Najviše korištene transformacijske funkcije kod procesa transformacije podataka jesu: **revizija formata**; **dekodiranje polja** – funkcija koja će iste podatke koji dolaze iz različitih izvora prevesti (dekodirati) na jednoobrazni prikaz. Npr., u nekim izvornim sustavima oznake 1 i 2 koriste se za oznaku muško ili žensko, u drugim sustavima muško ili žensko označava se oznakama M i F. Daljnji primjeri jesu korištenje kriptičnih kodova koji korisniku ne znače ništa pa ih treba prevesti u jezik razumljiv korisniku pa će npr. kodovi AC, IN, RE i SU biti promijenjeni u Active, Inactive, Regular and Suspended; **izračunate nove vrijednosti; dijeljenje pojedinačnih polja** – funkcija koja će iz starijih naslijeđenih sustava velika polja koja su u sebi sadržavala i ime i srednje ime i prezime pretvoriti u tri zasebna polja ili koja će polje u koje se upisivao i grad i pošta i adresa i država također podijeliti u četiri zasebna polja. To je dobro učiniti jer ćemo najprije indeksiranjem pojedinačnih elemenata ubrzati performance sustava prilikom izvršavanja upita i analiza, a zatim korisniku omogućiti analizu pomoću pojedinačnih komponenti npr. izvještaja po gradovima; **spajanje informacija; konverzija grupa znakova** – gdje kod naslijeđenih sustava moramo pretvoriti stari EBCDIC standard u ASCII standard[31] (American Standard Code for Information Interchange). To je neslužbeni svjetski standard u računalima koji ima 128 kodnih kombinacija za kodiranje brojki, slova i interpuncijskih znakova; **pretvaranje mjernih jedinica** – jedna od posljedica globalizacije jest činjenica da danas mnoge tvrtke imaju podružnice po cijelom svijetu. EU ima metrički sustav mjernih jedinica dok na drugim velikim tržištima, koje se nalaze u drugim dijelovima svijeta, nije isti slučaj. Npr. USA sustav mjera za duljinu gleda se prema palcu (eng. inch), stopi, yardu i milji; **pretvorba formata vremena; sumiranje; restrukturiranje ključeva; deduplikacija** – proces transformacije gdje se više pojedinačnih zapisa koje se odnose na istoga npr. kupca, proizvod ili zaposlenika svedu na jedan zapis. Do takvih pogrešaka dolazi zbog greške prilikom upisa ili zbog toga što ne postoji kontrola prilikom upisa podatka (npr. kontrola OIB-a na ispravnost ili format broja znamenki).

Treba razjasniti na koji način treba provesti samu transformaciju i čišćenje podataka. Izbor se svodi na to treba li se koristiti skupim alatima za transformaciju ili ručnim tehnikama transformacije. Odgovor na to pitanje ovisi o više čimbenika, npr. imamo li vremena, novaca, ljudi i znanja koji bi upogonili alate za transformaciju, koliko izvornih sustava imamo, koliko je tih izvornih sustava naslijeđeno (starijom tehnologijom rađeni sustavi), što znači da nisu izrađeni u novom

[31] https://www.hrleksikon.info/definicija/ascii.html, 3.5.2020.

klijent/server okruženju, je li izrada skladišta podataka velik, srednji ili mali projekt. Vidimo da složenost posla i opseg transformacije utječe na odabir metoda transformacije i čišćenja podataka. U većini slučajeva kombinacija tih dviju metoda bit će najprikladnije rješenje.

Cilj alata je u potpunosti eliminirati ručne metode jer se poboljšava učinkovitost i preciznost, a najveća prednost alata je ta što alat omogućuje snimanje metapodataka. Metapodatci od toga alata postaju dio cjelokupne komponente metapodataka i međusobno dijele metapodatke s ostalim komponentama sustava, što olakšava ETL procese. Alati se podešavaju tako da se odrede parametri, definicije podataka, poslovna pravila, pravila za transformacijski alat i, ako je sve točno podešeno i napisano, alat obavlja sav posao. Ako se promijene poslovna pravila, promjene jednostavno unesemo u alat, pri čemu se i metapodatci prilagođavaju.

Korištenje ručnih tehnika sve je manje zastupljeno pojavom alata. Koriste se kod manjih projekata skladišta podataka. To su ručno kodirani programi i skripte koje izvršavaju svaku transformaciju podataka. Ova metoda podložnija je pogreškama jer nije automatizirana, a održavanje ovih programa je skupo uslijed promjena poslovnih pravila, kada se mijenjaju i pravila transformacije. Kod ručnih tehnika problem je i održavanje metapodataka jer (kad se promijene pravila transformacije), osim održavanja programa i skripti, treba održavati i metapodatke.

Učitavanje podataka (eng. Load) – spremanje podataka u skladište

Treća ključna aktivnost vezana za ETL proces jest učitavanje podataka. To je proces koji dolazi nakon ekstrakcije i transformacije podataka. Razlikujemo dvije generalne kategorije učitavanja podataka: masovno učitavanje svih podataka i pojedinačno učitavanje pojedinih zapisa ili tabela.

Prema P. Ponniah[32] razlikujemo tri modela učitavanja podataka koja ovise o trenutku kada se to učitavanje i dogodi. Nije isto učitavamo li podatke po prvi put u skladište podataka ili učitavanje radimo nakon što se inicijalni unos već dogodio.

1. Početno učitavanje – prvi put kada punimo skladište podataka (eng. *Initial Load*).
2. Postupno (djelomično) punjenje – učitavaju se promjene koje su se dogodile na izvornim sustavima u nekom razdoblju (eng. *Incremental Load*). Zovemo ga još i inkrementalno punjenje.
3. Potpuno punjenje (osvježavanje) – brisanje i učitavanje podataka događa se samo u nekim tablicama u skladištu podataka, što ga čini različitim od inicijalnoga punjenja jer kod inicijalnoga punjenja u sve tablice učitavamo podatke (eng. *Full Reload or Refresh*).

[32] Ponniah, P., (2008). Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.

Prilikom učitavanja podataka treba obrati pozornost na sljedeće:

- Vrijeme učitavanja podataka – proces koji treba napraviti kada isti neće utjecati na korisnike skladišta podataka, ali i na ostalo poslovanje poduzeća. Noćni *jobovi* su idealni za učitavanje podataka. To je proces koji s obzirom na količinu podataka dugo traje. Razbijanjem procesa na manje dijelove možemo ga ubrzati jer se tako neki dijelovi procesa mogu odvijati i paralelno. Također, s obzirom na to da proces dugo traje, trebalo bi najprije napraviti testove učitavanja da otkrijemo dužinu trajanja tog procesa, kako nam se ne bi dogodilo npr. da noćni *job* postane i dnevni *job*, što može usporiti redovne dnevne procese kada korisnici dođu na posao i počnu raditi.
- Predvidjeti greške kod učitavanja podataka – npr. može se dogoditi ako imamo izmjenu u relacijama podataka.
- Smještaj na serverima *stagea* i skladišta podataka (DW) – ako su *stage* i DW na istim serverima, nema problema s učitavanjem podataka. Međutim, ako su na odvojenim serverima, treba paziti kakva je propusnost i brzina mreže te utjecaj prijenosa (FTP, WEB ili linkani serveri i baze) na mrežu.
- Razlikovanje starih od novih podataka – ako nismo napravili klasifikaciju podataka unutar ETL procesa, susrest ćemo se s ovim problemom. ETL proces treba razlikovati koji su to podatci koje trebamo: nadodati (novi podatak), izmijeniti (promijenio se stari podatak, koji postaje povijesni) ili obrisati (tu se ne misli na brisanje povijesnoga podataka koji treba biti u arhivi, već na podatak za koji se u međuvremenu u izvornom sustavu ispostavilo da je pogrešan pa ga treba onda obrisati i u skladištu).

O načinima ili metodama kojima se podatci mogu osvježiti, tj. ažurirati (eng. *Applying Data*), P. Ponniah govori[33] da postoje četiri metode (Slika 11.), koje podatkovne datoteke ažuriraju u skladište podataka. **Punjenje** (eng. *Load*) – ako u ciljanoj tablici postoje podatci, oni će se najprije izbrisati, a zatim napuniti. U slučaju da je tablica koja se puni bila prazna, ista će se samo napuniti. **Nadopunjavanje** (eng. *Append*) – u ovom modelu se novi podatci samo nadodaju na postojeće podatke. U slučaju da je novi podatak duplikat, treba odlučiti je li njega potrebno ostaviti ili će se on odbiti procesom deduplikacije. **Destruktivno spajanje** (eng. *Destructive Merge*) – ako se primarni ključ dolazećega podatka poklapa s primarnim ključem postojećega, podatak se zamijeni. U slučaju ako je dolazeći podatak novi podatak, koji se ne poklapa s nijednim postojećim, podatak

[33] Ponniah, P., (2008). Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.

se samo dodaje u ciljanu tablicu. **Konstruktivno spajanje** (eng. *Constructive Merge*) – u ovom slučaju, prema primarnom ključu ostavlja se postojeći podatak, a podatak koji je novi doda se u novom retku i označi se da je on trenutno važeći.

Slika 11. Model apliciranja podataka prema P. Ponniah[34]

Metapodatci – podatci o podatcima

P. Ponniah[35] u svojoj knjizi kaže da metapodatke možemo usporediti sa „Žutim stranicama našeg grada“. U slučaju da trebamo informacije o trgovinama ili bilo kojim institucijama u našem gradu, ako nas zanima koje proizvode ili usluge prodaju, kako se zovu, gdje su smještene, najbolje je pogledati „Žute stranice“ i sve o tome pročitati. Možemo zaključiti da su „Žute stranice“ jedan direktorij s podatcima o svim bitnim djelatnostima i institucijama unutar grada. Na isti način govorimo i o metapodatcima. Jednostavno kažemo da su to podatci o našim podatcima.

Metapodatke, kao što prikazuje Slika 12., možemo podijeliti u tri glavne kategorije:

1. Radni podatci (eng. *Operational Metadata*) – podatci o podatcima koji su nam potrebni kako bismo podatke koje uđu u skladište mogli povezati s izvorišnim podatcima, što je potrebno krajnjem korisniku da točno zna s kojim podatcima radi.
2. Ekstrakcijski i transformacijski metapodatci (eng. *Extraction and Transformation Metadata*) – sadrže podatke o ekstrakciji podataka iz izvornih sustava kao što su: podatci

[34] Ponniah, P., (2008). Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.
[35] Ponniah, P., (2008). Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.

o metodama ekstrakcije, poslovna pravila za ekstrakciju podataka, frekvencije ažuriranja iz izvornih sustava, kao i o svim transformacijama koje su rađene na podatcima na *stageu.*

3. Podatci za krajnjega korisnika (eng. *End-User Metadata*) – metapodatci krajnjega korisnika jesu navigacijska karta skladišta podataka pomoću koje pronalaze podatke u skladištu podataka tako da se mogu koristiti svojom ustaljenom poslovnom terminologijom i tražiti informacije na uobičajene načine.

Entity Name:	Customer
Alias Names:	Account, Client
Definition:	A person or an organization that purchases goods or services from the company.
Remarks:	Customer entity includes regular, current, and past customers.
Source Systems:	Finished Goods Orders, Maintenance Contracts, Online Sales.
Create Date:	January 15, 2006
Last Update Date:	January 21, 2008
Update Cycle:	Weekly
Last Full Refresh Date:	December 29, 2007
Full Refresh Cycle:	Every six months
Data Quality Reviewed:	January 25, 2008
Last Deduplication:	January 10, 2008
Planned Archival:	Every six months
Responsible User:	Jane Brown

Slika 12. Primjer elemenata metapodataka za *entity Customer*[36]

Kome su metapodatci namijenjeni? Na Slici 12. vidimo da metapodatci opisuju aspekte podataka u skladištu podataka na jedan potpun i precizan način. Programeri i poslovni analitičari, graditelji sustava, metapodatcima sustav čine razumljiv svima koji se njime koriste i održavaju ga. Uvidom u podatke sa Slike 12 zaključujemo da metapodatci pomažu svim korisnicima sustava, ali isto tako pomažu i programeru, poslovnom analitičaru, menadžeru i projektnom timu. Možemo zaključiti da su nam metapodatci prijeko potrebni da bismo se sustavom mogli koristiti, dodatno ga razvijati, održavati i administrirati. Zaključujemo da postoji klasifikacija metapodataka na način koji razlikuje poslovne metapodatke od tehničkih metapodataka.

Korisnici trebaju **poslovne metapodatke** kako bi mogli dohvatiti podatke koje trebaju. Tu je bitno naglasiti da poslovni metapodatci daju podatke običnim jezikom koji se koristi u poslovnoj komunikaciji, a koju korisnici lako razumiju. Primjeri poslovnih metapodataka jesu: tko je vlasnik podatka, koja su poslovna pravila, predefinirani upiti, predefinirani izvještaji, poslovna pravila kod transformacije podataka, izvorni sustavi, kada je bilo zadnje ažuriranje podataka u skladištu podataka i još mnogi drugi.

[36] Ponniah, P., (2008). Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.

Tehnički metapodatci potrebni IT djelatnicima jesu podatci vezani uz pravila ekstrakcije, transformacije i čišćenja podataka, dizajna baze podataka, kada se dogodio zadnji uspješan *update*, pravila dizajna izvještaja i upita, kada su se izvršila periodična ažuriranja, je li se dogodio *backup* podataka, jesu li se arhivirali stari podatci iz skladišta podataka, koja su poslovna pravila korištena kod čišćenja podataka, redoslijed uvjetovanih procesa, pravila kod ekstrakcije podataka, dizajn OLAP-a i drugi. Kažemo da su tehnički metapodatci za IT profesionalce vodič koji im pomaže za daljnji razvoj, održavanje i administraciju skladišta podataka.

Nova uloga metapodataka u automatizaciji poslova u skladištu podataka javlja se s pojavom sofisticiranih programskih alata koji se koriste u automatizaciji pojedinih ETL procesa prilikom stvaranja skladišta podataka. Do tada su metapodatci bili organizirani kao pasivna dokumentacija unutar koje su bili zapisani podatci o podatcima. Profesionalni programski alati koji odrađuju pojedine procese unutar skladišta podataka sada i stvaraju metapodatke procesa koji odrađuju. To je ono što metapodatcima daje aktivnu ulogu u procesu stvaranja skladišta podataka jer programski alat sada koristi metapodatke koje je kreirao prethodni alat u procesu i taj postupak se događa sve do krajnjih alata za upite kojima se korisnici koriste na samom kraju procesa.
Metapodatke za korištenje osiguravamo preko repozitorija metapodataka. Repozitorij, osim spremanja podataka, osigurava i praćenje metapodataka od ulaska u sustav do izlaska iz sustava. Prateći taj tok, osigurava se integritet podataka. Međutim, izraditi repozitorij metapodataka predstavlja izazov. Kako smo gore napisali, programski alati prikupljaju metapodatke za vrijeme procesa koji se odvijaju. Prikupljene metapodatke dijele s drugim alatima koji pokreću druge procese. Vidimo da problem nije u stvaranju metapodataka već u integraciji metapodataka iz raznorodnih alata jer, s obzirom na to da još nema standardizacije pa svatko želi svoj dio kolača dobro naplatiti, svaki alat upravlja i sprema metapodatke različito. Kada se repozitorij metapodataka uspostavi, on će osigurati[37]: integraciju metapodataka u cijeloj organizaciji, prikupljanje i spremanje metapodataka u vremenskom slijedu (verzioniranje), vezu između različitih vrsta metapodataka, poveznicu između različitih sustava, poslovnu kopiju definicija, standardizaciju podataka (iste metapodatke iz različitih alata prikazat će na isti način), nadzor verzija promjena na razini strukture, razmjenu metapodataka iz jednoga alata u drugi, automatsku sinkronizaciju strukture podataka, pravila i događaja, veću kontrolu poslovnih odluka, podršku krajnjim korisnicima da dođu do podataka koje trebaju i da su isti prikazani iz poslovne perspektive koju poznaju, otkrivanje neusklađenosti, kao i razna mjerenja na razini strukture podataka.

[37] https://en.wikipedia.org/wiki/Metadata_repository, 26.04.2020

P. Ponniah[38] zaključuje (Slika 13.) da su metapodatci poput živaca jer različiti procesi generiraju metapodatke u skladištu podataka i te metapodatke koji su generirani jednim procesom (alatom) koristi drugi proces (alat). Zbog te funkcije, metapodatci u skladištu podataka zauzimaju središnji položaj jer omogućavaju komunikaciju između različitih procesa. Stoga P. Ponniah tvrdi da se metapodatci unutar skladišta mogu usporediti s ponašanjem živčanoga sustava.

Slika 13. Položaj metapodataka u skladištu podataka

OLAP

Transakcijske baze podataka vrlo učinkovito obrađuju podatke upravo zahvaljujući svom relacijskom modelu. Međutim, ostvarujući to svojstvo, relacijski model zbog velikoga broja relacija u transakcijskoj baze podataka postaju presloženima za učinkovito pregledavanje i analize podataka, što je drugo bitno i potrebno poslovno svojstvo dobre baze podataka. Ove analitičke nedostatke relacijskih baza priznao je i sam idejni začetnik relacijskih baza podataka Edgar F. Codd. Stoga je imao potrebu dati svoj doprinos u razvijanju boljega analitičkog tehnološkog rješenja je je 1993. godine napisao rad pod nazivom "Providing On-Line Analytical Processing to User Analysts" u kojem se prvi put spomenuo izraz OLAP (*on-line analytical processing*).

Definicija za OLAP, podržana od vijeća za OLAP [39] glasi: „On-line analytical processing (OLAP) je kategorija softverske tehnologije koja omogućava analitičarima, menadžerima i rukovoditeljima stjecanje uvida u podatke, brzim, dosljednim i interaktivnim pristupom. Podaci se prikazuju u

[38] Ponniah, P., (2008). Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.
[39] http://www.altaplana.com/olap/glossary.html, 25.04.2020.

širokom rasponu mogućih prikaza informacija koji su dobiveni iz neobrađenih podataka i odražavaju stvarnu dimenziju poduzeća na način kako je to korisnik shvatio“.

U svojoj knjizi R. Kimball i J. Caserta[40] govore da OLAP poslužitelji imaju dvije glavne funkcije. Prva funkcija jest osiguravanje izvršavanja upita koristeći se agregatnim tablicama, specijaliziranim indeksiranjem i skladišnom strukturom (dimenzijske i činjenične tablice), što povećava brzinu dohvaćanja upita. Druga bitna funkcija jest omogućavanje velike analitičke moći nad podatcima koristeći se MDX jezikom koji je i dizajniran za dohvaćanje podataka za složene analitičke obrade nad multidimenzionalnim objektima. Dalje ističu da je RDBMS baza podataka najbolji izvor za dimenzioniranje OLAP kocke iz skladišta podataka. Ne preporučuju izgradnju OLAP kocke iz transakcijskih izvora, iako sofisticirani OLAP alati imaju tu mogućnost. Njihova preporuka je osmisliti i izgraditi relacijsko skladište podataka i napuniti ga podatcima ETL tehnikama. Zatim iz takvog relacijskog skladišta podataka podatke prebaciti u dimenzijske kocke. Zašto nije dobro transakcijske podatke odmah premještati u OLAP opisuje P. Ponniah[41]:

- OLAP sustavu trebaju transformirani (očišćeni) i integrirani (objedinjeni) podatci jer OLAP sustav ne može podržati neusklađene podatke iz raznih transakcijskih sustava i kao takav dati točne rezultate analiza. Loši rezultati analiza jesu pogrešne poslovne odluke poduzeća.
- OLAP sustavu trebaju opsežni povijesni podatci, međutim, transakcijski sustavi čuvaju povijesne podatke samo u ograničenoj mjeri. To znači da će za potrebe OLAP - a trebati povijesne podatke iz transakcijskih sustava kombinirati s arhiviranim povijesnim podatcima i tek onda isporučiti OLAP sustavu. Ti nam podatci govore o trendovima, čime nam pomažu u boljem shvaćanju našega poslovanja.
- OLAP sustav radi s podatcima koji su posloženi u višedimenzijski model. Višedimenzijski model jest model koji sumira podatke kroz sve postavljene dimenzije. Izvući podatke i napraviti tu potrebnu agregaciju podataka iz različitih transakcijskih sustava nemoguće je jer da bi se podatci mogli zbrajati na različitim razinama u različitim kombinacijama, isti najprije trebaju biti konsolidirani.

Možemo zaključiti da kvalitetan OLAP model, bez skladišta podataka kao baze podataka, u kojoj smo pospremili sve potrebne, točne, potpune, pravovremene i konzistentne podatke ne postoji.

[40] Kimball, R., Caserta, J. (2004). The Data Warehouse ETL Toolkit: Practical Techniques for Extracting, Cleaning, Conforming and Delivering Data, Wiley

[41] P. Ponniah, (2008). Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.

Kada govorimo o **tipovima OLAPA,** u biti govorimo o različitim modelima pohrane podataka. Metodologija spremanja podataka drugačija je za različite tipove podataka, dok je dio koji se odnosi na obradu podataka za sve tipove isti: analitička obrada podataka u stvarnom vremenu.

Glavni tipovi OLAP[42] tehnoloških rješenja jesu: Multidimensional OLAP (MOLAP) – Cube based, Relational OLAP (ROLAP) – Star Schema based i Hybrid OLAP (HOLAP).

Osnovna razlika između MOLAP i ROLAP modela jest u tome što se u MOLAP modelu agregirani podatci i neagregirani podatci nalaze u višedimenzionalnoj bazi podataka (MDDB) na OLAP serveru u pripremljenim kockama gdje čekaju na upit korisnika. To znači da su agregirani podatci već unaprijed izračunati pa se isti neće morati stvarati kad se upit postavi, što će ubrzati vrijeme izvođenja upita. U ROLAP modelu se u srednjem, aplikacijskom sloju, nalazi analitički server u kojemu se kreiraju višedimenzionalni pogledi na podatke, dinamički, odmah nakon upita korisnika. Nakon upita korisnika prvo što učini srednji, aplikacijski sloj jest da SQL upit proslijedi prema skladištu podataka, koji onda vraća podatke istim putem nazad. Podatci u aplikacijskom sloju preoblikuju se u denormaliziranu strukturu poznatu kao zvjezdasta shema. Zvjezdasta shema (tablična struktura) potrebna je da bi se osigurala prihvatljiva analitička svojstva za podatkovnu analizu. Na prezentacijskom sloju korisniku se pruža višedimenzionalni prikaz podataka. Oba modela su na troslojnoj arhitekturi: podatkovni, aplikacijski i prezentacijski sloj. Odabrati relacijski (ROLAP) ili višedimenzionalni pristup (MOLAP), ovisit će o važnosti izvedbe (brzine) upita za korisnike i o tome koliko su kompleksni upiti korisnika. MOLAP je izbor ako želimo brži odziv upita i ako su upiti i analize kompleksnije.

HOLAP, hybrid OLAP - a, nastao je kao kombinacija ROLAP - a i MOLAP - a tako da je u jednoj arhitekturi objedinio njihove najbolje značajke. To znači da se HOLAP koristi i višedimenzionalnom i relacijskom bazom podataka. Relacijsku bazu podataka koristi zbog veće skalabilnosti pa se u njoj pohranjuju velike količine detaljnih podataka. Tehnologijom kocke koristi se za pohranjivanje agregiranih (sumiranih) podataka u unaprijed izračunate kocke, čime se postiže da su brži odzivi kod upita i lakše se izvode složeniji upiti i analize podataka. Kocke su sada i manje nego kod klasičnoga MOLAP-a jer se detaljniji podatci čuvaju u relacijskim bazama podataka. HOLAP, koristeći se tehnikom „drill through“ može iz kocke doći do podataka u relacijskoj bazi. Zaključno, prednosti hibrida nazvanog HOLAP jesu: bolja skalabilnost, brža obrada podataka i povećana fleksibilnost u pristupu izvornih podataka. Problem kod hibrida se očituje u činjenici da, osim što se koristi najboljim od oba svijeta, mogu se pokazati i slabosti upravo zbog pomiješanosti dvaju različitih svjetova (sustava).

[42] https://olap.com/types-of-olap-systems/, 8.5.2020

Karakteristike podataka OLAP sustava najbolje ćemo upoznati ako ih usporedimo s karakteristikama podataka koji se nalaze u skladištu podatka (Tablica 1.).

Tablica 1. Usporedba OLAP sustava i skladišta podataka u radu s podatcima

OLAP sustav	Skladište podataka (DW)
Pohranjuje i koristi se s mnogo manje podataka	Pohranjuje i koristi se s mnogo više podataka
Podatci u OLAP sustavu su sumirani podatci	Podatci u DW su podatci s najnižom razinom detalja
Podatci su fleksibilniji za obradu i analizu (dimenzionalni model i manje je podataka)	Manje fleksibilniji za obradu i analizu (relacijski model i veća količina podataka)
Podatci u OLAP sustavu prikazani su s aspekta poduzeća u cjelini	Podaci u DW modelirani su prema svojim poslovnim vertikalama

Višedimenzionalni model OLAP sustava osigurava nam različiti pogled na podatke. Postoje tri osnovne operacije koje provodimo prilikom obrade, tj. prikaza dimenzijskih podataka.

Rotacija podataka (eng. *Pivoting*) – ovom metodom se kocka okreće oko svoje osi kako bi se podatci mogli vidjeti iz različitih perspektiva (Slika 14.). To znači da su dimenzije koje su prije bile u redovima sada prikazane u stupcima ili obrnuto.

Slika 14. Rotacija podataka[43]

Raslojavanje i isijecanje podataka (eng. *Slice and Dice*) – metode možemo raditi horizontalno ili vertikalno ili možemo uzeti dio glavne kocke kao pod kocku. Raslojavanjem selektiramo jednu dimenziju koju želimo promatrati iz glavne kocke, pri čemu onda nastane pod-kocka (Slika 15.).

Slika 15. Raslojavanje podataka[44]

[43] https://cracklogic.com/olap-tutorial/, 12.5.2020.
[44] https://cracklogic.com/olap-tutorial/, 12.5.2020.

Metodom isijecanja podataka selektiramo dvije ili više dimenzije iz glavne kocke i formiramo novu manju pod-kocku (Slika 16.).

Slika 16. Isijecanje podataka[45]

Detaljiziranje podataka (eng. *Drill up and Drill down*) – detaljiziranje se (Slika 17.) može događati po hijerarhiji na gore (*Drill up ili Roll up*) ili po hijerarhiji na dole (*Drill Down*). Tako su, ako promatramo primjere sa slike, mobiteli i laptopi po hijerarhiji prema gore postali elektronički uređaji, dok su po hijerarhiji prema dole kvartali postali mjeseci.

Slika 17. Metode za detaljiziranje podataka (*Drill Up i Drill Down*)[46]

P. Ponniah[47] zaključuje što OLAP sustav donosi korisnicima:

- omogućuje višedimenzionalni i logički pogled na podatke
- interaktivnim upitima olakšavaju postavljanje upita, kao i složene analize podataka
- metodom „drill down“ omogućuje pregledavanje podataka u dubini do najsitnijih detalja i metodom „roll up“ sumiranje vrijednosti unutar jedne ili više poslovnih dimenzija
- osigurava izvršavanje vrlo kompleksnih izračuna i njihovu usporedbu
- omogućava im odličnu vizualizaciju podataka preko raznih smislenih načina vizualizacije koji uključuju razne grafikone, tablice, slike, interaktivne mape, *dashboarde* i sl.

[45] https://cracklogic.com/olap-tutorial/, 12.5.2020.
[46] https://cracklogic.com/olap-tutorial/, 12.5.2020.
[47] Ponniah, P., (2008). Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.

Rudarenje podataka (eng. Data Mining)

Poslovni značaj rudarenja podataka proizlazi iz činjenice što živimo u svijetu gdje se velika količina podataka svakodnevno prikuplja kroz razne poslovne i neposlovne sustave. Glavni ciljevi više nisu kako prikupiti podatke ili kako pregledati podatke. Glavno pitanje poduzeća postaje kako analizirati sve te podatke i tako doći do neotkrivenih novih trendova prije konkurencije. Velika količina prikupljenih podataka daje nam pravo da kažemo da je današnji svijet bogat podatcima, ali još uvijek siromašan znanjem koje ti podatci kriju. Kako iščupati neki novi poslovni obrazac iz tolike količine podataka, otkriva nam disciplina koju zovemo rudarenje podataka (eng. *Data Mining*). Ona se koristi mnogim tehnikama i automatiziranim alatima (aplikacijama) koji svojim razvijenim složenim algoritmima otkrivaju dragocjene informacije koje prikupljamo u bazu znanja poduzeća. Zbog svojih velikih mogućnosti, OLAP - om kao višedimenzionalnom bazom podataka koristimo se za razne poslovne analize, izvještavanje, ali i za rudarenje podataka. Skladište podataka je zbog svojih točnih, očišćenih, konsolidiranih, integriranih podataka najčešći izvor za dubinske analize, međutim treba naglasiti da nije i jedini izvor koji se može koristiti za *data minining*. Mogućnosti rudarenja podataka u raznih aspektima života velike su jer predviđanjem budućih trendova možemo djelovati u sadašnjosti i smanjiti rizik loših događaja, kao i povećavati šanse dobrih događaja u raznim aspektima života, pa tako i u poslovanju poduzeća.

Razlika između OLAP analize i rudarenja podataka koristeći se OLAP - om, leži u tome što kod složenijih ili jednostavnijih upita, predefiniranih izvještaja, korisnik ima prethodno znanje o tome što traži, on zna otprilike obrazac koji će dobiti, možda otkrije i neki novi obrazac ponašanja kupaca, ali ima znanja o podatcima u bazi kako bi nešto mogao pretpostaviti i onda upitima to pokušati dokazati ili osporiti. U ovim slučajevima vidimo da korisnik ima prethodno znanje da bi dobio očekivani rezultat. U slučaju rudarenja podataka iz OLAP -a ili bilo kojih drugih baza podataka, korisnik nema nikakvoga pojma o tome koji bi se novi obrasci i povezanosti između podataka mogli pokazati. Ovo se događa zato što je u igri velika količina podataka i korisniku je teško uočiti sve povezanosti između podataka, pogotovo ako povezujemo podatke iz različitih poslovnih sustava. Da bismo to znanje otkrili, moramo se koristiti aplikacijama (alatima) i tehnikama za rudarenje podataka. Za bolje razumijevanje možemo reći i sljedeće. OLAP analiza odgovara na pitanje „Tko su najboljih 50 kupaca u protekle tri godine?“ dok rudarenje iz OLAP baze može dati odgovor na pitanje „Tko su najboljih 50 kupaca u iduće dvije godine kojima možemo prodati naše proizvode ili usluge?“. Iz primjera vidimo da OLAP analiza odgovara na sva pitanja vezana uz prošlost poslovanja poduzeća. Tako korisnik razumije zašto se nešto dogodilo u prošlosti. Nasuprot tome, kod rudarenja podataka, vidimo sasvim drugi koncept. Rudarenjem pokušavamo otkriti i predvidjeti, na temelju podataka koje imamo u sustavu, budućnost poslovanja

poduzeća, te moramo imati odgovor na pitanje zašto će se nešto dogoditi. Odgovor na to pitanje u sebi krije novootkriveno znanje koje smo dobili rudarenjem podataka. Kod OLAP analize, analitičar je taj koji pokreće postupak, dok kod rudarenja podataka, analitičar priprema podatke za dubinsku analizu, a alat je taj koji pokreće postupak rudarenja podataka.

Možemo zaključiti da rudarenjem podataka (dubinska analiza podataka) predviđamo buduće događaje, spoznajemo nove činjenice, relacije, zakonitosti i odnose unutar podataka s većom sigurnošću nego da smo samo intuitivno, na temelju prošlosti, pokušali spoznati novi trend u poslovanju. Stoga kažemo da ti novi spoznati obrasci ne nagađaju, već predviđaju poteze poslovanja u budućnosti, sigurno s većim postotkom sigurnosti nego nagađanja (intuicija) koja su izraženija u klasičnoj OLAP analitici. Naravno, ovim ne prikazujemo intuiciju u poslovanju kao nepoželjnu, naprotiv, više kao činjenicu da je rudarenja podataka nadgradnja intuicije gdje rudarenjem u biti potvrđujemo, odbijamo ili korigiramo intuiciju.

Kada klasična OLAP analiza više ne može odgovoriti potrebama poslovnih analitičara i menadžera poduzeća, kad treba uključiti više varijabli u pretrage, koje upite čine još složenijim, koristimo se rudarenjem podataka sa svojim tehnikama i alatima. Vidljivo je da se ta dva procesa nastavljaju jedan na drugi pa govorimo o njihovoj komplementarnosti. Poduzeće u svom poslovanju razlikuje alate koji služe za praćenje poslovanje poduzeća od alata koji služe za dubinsko istraživanje podataka i otkrivanje novoga znanja. Za dubinsko istraživanje podataka koristimo se skupom alata (aplikacija) i tehnika za rudarenje podataka koji rade s velikim količinama podataka. Alati za rudarenje podataka imaju razvijene specijalne algoritme kojima otkivaju logičku povezanost između podataka s ciljem otkrivanja novih trendova, novih poslovnih obrazaca.

U svom radu Pejić Bach, M.[48] ističe da je cilj tehnika rudarenja podataka pronaći zanimljive obrasce ponašanja koje predstavljaju novo znanje. Tehnike rudarenja autorica kategorizira u dvije skupine:

1. Rudarenje podataka **predviđanjem** – metodama predviđanja koristimo se varijablama ili poljima u skupu podataka da bismo predvidjeli manje poznate ili buduće vrijednosti ostalih varijabli koje nas interesiraju. Predviđanje se događa na način da se na temelju prepoznatih odnosa i povezanosti podataka koje imamo u sustavu, isti dovedu u odnos za neki događaj ili stanje. Npr. u našim podatcima primijetili smo da povećanje cijena ima veze sa starosnom dobi, osobnim primanjima ili bračnim statusom pa želimo predvidjeti koji odnosi (povećanje cijena – dob, povećanje cijene – osobna primanja) imaju manji utjecaj,

[48] Pejić Bach, M., (2003). Data Mining Applications in Public Organizations, IEEE

što znači da će se, ako i podignemo cijenu proizvoda, kupci i dalje ponašati prema svojim istim obrascima kupnje, što znači da će i dalje kupovati proizvod iako smo podigli cijenu.

2. Rudarenje podataka **opisivanjem** – opisnim tehnikama korisnici otkrivaju nove obrasce i odnose među podatcima na dostupnim setovima podataka. Pozornost je na pronalaženju onih obrazaca koje opisuju podatke na način na koji ih korisnici mogu protumačiti. Taj princip pojašnjava opisne tehnike rudarenja podataka, kada se na temelju dostupnih setova podataka otkrivaju novi obrasci i novi odnosi među podatcima korištenjem alata i tehnika za opisno pronalaženje novih znanja.

Najčešće upotrebljavane tehnike rudarenja podataka:

Klaster analiza ili klasteriranje (eng. *Cluster analysis*) – klasteriranje znači da se u određenom skupu podataka prepoznaju i formiraju grupe koje imaju iste značajke. Značajke se određuju postavljanjem jedne ili više varijabli (npr. dobna skupina i visina primanja). To znači da se prema grupama može ići s istim marketinškim aktivnostima jer očekujemo da će se slični kupci ponašati na sličan način, što znači da možemo donijeti dobre poslovne odluke (npr. nabaviti proizvode koje taj klaster više koristi). Alatima za određivanje klastera koristimo se kada imamo velik broj varijabli i zapisa u bazi. Grupe su formirane tako da objekti unutar klastera imaju veliku sličnost u usporedbi jedni s drugima, ali su prilično različiti od objekata u drugim klasterima. Algoritam se također koristi ovim usporedbama za izračunavanje udaljenosti pojedinih korisničkih zapisa od centroida. Nakon izračuna udaljenosti, algoritam crta i granice klastera. Klasteriranjem dobijemo jednu širu sliku nad podatcima koji su nakon analize posloženi u manje podskupove podataka. Poznati primjer klaster analize jest segmentacija tržišta zbog planiranja marketinških kampanja.

Pronalaženje asocijacija (eng. *Associations analysis*) – ova tehnika najbolje se objašnjava prilikom kupovine u supermarketu i kaže da prisustvo jednoga proizvoda u košarici sugerira prisutnost drugoga proizvoda u toj istoj košarici. Kažemo da postoji povezanost između tih dvaju proizvoda, tj. da kupnja jednoga sugerira kupnju drugoga proizvoda unutar jednoga događaja, što je npr. kupovina u dućanu dana 15.6.2020. u 15:00 sati. Ovo je vrlo korištena tehnika rudarenja podataka jer imamo samo dva čimbenika koja se trebaju protumačiti, a to su čimbenik podrške i čimbenik sigurnosti. Rudarenjem podataka kod npr. kupovine računala i softvera, nalazimo da je čimbenik podrške 2%, a čimbenik povjerenja ili sigurnosti 60%. Čimbenik povjerenja od 60% znači da postoji 60% šanse da će kupac koji kupi računalo kupiti i softver. Podrška od 2% ukazuje da 2% svih transakcija u analizi pokazuje da se računalo i softver kupuju zajedno.

Otkrivanje sekvencionalnih uzoraka (eng. *Sequential Patten Discovery*) – ova tehnika dosta je slična tehnici „Pronalaženje asocijacija“. Razlika je u tome što ovdje otkrivamo obrazac proizvoda

koji se kupuju jedni nakon drugih, ali ne unutar jednoga događaja (npr. jedne kupovine), već se otkriveni povezani proizvodi kupuju u određenim razdobljima (dva mjeseca nakon, pet dana nakon itd.). Primjer povezanih proizvoda koji se kupuju jedan iza drugoga u određenom razdoblju mogu biti digitalni fotoaparat => printer u boji => memorijska kartica. Neki primjeri iz prakse kažu da je u 50% slučajeva uslijedila kupovina namještaja za dnevnu sobu nakon što najprije kupljene zavjese za dnevnu sobu. Znači, osobi koja je kupila zavjese može se ponuditi 10% popusta ako kupi namještaj i tako ubrzati i povećati prodaju proizvoda.

Klasifikacija (eng. *Classification*) – tehnika rudarenja koja pronalazi model koji opisuje i razlikuje klase podataka ili pojmove. Model se dobije tako da se prvo radi analiza na objektima za koje su oznake klase poznate. To se zovu „trening podatci“. Onda se taj model koristi da se predvide klase za objekte za koje oznaka klase nije poznata. Model se može predstaviti u različitim oblicima: *if-then* klasifikacijskoga pravila, stabla odlučivanja, neuronskih mreža ili matematičkih formula. Ovom tehnikom smanjujemo troškove marketinga jer možemo otkriti karakteristike kupca koje više ili manje utječu da neki proizvod kupe ili možemo vidjeti koje su karakteristike proizvoda (cijena, marka proizvoda, mjesto proizvodnje ili kategorija) utjecale da se neki proizvod više, manje ili nikako nije kupovao nakon organizirane TV prodajne kampanje.

Regresijska analiza (engl. *Regression analysis*) – iz istoga primjera možemo vidjeti koji je atribut najviše utjecao na prodaju proizvoda i mogli smo predvidjeti koliku će prodaju u kn ostvariti svaki proizvod nakon televizijskih reklama. To smo napravili na temelju prethodnih podataka o prodaji. To je primjer regresijske analize jer će u tom slučaju regresijski model predvidjeti brojčanu vrijednost koju tražimo. Možemo zaključiti da se regresijska analiza u rudarenju podataka koristi kao statistička metoda za predviđanje brojčanih vrijednosti podataka.

Neotkriveno znanje, u **procesu rudarenja podataka**, pokazuje se kroz dva oblika:

a) **„Otkrivanje odnosa između podataka“ (eng. *relationship*)** – rudarenje podataka otkriva odnose između podataka i zato nije za čuditi se što u supermarketima mlijeko stoji pored sira, a pivo blizu čipsa (grickalica). Možda je to znak da se taj lanac trgovina bavi rudarenjem podataka ili su samo primijenili dobre poslovne prakse (znanja) učeći od drugih ili im se činilo logično (intuitivno) da mliječne proizvode stave jedne blizu drugih ili su možda vlasnici supermarketa opažanjem vidjeli da muška populacija, dok gleda utakmicu, voli popiti pivo i jesti grickalice i pohitali na police staviti pivo pored čipsa.
b) **„Otkrivanje obrazaca ponašanja korisnika“ (eng. *patterns*)** – ako želimo otkriti kada se i koji korisnici kreditnih kartica najviše koriste karticama jer želimo da se još više koriste njima, tada ćemo rudarenje podataka usmjeriti na istraživanje baze podataka jer želimo

otkriti za što su sve korisnici upotrijebili kartice i kada. Otkrivajući te obrasce ponašanja, možemo usmjeriti marketing i s većom sigurnošću očekivati dobre poslovne rezultate.

Što god je uzrok poslovne odluke, u gornjem primjeru za slaganje proizvoda na police možemo zaključiti da se rudarenjem podataka najtočnije utvrđuju odnosi i obrasci ponašanja među proizvodima jer su isti izvedeni na temelju stvarnih događaja, praćenjem ponašanja korisnika preko baza podataka. Znanje izvedeno na takav način daje nam sigurnost da donesenu poslovnu odluku donesemo „bez razmišljanja“ i u vrlo kratkom vremenu. Na tržištu nam to donosi inovativnost, poslovnu prednost, veći profit, prepoznatljivost i niz drugih pogodnosti..

Proces rudarenja podataka iterativan je proces, kao što to prikazuju Slika 18.[49] i Prilog I. Iterativnost dopušta vraćanje na prethodne korake jer što više upoznajemo podatke koje ćemo istraživati, više se upoznajemo i s poslovnim problemom. To često rezultira promjenom definiranoga poslovnog cilja. Koraci kod procesa rudarenja[50] podataka jesu:

Definicija poslovnoga problema – u ovoj fazi jasno određujemo što želimo postići alatom za rudarenje podataka. To mora biti konkretno pitanje na koje ćemo na kraju procesa moći jasno dati odgovor. Primjeri dobro definiranoga poslovnog problema jesu: Koji nam se proizvodi prodaju zajedno? Imamo li prijevare kod korištenja kreditne kartice? Kad definiramo poslovni cilj, obično je to dio poslovanja koji treba unaprijediti jer nam neki vanjski pokazatelji na to ukazuju, npr. slaba prodaja, prijava zloupotreba kartica itd.

Priprema podataka – ovo je najzahtjevnija faza. Međutim, ne mora biti toliko zahtjevna ako je izvor podataka za rudarenje skladište podataka jer se zna da su podatci u skladištu podataka očišćeni i transformirani, što skraćuje ovaj dio procesa. Priprema podataka obuhvaća:

1. odabir potrebnih podataka – poslovni cilj koji smo definirali na početku projekta određuje relevantne podatke koje trebaju biti prikupljeni od strane stručnjaka za rudarenje podataka i poslovnoga analitičara. U ovoj fazi određujemo koje varijable izbacujemo iz analize, određujemo koje su varijable zavisne, a koje su varijable ciljne jer želimo dobiti konačan popisa varijabli kojima ćemo se koristiti da bismo izradili model.
2. transformaciju podatka – ako se koristi skladište podataka, ovaj posao uglavnom je obavljen. Također se dodatno izračunavaju maksimumi, minimumi, prosjeci i razne druge

[49] Pejić Bach, M. (2005). Rudarenje podataka u bankarstvu. Zbornik Ekonomskog fakulteta u Zagrebu, Vol. 3, No.1, str. 181 – 193.
[50] Pejić Bach, M. (2005). Rudarenje podataka u bankarstvu. Zbornik Ekonomskog fakulteta u Zagrebu, Vol. 3, No.1, str. 181 – 193.

varijable koje određuje poslovni analitičar analiziranoga područja. Nesumirani podatci se sumiraju, više varijabli možemo spojiti u jednu.

3. Uzorkovanje podataka – u ovom koraku izbacujemo podatke jer za izračun modela ne treba velika količina podataka, već manja količina podataka potrebnih za model. Podatci za uzorak izabiru se najčešće slučajnim odabirom. Nakon što smo izabrali uzorak za izradu modela, isti podijelimo na dva dijela. Prvim dijelom uzorka koristimo se za izradu modela, a drugi dio uzorka treba nam za testiranje modela jer na taj način provjeravamo učinkovitost modela.
4. Vrednovanje podataka – postupak u kojem se pronalaze i analiziraju netipične vrijednosti i prljavi podatci. Netipične vrijednosti su one vrijednosti koje se nalaze na krajnjim točkama spektra, a odnose se na isti atribut, znači ili je nešto previše ili premalo. Te vrijednosti možemo izbaciti ili ih zamijeniti prosjekom za taj atribut minimumom ili maksimumom. Vrijednosti varijable mogu se podijeliti i u razrede (npr. niska, srednja, visoka). Prljavi podatci su netočne vrijednosti (krivi unos u bazi podataka), vrijednosti koje nedostaju (nismo mogli unijeti podatke jer su nedostajali pa je ostalo prazno polje), mogu biti i nejasne definicije podataka pa ne znamo na što se podatci sada odnose (događaju se pri migracijama podataka). Također, te podatke treba ispraviti, izbaciti ili zamijeniti.

Modeliranje podataka – na početku modeliranja izrađuje se analiza atributa na temelju odabranih karakteristika atributa za koje smo predvidjeli da su nam potrebne za rješavanje postavljenoga cilja s početka procesa, npr. atribut proizvoda ima karakteristike (cijena, model, godina proizvodnje, mjesto proizvodnje itd). Zatim odabiremo metodu. Metoda ovisi o onome što nam je cilj analize. Metode rudarenja podataka dijelimo u tri kategorije, kao što prikazuje Tablica 2.

Tablica 2. Metode rudarenja podataka

Rb	Metode	Cilj	Tehnike
1	Metode otkrivanja	Traže pravilnosti u podatcima	Klaster analiza, pronalaženje asocijacija
2	Metode klasifikacija	Predviđaju grupe (kategorije, klase) atributa koji istražujemo	Stablo odlučivanja, neuronske mreže
3	Metode za predviđanje	Predviđaju numeričke vrijednosti	Neuronske mreže, regresijska analiza

Metoda se ne izabire „na prvu“ već se na konkretnom uzorku podataka uspoređuju metode i odabire se ona za koju procijenimo da će dati odgovor na postavljen cilj. Primjena metoda je vezana uz aplikacije (softver) za rudarenje podataka. Unutar mnogih aplikacija može biti sadržano više metoda za rudarenje podataka ili su specijalizirane samo za jednu. Izvršavanje rudarenja

podataka (odabrane metode) ključni je korak u procesu otkrivanja novih znanja. Mehanizam otkivanja znanja funkcionira tako da se odabrani algoritam (metoda) primijeni na podatke koje smo odabrali i pripremili. Rezultati su obrasci ponašanja i novi set odnosa između podataka raspoređeni u tablice. Dobivene rezultate vrednujemo, ispravljamo greške i opet puštamo izvođenje algoritma. Vrednovanje modela radimo s onim dijelom pripremljenih podataka kojima se nismo koristili kod izrade modela jer tako želimo provjeriti uspješnost modela koji smo postavili. Nakon što smo dobili rezultate, tražimo znanja (obrasce i odnose) koja su nam zanimljiva i koja nam pomažu da još bolje razumijemo svoje klijente, proizvode, profit i tržište na kojem djelujemo. Ovo je dio procesa u kojem ispitujemo dobivene rezultate i odabiremo one koji nam se čine obećavajućim za naše poslovanje.

Implementacija – ova faza odnosi se na prezentaciju rezultata i njihovo korištenje. Rezultati modela prikazuju se u obliku dobivenih zaključaka, tablica, grafikona. Poslovni analitičar koji je sudjelovao u radu na projektu i koji je stručnjak za istraživano područje jest osoba koja treba prezentirati dobivene rezultate zainteresiranim korisnicima, srednjem i visokom menadžmentu firme. Važnost prezentacije rezultata vrlo je važna jer je cilj korištenje i ugradnja dobivenih rezultata u svakodnevno poslovanje. Cilj je implementirati dobivene modele u informacijski sustav poduzeća, točnije u bazi podataka, za višekratnu upotrebu, a cilj je također dobiveni model kroz daljnje postupke rudarenja podataka stalno nadograđivati. Npr. novootkrivena znanja vezana uz prodaju dodatnih informatičkih proizvoda dobro je integrirati u bazu jer će pokazivati koje bi proizvode korisnik mogao sljedeće kupiti, ili npr. za koje bi bankarske usluge klijent mogao biti zainteresiran pa pri sljedećem ulasku korisnika u mobilnu bankarsku aplikaciju ista može nuditi korisniku usluge koje su se na temelju rudarenja podataka pokazale kao privlačne za moguće korisnike.

Zaključno, rudarenje podataka proces je učinkovitoga otkrivanja vrijednih i skrivenih informacija iz velike zbirke podataka poduzeća i eksternih izvora.[51] Na temelju tih informacija menadžeri poduzeća donose proaktivne poslovne odluke koje daju poduzeću prednost u poslovanju u odnosu na konkurentna poduzeća. Korištenjem rudarenja podataka i novim spoznajama bolje razumijevamo posao koji obavljamo. Iz boljeg razumijevanja posla, koristeći se novootkrivenim znanjima, poduzimamo nove, drugačije poslovne poteze s jedinim ciljem, a to je unaprjeđenje poslovanja.

[51] Bigus, J.P. (1996). Data Mining with Neural Networks

2.5 ČIMBENICI USPJEHA UVOĐENJA POSLOVNE INTELIGENCIJE U POSLOVANJU TVRTKE

Joe Ross, menadžer projekata u kompaniji Cognos, govoreći o uspjehu uvođenja projekta poslovne inteligencije u tvrtki kaže: „Bez dobre kombinacije poslovnih i tehničkih umijeća ljudi angažiranih na projektu poslovne inteligencije definitivno ste u nevolji. Imati samo žarku želju i dobru volju neće vam biti od velike pomoći. Trebaju vam umješni poslovni ljudi i informatičari sa zajedničkom vizijom.“ Howard Dresner, analitičar u kompaniji Gartner Inc. ima slično iskustvo kada, između ostaloga, kaže da je uspjeh uvođenja poslovne inteligencije u poslovanje tvrtke vjerojatniji kada informatičari i krajnji korisnici iskazuju podjednaku količinu ambicija u želji da promoviraju poslovnu inteligenciju te kada su obje strane spremne na suradnju kako bi stvorile vrijedna i održiva rješenja za poslovnu inteligenciju svojih kompanija. Također kaže da, na žalost, takvo ozračje u mnogim kompanijama još uvijek nije uspostavljeno.

Panian i suradnici[52] ističu pet čimbenika uspjeha uvođenja poslovne inteligencije u poslovanje tvrtke:

1. *Korisnike treba razumjeti*

Poslovni korisnici netehničkoga profila najraširenija su skupina korisnika u firmi koja se ne koristi informacijskim tehnologijama u svojemu radu već se koriste unaprijed pripremljenim izvještajima za svoj rad. Ovisni su o informatičarima koji im dostavljaju novije ili drugačije informacije od onih koje već imaju. S druge strane, **informatičari** poznaju tehnologije, oni su tu da udovolje potrebama poslovnih korisnika tako da im dostavljaju podatke iz baza podataka i educiraju ih o osnovnim funkcionalnostima tehnologija koje se koriste u firmi. Uglavnom ne znaju poslovnu logiku podataka koje dostavljaju i ne zanima ih zašto korisnicima trebaju informacije koje su zatražili. **Poslovni analitičari** imaju iskustva pri korištenju raznih softvera (npr. exel napredno korištenje), znaju mijenjati izgled izvještaja, dodavati nove kolone, redove i drugačijim sortiranjem stvarati nove izvještaje. Također su vješti u rukovanju sa sofisticiranijim softverima (OLAP alati) i alatima poslovne inteligencije. Na kraju, tu su **napredniji poslovni korisnici** koji se znaju koristiti potencijalima informacijske tehnologije i prvenstveno su usmjereni na poslovanje, a tehnologiju smatraju isključivo sredstvom za ostvarivanjem svojih poslovnih ciljeva. Rade s bazama podataka i iz njih sami izrađuju *ad hoc* izvještaje potrebne za njihov svakodnevni rad. Nema ih puno u firmi.

[52] Panian, Ž., i suradnici. (2007). Poslovna inteligencija – studije slučajeva iz Hrvatske prakse. Zagreb: Narodne novine d.d.

2. *Primjena paradigme broja klikova*

Jedan od ciljeva uspješne implementacije poslovne inteligencije jest da što veći broj korisnika dođe do informacija upotrebom što manjega broja klikova. Paradigma broja klikova govori o činjenici da je s većim brojem klikova, veći i trud koji djelatnik ulaže da dođe do željene informacije. Znači, cilj je smanjiti broj klikova da korisnici brže dolaze do potrebnih informacija. Govorimo o pet razina „broja klikova“ potrebnih da bi se dobila informacija koja nam je potrebna:

- Informacije za koje nije potrebno napraviti niti jedan klik. To su informacije koje se korisniku šalju automatski putem elektroničke pošte. Informacija sama pronalazi put do korisnika bez uloženoga truda da se dođe do nje.
- Izvještaj s pomoću jednoga klika tip je izvještaja u kojem korisnik generiranje izvještaja, koji je prethodno odabrao, aktivira klikom. To je ili unaprijed pripremljen izvještaj ili izvještaj koji generira aktualno stanje tj. najsvježije podatke. Trud koji korisnik uloži sličan je trudu koji upotrijebi dok dođe i klikne hiperlink koji otvara neku mrežnu stranicu.
- Izvještaji koji su generirani s pomoću dva klika, za razliku od prva dva modela, nude različite opcije generiranja izvještaja koristeći se raznim opcijama filtriranja podataka, redoslijeda prikaza podataka, *pivot exel* tablica. S obzirom na to da postoji mogućnost mijenjanja parametara prije generiranja izvještaja, takve izvještaje zovemo strukturiranim *ad hoc* izvještajima koji zadovoljavaju veće potrebe korisnika koji traže informacije. Ovakav tip izvještaja smanjuje potrebu za profesionalnim informatičarima koji tada svrsishodnije mogu rasporediti svoje vrijeme.
- Izvještaji generirani s tri klika jesu korisnici s malo kompleksnijim zahtjevima. Njihova poslovna potreba je da žele imati mogućnost da promijene sve što se trenutno prikazuje u nekoj bazi ili izvještaju, npr. dodavanje novih stupaca, seljenje stupaca u retke ili obrnuto, razna filtriranja itd. Alati koji pripadaju ovoj skupini jesu OLAP alati s pomoću koji možemo mijenjati aktualni prikaz podataka da bismo dobili potrebne informacije.
- Vješti napredni korisnici stvaraju izvještaje s pomoću četiri klika. To su korisnici čije stvaranje izvještaja počinje praznom stranicom koja korisniku otvara pristup bazi podataka. Korisnik u tom slučaju radi izvještaje koje god zaželi. Ti korisnici poznaju tehnologiju strukturiranih podataka i povezivanje relacijskih baza.

U svakoj je organizaciji uvijek veća količina korisnika koje će zadovoljiti izvještavanje s pomoću nula, jednog ili dva klika, stoga je praktičnije najprije razvijati infrastrukture koje će generirati upravo te izvještaje, a tek nakon toga generirati izvještaje s pomoću tri, četiri i više klikova, koji su namijenjeni naprednijim korisnicima. Na tom postupnom putu razvoja i učenja mnoge će

korisnike zainteresirati mogućnosti koje pruža poslovna inteligencija, što će dovesti do povećanja broja srednjih korisnika,a to posredno povećati uspjeh implementacije poslovne inteligencije. Povećavajući veću masu ljudi „koja bez toga ne može više raditi“ osiguravamo veću uspješnost uspostave projekta poslovne inteligencije. Bitno je najprije uspostaviti izvještavanje s nula, jednim ili dva klika zato što će tako u fazi mjerenja, prvoj fazi životnoga ciklusa poslovne inteligencije, biti uključen veći broj korisnika koji rade u svojim procesima i najbolje poznaju točnost unesenih podataka, što će pridonijeti većoj kontroli samih procesa i podataka, što kasnije osigurava naprednijim korisnicima koji se koriste izvještajima s tri, četiri i više klikova veću točnost pri otkrivanju novih trendova i odnosa među podatcima. Svaki novi trend dat će odgovor na pitanje zašto se nešto događa onako kako se događa. Napredniji korisnici, korištenjem izvještaja s tri, četiri i više klikova pripremaju analize potrebne da donositelji odluka u zadnjoj fazi životnoga ciklusa poslovne inteligencije, fazi dodavanja vrijednosti, definiraju strategiju poslovanja. Na temeljima tih analiza oni imaju mogućnost pokretanja novoga ciklusa i daljnjih mjerenja uspješnosti poslovanja.

3. <u>Napredniji korisnici jesu korisnici, ali i proizvođači informacija</u>

U proces mjerenja uspješnosti poslovanja poželjno je uključiti što više ljudi. Tada će se dogoditi veći broj korisničkih zahtjeva prema informatičarima, kao glavnim proizvođačima informacija u tvrtki, što će dovesti do zagušenja IT odjela. Informatičari po prirodi posla nisu upućeni u sve finese poslovanja pa u većini korisničkih zahtjeva neće moći predvidjeti kakve će sve informacije korisnici trebati, što će dovesti do više iteracija u traženju, a posljedica je veće zagušenje odjela informatike. Rješenje su upravo napredniji korisnici i poslovni analitičari koji zbog svojih sposobnosti izvlačenja podataka iz baza podataka i poznavanju tih finesa poslovanja moraju uskočiti i odigrati u jednom razdoblju životnoga ciklusa poslovne inteligencije dvostruku ulogu, gdje postaju i konzumenti, ali i proizvođači informacija. Tako će se smanjiti pritisak na IT odjel, što će osigurati dobro funkcioniranje sustava poslovne inteligencije.

4. <u>Uspostavljanje kulture mjerenja</u>

„Ne možeš upravljati nečim što ne mjeriš“ (*You can’t manage what you don’t measure*)[53] – kažu Peter Drucker i W. Edwards Deming. Uspostavljanje kulture mjerenja jedan je dugotrajan proces i kao takvog ga treba razvijati, njegovati i konstantno unaprjeđivati. Panian i suradnici[54] govore o

[53] https://hbr.org/2012/10/big-data-the-management-revolution, 17.10.2020.
[54] Panian, Ž., i suradnici. (2007). Poslovna inteligencija – studije slučajeva iz Hrvatske prakse. Zagreb: Narodne novine d.d.

tom dugotrajnom procesu uspostave mjerenja kao dijelu opće korporativne kulture, koji se ostvaruje tako da dojavljujemo korporativnu strategiju svakom pojedinom zaposleniku te ju razrađujemo na način da se strateški ciljevi prikažu jasnim i nedvosmislenim pokazateljima uspješnosti. Dalje, treba kontinuirano objavljivati informacije o uspješnosti ostvarivanja poslovne strategije svim zaposlenicima. Na kraju, dobro je nagraditi zaposlenike koji dostižu i prestižu postavljene ciljeve poslovanja. Cilj je stvoriti osjećaj odgovornosti zaposlenika da pridonose ostvarivanju postavljenih ciljeva koji povećavaju uspješnost poslovanja, npr. isplata poticaja što ranije prije sjetve (avansna isplata) jedan je takav cilj Agencije koji povećava uspješnost našega poslovanja na zadovoljstvo naših korisnika.

5. *Razvoj poslovne inteligencije strateško je opredjeljenje tvrtke*

Da bi svoje poslovne informacije pretvorili u znanje koristeći se sustavom poslovne inteligencije, uspjeh može biti zajamčen jedino i samo ako je to strateški projekt, što znači da iza njega stoji najviši menadžment tvrtke. Uspostava sustava poslovne inteligencije podrazumijeva i nabavku skupih alata koje svoje opravdanje mogu naći jedino ako je implementacija strateška odluka firme koja želi cjelovito rješenje za cijelu tvrtku, a ne projekt ograničiti samo na neke uže organizacijske skupine. Kad krenemo utvrđivati podatke i iz njih tražiti informacije, shvaćamo koliko su nam podatci u tvrtki povezani i da parcijalna rješenja zapravo ne vode nikud. Jedino sagledavanje svih podataka u organizaciji može iznjedriti prave informacije iz kojih možemo dobiti potrebno znanje koje ugrađujemo u strategiju vođenja firme. Jednom kad povežemo sve podatke unutar poduzeće raste potreba da se ti podatci prošire i s podatcima iz vanjskoga okruženja koji su bitni za naše poslovanje. Taj automatizam koji se događa da „podatak traži podatak“ da bi informacija bila potpuna, a znanje cjelovitije jasan je znak da uspostava poslovne inteligencije treba biti strateška odluka jer obuhvaća sve podatke kojima se bavimo. Ta glad za širenjem i povezivanjem podataka u mrežu podataka sasvim je prirodna i normalna za organizacije koje svoje poslovanje shvaćaju ozbiljno i koje žele biti ozbiljan konkurent u svojoj grani proizvodnje ili usluge kojom se bave. Tko to ne shvati tako, posao će obaviti polovično, što sigurno neće dobro utjecati na krajnji uspjeh samoga projekta uspostave poslovne inteligencije, ali i na uspješnost poslovanja tvrtke. Iz svega je vidljivo da projekt uspostave poslovne inteligencije nije „mali zalogaj“. Mora biti pametno upravljan tako da na kraju zahvati cijelu tvrtku. Taj projekt je svakako visoki kriterij i cilj koji tvrtka strateški postavlja i kojim će onda sigurno ostvariti i zadovoljavajuće učinke na svoje poslovanje.

3 PROCES UVOĐENJA SUSTAVA ZA ANALITIČKU OBRADU PODATAKA ZA ISPLATU POTICAJA U POLJOPRIVREDI

3.1 PROCESNI PRISTUP ISPLATI POTICAJA U POLJOPRIVREDI

U sklopu operativne provedbe mjera ruralnoga razvoja, izravne potpore i zajedničke organizacije tržišta poljoprivrednik/korisnik podnosi zahtjev za potporu Agenciji koja utvrđuje jesu li ispunjeni svi uvjeti propisani EU i nacionalnim pravilima, što uključuje određene provjere prema odgovarajućim specifičnim propisima kojima se uređuju pojedine mjere u okviru kojih se zahtijeva potpora. Provjere obuhvaćaju: administrativnu kontrolu – provodi se nad svim zahtjevima i kontrolu na terenu – provodi se na uzorku zahtjeva ovisno o mjeri. Nakon provedenih kontrola, sljedeći korak jest odobravanje zahtjeva i na kraju isplata potpora na račune podnositelja zahtjeva, sukladno odobrenim iznosima. Funkcija Agencije također je knjiženje obveza i izvršenih plaćanja iz poljoprivrednih fondova EU - a. O svim tim aktivnostima Agencija izvještava Europsku komisiju (EK) u obliku mjesečnih, tromjesečnih i godišnjih izvješća. Također se vodi i evidencija svih potraživanja, odnosno evidencija o svim korisnicima potpora koji zbog počinjene nepravilnosti ili uslijed administrativne greške postanu dužnici. Sva potraživanja od dužnika uz računovodstvene knjige evidentirana su i u knjizi dužnika.

Na Slici 19. (Prilog II.) prikazan je poslovni proces koji se odvija unutar IAKS-a. Unutar ovoga prikaza procesa prikazane su međusobno povezane aktivnosti u jedinstven poslovni proces. Aktivnosti su prikazane kroz tri grupe procesa. Unutar svake grupe procesa postoje aktivnosti koje su vezane uz svoju proceduru koja detaljno pojašnjava aktivnosti procesa, dok s lijeve strane pratimo dokumentaciju i podatke koji ulaze i izlaze iz sustava. Glavne aktivnosti unutar cjelokupnoga procesa Agencije za IAKS programe jesu: ažuriranje svih potrebnih podataka kroz registre, prikupljanje jedinstvenoga zahtjeva za potporu, odobravanje zahtjeva (uključuje vizualnu kontrolu, kontrolu četiri oka, kontrole višestruke sukladnosti i kontrolu na terenu), dodjela prava na plaćanja, izračun potpora, izvršenje plaćanja i računovodstveno evidentiranje plaćanja. Poslovni proces je vrlo kompleksan zbog velikoga broja potpora i količine kontrola koje se trebaju provesti i zbog različitih sudionika koji u procesu imaju svoje funkcije i zadatke, kao što prikazuju Slika 20. i Slika 21. (Prilozi III. i IV.). Glavni sudionici u procesnom modelu prikupljanja jedinstvenoga zahtjeva za potporu, obrade, isplate i knjiženja potpora jesu: poljoprivrednici, djelatnici Agencije, vanjske institucije (FINA, Ministarstvo financija, Ministarstvo poljoprivrede, ovlaštena kontrolna tijela, Hrvatska poljoprivredna agencija, MUP, EU).

3.2 PODRUČJA PRIMJENE SUSTAVA

Zajednička poljoprivredna politika (ZPP) jest politika koju provodi EU a ciljem osiguranja samodostatnosti proizvodnje hrane, kao i opskrbe potrošača s ciljem osiguranja kvalitetnoga životnog standarda poljoprivrednika i jednakomjernoga razvoja ruralnih područja u državama članicama EU - a. U svrhu ostvarivanja ciljeva ZPP-a EU je osnovao posebne fondove iz kojih se vrši financiranje poljoprivrednih programa. Zadaća Agencije je operativna provedba tih programa u koje spadaju mjere zajedničke organizacije tržišta, ruralnoga razvoja i izravne potpore, te provedba određenih delegiranih funkcija za potpore u ribarstvu. Na Slici 22. prikazane su glavne zadaće (poslovi) Agencije. Zeleno označena polja pokazuju poslovne procese za koje smo najprije organizirali izvještajni sustav za isplatu poticaja u poljoprivredi.

Slika 22. Poslovni procesi Agencije (skica autora)

Koncept OLAP izvještajnoga sustava Agencija će primijeniti na cjelokupno poslovanje. Projekt je podijeljen u više faza, prema poslovnim područjima. Svako skladište podataka ima svog vlasnika koji može biti odjel, sektor ili pojedina osoba. U Agenciji će se implementirati OLAP kocke za:

1. poslovne vertikale Agencije (*core business* Agencije): izravna plaćanja, ruralni razvoj, tržišne potpore, ribarstvo, registri, kontrola na terenu i isplata potpora
2. vertikale za potporu poslovanja Agencije: računovodstvo i financije i aplikacija HR plus (GO, evidencija djelatnika, radna mjesta, poslovna putovanja ….).

Program izravne potpore obuhvaća dvanaest mjera koje se odnose na isplatu potpora za: osnovno plaćanje; zeleno plaćanje – plaćanje za poljoprivredne prakse korisne za klimu i okoliš

(raznolikost usjeva, ekološki značajne površine, održavanje postojećih trajnih travnjaka); preraspodijeljeno plaćanje; mladi poljoprivrednik; proizvodno vezana plaćanja za krave u proizvodnji mlijeka, za tov junadi, za krave dojilje, za ovce i koze, za povrće, za voće, za šećernu repu i za krmno proteinske usjeve. Navedene mjere izravne potpore dio su reformskoga paketa Zajedničke poljoprivredne politike EU – a za razdoblje 2015. - 2020. Dodatno, iz državnoga proračuna financiraju se i plaćanja za mjere državne potpore: maslinovo ulje, duhan, mliječne krave, rasplodne krmače i očuvanje izvornih i zaštićenih kultivara. Pored programa izravnih plaćanja, poljoprivrednik može za iste površine, uz zadovoljenje propisanih uvjeta, ostvariti plaćanja iz **Programa ruralnog razvoja** (tzv. IAKS mjere ruralnoga razvoja) koji ide kroz četiri mjere (M) i obuhvaća 26 različitih operacija (potpora). Četiri mjere koje provodimo jesu: M10 poljoprivreda, okoliš i klimatske promjene, M11 ekološki uzgoj, M13 plaćanja područjima s prirodnim ili ostalim posebnim ograničenjima i M14 dobrobit životinja. S obzirom na količinu programa, glavni cilj Agencije jest kvalitetno i u zadanim rokovima obaviti sve provjere prihvatljivosti jedinstvenoga zahtjeva korisnika programa kako bi ispravno odobrila sve zahtjeve korisnika te izvršila plaćanja. Načini ostvarenja toga cilja vidljivi su u Tablici 3.

Tablica 3. Načini ostvarenja programa (izvor: Agencija)

Ostvarenje programa	Pokazatelj rezultata poslovanja	Ciljna vrijednost u 2019.
Provedba administrativne kontrole i kontrole na terenu	Administrativna kontrola svih zahtjeva	mora biti provedena na 100% dobivenih zahtjeva
	Kontrola na terenu površina i stoke provedena u zadanom postotku	mora biti napravljena na minimalno 5% zahtjeva
	Kontrola na terenu ispunjavanja uvjeta višestruke sukladnosti	minimalno na 1% obveznika
	Kontrola na terenu daljinskim istraživanjem	minimalno provedena na 60% od svih kontrola površina
Isplata potpore korisnicima	Izvršene isplate za sve odobrene zahtjeve	isplata mora biti provedena za 100% odobrenih zahtjeva
	Smanjen broj neuspjelih transfera	0,10% s tendencijom smanjenja
Provedba računovodstvenih postupaka	Smanjen broj greški utvrđen provjerama i usklađivanjem	0,10% s tendencijom smanjenja u idućim godinama
	Dospjeli dugovi naplaćeni	45% s tendencijom povećanja u idućim godinama

Jedinstveni zahtjev koji podnosi korisnik obuhvaća mjere izravne potpore i IAKS mjere ruralnoga razvoja. Za navedenu provedbu programa Agencija je izgradila vrlo složenu informatičku podršku te uspostavila integrirani administrativni i kontrolni sustav (IAKS) koji obuhvaća niz standarda i procesa definiranih na razini EU nužnih za pravilnu provedbu programa koji se sastoji od:

jedinstvene identifikacije korisnika izravne potpore i IAKS mjera ruralnoga razvoja koji podnose zahtjeve, sustava za identifikaciju poljoprivrednih parcela i evidenciju uporabe poljoprivrednoga zemljišta u digitalnom grafičkom obliku (ARKOD sustav), sustava za identifikaciju i registraciju životinja (JRDŽ), sustava za identifikaciju i registraciju prava na plaćanje, sustava za podnošenje zahtjeva, administrativne kontrole zahtjeva i kontrole na terenu. Svi navedeni elementi IAKS-a nužni su za ispravnu kontrolu zahtjeva za potpore. Agencija provodi kontrolu ispunjavanja uvjeta prihvatljivosti za potporu putem administrativne kontrole i kontrole na terenu, što obuhvaća provjeru točnosti podataka u jedinstvenom zahtjevu, sukladnost s uvjetima prihvatljivosti za pojedine mjere potpore i poštivanja pravila višestruke sukladnosti.

3.3 PROCES RAZVOJA SUSTAVA

Prije pokretanja BI projekta unutar Agencije organiziran je sastanak s visokim menadžmentom gdje smo predstavili ciljeve projekta. Ako se radi BI sustav na razini čitave Agencije, bitno je imati sponzorstvo na najvišoj razini menadžmenta. Projekt je prihvaćen i odobren od strane ravnatelja i menadžmenta Agencije pa smo krenuli u traženje izvođača i implementaciju projekta poslovne inteligencije. Kod izrade DWH/BI sustava treba se držati strogo određenih protokola i pravila koje propisuje odabrana metodologija. To znači da je pristup izrade DWH/BI sustava vrlo formalan. U svijetu postoje dva dominantna procesa kod uspostave ovakvih sustava: metodologija po Inmonu i metodologija po Kimballu. Izvođač odabran za ovaj projekt koristi se metodologijom po Kimballu. Njihovo je iskustvo da je ta metodologija jednostavnija u tehničkom smislu i iterativnija što znači da se sustav lakše nadograđuje. Prema toj metodologiji proces razvoja BI sustava u Agenciji ima pet faza (Slika 23.).

Slika 23. Metodologija implementacije prema Kimballu (izvor: Agencija)

Aktivnosti koje su se događale unutar ovoga projekta, prema Kimballovoj metodologiji, definirali smo WBS-om koji je prikazan u Tablici 4. (Prilog V.), gdje su aktivnosti hijerarhijski prikazane.

Prva faza, uspostava projekta, faza je koja se susreće uglavnom na svim projektima. U toj fazi dogovorili smo osnovne parametre rada i na koji ćemo način funkcionirati unutar projekta:

1. Dogovorili smo uloge i odgovornosti na projektu, kako prikazuje Tablica 5., (Prilog VI.).
2. Održavanje koordinacije projektnoga tima – koordinacija će se održavati svaka dva tjedna. Prisutni na koordinaciji: voditelji projekta, glavni poslovni analitičar, BI stručnjak i vlasnici poslovnih područja.
3. Dokumentacija na projektu – projektna dokumentacija: vremenski plan, wbs, zapisnici, korisnički zahtjev, funkcionalna specifikacija, tehnička specifikacija: specifikacija arhitekture sustava i upravljanje sustavom, testovi prihvaćanja funkcionalnosti: izjava o alfa testiranju i izjava o beta testiranju, korisničke upute i izjava o primopredaji.
4. Potrebe vezane uz infrastrukturu: razvoj sustava se odvija na infrastrukturi izvođača, testiranje sustava na infrastrukturi Agencije.
5. Ključni parametri za održavanje radionica poslovne analize: radionice su cjelodnevne, 10 – 15 sati uz pauze. Treba osigurati relevantne sugovornike a to su ključni korisnici (vlasnici poslovnih područja). Na uvodnoj radionici cilj je upoznati se s organizacijskom strukturom, poslovnim područjima Agencije i prepoznati glavne izvore podataka. Radionice će biti organizirane prema poslovnom području (1 do 4 radionice). Ciljevi prve radionice su prepoznati procese, terminologiju, dostupne podatke i koji su zahtjevi za izvještavanjem. Na ostalim radionicama, na osnovi zapisnika i informacija od korisnika, finalizirat će se zahtjevi za izvještavanjem, rječnik pojmova, matrica mjera i dimenzija, standardni izvještaji. Usuglašeni zapisnici s radionica temelj su za kreiranje funkcionalne specifikacije. Isporuka faze poslovne analize jest funkcionalna specifikacija koja se usuglašava i potpisuje prije početka razvoja.

Druga faza procesa, unutar Kimball metodologije, jest faza poslovne analize koja je ključna faza BI projekta jer je projekt uspostave izvještajnog sustava projekt koji je orijentiran poslovnim procesima i poslovnim korisnicima. O pravilnom prepoznavanju i definiranju potreba korisnika ovisi uspjeh čitavoga projekta. Stoga je bilo potrebno osigurati s jedne strane ključne poslovne korisnike koji poznaju sustav i svoje potrebe za podatcima, dok je s druge strane trebao iskusan BI stručnjak koji će, koristeći se primjerima dobre prakse u iteracijama analize s vlasnikom procesa i poznavanjem metodologije, doći do svih potrebnih informacija s pomoću kojih će napraviti kvalitetnu funkcionalnu specifikaciju i pri tome stvoriti jasnu definiciju svih potrebnih podataka. Jasnu definiciju opsega poslovnih procesa i svih pojmova (podataka) definirali smo u sklopu ove

faze u dokumentima: popis korisnika, popis izvornih sustava, rječnik pojmova, definicija poslovnih procesa, bus matrica, definicija podataka za skladište podataka i podataka za ODS.

Na radionicama poslovne analize, u suradnji s vlasnikom procesa, išli smo do najniže hijerarhije podataka, vrlo niske razine detalja, čime smo htjeli osigurati sveobuhvatniji pregled nad podatcima za potrebe izvještaja i analize. Ta definicija spuštala se sve do razine redaka i kolone u tablici, stoga su funkcionalne specifikacije tehnički napisane. Na tim radionicama prepoznavali smo dimenzije i mjere i otkivali veze unutar njih. Postojanje veze između mjere i dimenzije znači da postoji mogućnost analize pojedine mjere prema pojedinim dimenzijama koje onda predstavljaju različiti pogled za te mjere. Ta veza može biti ostvarena jedino ako ona postoji i u izvornom sustavu. To je prikazano u dokumentu bus matrica. Isporuka faze poslovne analize jest funkcionalna specifikacija s gore nabrojanom dokumentacijom potvrđenom od vlasnika procesa.

U **trećoj fazi,** osim dimenzijskoga modeliranja i ETL razvoja, događaju se paralelno i aktivnosti vezane uz kreiranje arhitekture sustava, podizanje infrastrukture i razvoj samih izvještaja. Ovdje je bitno naglasiti da nam je cilj bio za sve poslovne procese Agencije kreirati jedinstveni centraliziran i automatiziran model prikupljanja podataka. Stoga smo ovim projektom postavili *proof of concept* (arhitekturu) sveobuhvatnoga centralnog izvještajnog sustava i definirali samo one podatke za kocku koji pokrivaju poslovno područje IAKS potpora (SIP): program izravnih plaćanja i program IAKS mjera ruralnoga razvoja.

Četvrta faza jest testiranje sustava i isporuka. Prema dokumentu „Test case scenarij“ koji je dostavio izvođač sustava, testirani su budući korisnici sustava. Neki od testova iz „Test case scenarija“ bili su: spajanje na OLAP kroz Excel alat, priprema izvještaja, priprema izvještaja s grafom, provjera dobivenih podataka s ključnim korisnicima. Nakon nekoliko iteracija testiranja, uslijed kojih smo pronašli *bugove* na sustavu i nejasnoće koje je izvođač popravio i dodatno pojasnio, potpisom na dokument „Izjava o korisničkom testiranju“ prihvatili smo OLAP izvještajni sustav za SIP poslovno područje. U koraku Isporuka sustava, u sklopu ove faze, aktivnosti izvođača bile su sljedeće: kreiranje uputa za korištenje sustava, edukacija ključnih korisnika Agencije i isporuka sustava u produkcijsko okruženje.

Zadnja, **peta faza**, jest faza održavanja i nadgradnje sustava u kojoj se i danas nalazimo. Kako smo već napomenuli, cilj je Agencije da sve poslovne vertikale preko postavljenoga modela dovede do ODS-a i OLAP kocki tako da osigura jedinstveni koncept izvještavanja i analize za svoje poslovanje. Do sada smo, osim programa izravnih potpora, u OLAP uveli druge poslovne vertikale vezane za ruralne programe i isplate potpora. U tijeku su projekti nadogradnje sustava vezani i za ostale poslovne vertikale. Nadogradnja sustava ne događa se samo uvođenjem nove poslovne vertikale unutar postavljenoga modela već i uslijed promjena poslovnih procesa za

poslovne vertikale koje već i jesu u tom modelu. Također, korištenjem sustava uočavaju se i propusti koji su se dogodili prilikom prijašnje implementacije. Iz svega navedenoga možemo zaključiti da je faza održavanja i nadogradnje sustava jedan kontinuiran proces između naprednih korisnika i *database* programera Agencije s jedne strane i BI stručnjaka s druge strane.

Implementacija ODS-a i OLAP-a u Agenciji nastaje postupno, kroz jedan proces serije implementacija (eng. *sprints*), prema Scrum metodologiji razvoja softvera. Taj proces kontinuirane nadogradnje i održavanja naslanja se na akreditirani proces razvoja softvera u Agenciji (Slika 24.). Svaka nova promjena u sustavu koja se implementira kroz održavanje ili nadogradnju sustava (funkcionalna specifikacija) može u sebi nositi utjecaj na ODS i OLAP sustav. Ako utjecaj postoji, pokreće se proces prikazan na Slici 24., gdje napredniji korisnik napiše korisnički zahtjev u suradnji s *database* programerima i voditeljima softverskih projekata Agencije. Korisnički zahtjev proslijedi se BI stručnjacima koji na radionicama s ključnim vlasnicima podataka (procesa) prikupe potrebne informacije i napišu funkcionalnu specifikaciju. Nakon prihvaćanja funkcionalne specifikacije od strane djelatnika Agencije, u skladu s planom i prioritetima razvoja softvera tima za OLAP kod izvođača, *storyji* iz funkcionalne specifikacije ulaze u dvotjedne *sprintove*. Nakon završenoga razvoja od strane izvođača i testiranja od strane djelatnika Agencije, nove nadogradnje za ODS i OLAP postavljaju se na produkciju.

Slika 24. Proces održavanja i nadogradnji razvoja OLAP-a u Agenciji (izvor: Agencija)

3.4 UVOĐENJE SUSTAVA U RAD

U početcima rada Agencije sustav potpora bio je jednostavniji. To znači da je bilo manje potpora, a po pojedinoj potpori nije bilo toliko uvjeta prihvatljivosti (kontrola). Mnoštvo raznovrsnih verzija izvještaja koji su generirani od strane vanjskoga izvođača, prema tadašnjem konceptu izvještavanja (Slika 25.), bili su izravno spojeni na transakcijske sustave i korisnici su mogli istima pristupiti kroz poslovnu aplikaciju „Upisnik“, modul „poslovno upravljanje“ (Slika 26.), kao i preko *report managera* koristeći se SQL server/reporting services, (Slika 27.).

Slika 25. Prvi koncept poslovnoga izvještavanja u Agenciji (izvor: Agencija)

Slika 26. Izvještaji kroz modul „Poslovno upravljanje“ (izvor: Agencija)

Slika 27. Izvještaji via SSRS, SQL Server/Reporting Services (izvor: Agencija)

Vremenom je broj predefiniranih izvještaja postajao sve veći što je počelo usporavati sustav, a pri pozivanju kompleksnijih izvještaja i potpuno ga blokirati, pa se krenulo u traženje novih rješenja izvještavanja. Povećanje kompleksnosti potpora i administrativnih kontrola istih od strane djelatnika Agencije mogla se riješiti jedino eksportima sirovih podataka iz baza na kojima su se zatim radile razne funkcionalne provjere, a napredniji korisnici i izvještavanja. Sve je to utjecalo na povećanje potreba za informatizacijom poslovnih procesa. Stoga se Agencija okreće novim modelima u razvoju svojega izvještajnog procesa i zapošljava svoje *database* programere s ciljem razvoja novoga koncepta izvještavanja jer vanjski izvođač više nije stizao izrađivati predefinirane izvještaje onim tempom kako je zahtijevao vlasnik poslovnoga procesa.

Zapošljavanjem svojih *database* programera dodatno smo osigurali da znanje o podatcima i svojoj bazi podataka sada imamo u kući. Do tada je to znanje bilo isključivo kod vanjskoga izvođača. Također, gledali smo i u budućnost jer smo zaključili da postojanje takvoga profila djelatnika lakše otvara mogućnosti novim pristupima poslovnoga izvještavanja koji bi donio koncept poslovne inteligencije koji smo željeli uvesti u Agenciju. Tako je nastao izvještajni model (Slika 28.).

Slika 28. Drugi koncept poslovnoga izvještavanja u Agenciji (izvor: Agencija)

Prema tom konceptu, korisnici koji su bili zaduženi za izvještavanje prema menadžmentu i vanjskim institucijama davali su zahtjeve prema našim *database* programerima koji upitima na bazi podataka izrađuju razne operativne izvještaje i eksportiraju sirove podatke iz baze podataka. Napredniji korisnici iz sirovih podataka rade razne *custom* izvještaje i projekcije, smanjujući povećani pritisak koji se sada javlja na tri *database* programera. U biti, pritisak koji smo imali prema vanjskom izvođaču, u nekom trenutku preselio se na naše *database* programere.

To je bio jedan od okidača za intenzivnije razmišljanje o ideji da poslovni korisnici sami iz sustava dohvaćaju razne operativne izvještaje koji su im potrebni u svakodnevnom poslovanju. Počinjemo razmišljati o uvođenju OLAP tehnologije. Pretenciozno bi sada bilo reći da smo u Agenciji prije desetak godina razmišljali da ćemo za deset godina uvesti OLAP tehnologiju i da su faze koje sada spominjemo bile svjesne faze na putu do OLAP tehnologije. Ne, istina je da smo se putem prilagođavali problemima koji su nastajali u izvještavanju i u tom smjeru smo se mijenjali, koristeći se dostupnom tehnologijom, s ciljem odgovora na poslovni izazov da izvještaj dostavimo onom tko ga traži u najkraćem mogućem roku. Međutim, u nekom trenutku, s obzirom na količinu podataka kojom Agencija raspolaže i zbog problema s kojima smo se susretali u poslovnom izvještavanju, shvatili smo da informatizacija izvještajnoga sustava treba postati poslovni proces jednako vrijedan informatizaciji bilo koje poslovne vertikale Agencije. S druge strane, uslijed stalno rastućega opsega posla i kompleksnosti potpora, što dovodi u konačnici do stalnoga porasta novih podataka u sustav, čime izvještavanje bez centralnoga i jedinstvenoga modela podataka postaje vrlo kompleksno, odlučili smo se za implementaciju ODS-a i OLAP tehnologije kao glavnih tehnoloških rješenja koji će poboljšati sustav izvještavanja i analize podataka unutar Agencije. Glavni cilj postaje poslovnim korisnicima osigurati samostalno kreiranje poslovnih izvještaja koji su im u tom trenutku potrebni te da se neki izvještaji preko „dashboarda“ učine stalno dostupnim. Tako je nastao i treći koncept izvještavanja (Slika 29.), u kojem se Agencija trenutno nalazi.

Slika 29. Treći koncept poslovnoga izvještavanja u Agenciji (izvor: Agencija)

Glavne komponente treće faze jesu ODS baza podataka, ETL proces, skladište podataka i OLAP multidimenzionalna kocka. ODS je postao sabirnica za sve podatke iz transakcijskih tablica, postao je centralno mjesto za operativno izvještavanje iz kojega se dohvaćaju podatci kao sirovi podatci i rade izvještaji ili se podatci iz ODS-a preko skladišta podataka formiraju u kocku gdje korisnici, koristeći se *exelom*, dohvaćaju potrebne izvještaje. Napredni korisnici preko *export* sheme ODS-a dohvaćaju sirove podatke i za potrebe administrativnih kontrola, analiza, projekcija, rabeći pri tome *Access* zbog velikoga broja zapisa (Slika 30.). Korisnici koji još nemaju OLAP kocku za svoje poslovne vertikale, za *ad hoc* izvještaje i dalje šalju zahtjeve našim *database* programerima koji preko upita na transakcijskoj bazi i ODS-u izvještaje vraćaju tražitelju zahtjeva ili preko ODS-a napredni korisnici dohvaćaju sirove podatke i sami rade izvještaje, analize i potrebne projekcije te razne administrativne kontrole potpora.

Slika 30. Alati poslovnoga izvještavanja u Agenciji (izvor: Agencija)

U trećem konceptu poslovnoga izvještavanja Agencija će biti sve dok sva poslovna područja ne prebacimo na OLAP. Kada se to dogodi, Agencija će prijeći na ciljani izvještajni koncept (Slika 31.).

Slika 31. Ciljna slika izvještajnoga koncepta u Agenciji (izvor: Agencija)

Znamo da će poslovni sustav Agencije i dalje rasti. Dobro definiranim procesom poslovnoga izvještavanja (Slika 31.), Agencija će se s porastom podataka, koji će se dogoditi uslijed porasta poslovnoga sustava, moći nositi. Glavne ideje ciljnoga koncepta izvještajnoga sustava jesu:

1. Svi uhodani poslovni sustavi iz transakcijskih sustava prebačeni su na ODS koji je glavni izvor podataka za skladište podataka iz kojeg BI stručnjaci rade kocke za poslovne vertikale. Educirani poslovni korisnici i napredniji poslovni korisnici preko *exela* ili BI izvještaja (predefinirani izvještaji, *Dashboardi*) dohvaćaju potrebne poslovne izvještaje i rade razne poslovne izvještaje i analize.
2. Implementacija ODS-a i OLAP sustava u Agenciji kontinuiran je proces. Trenutno su od devet prepoznatih ključnih poslovnih vertikala u OLAP prebačene četiri. To znači da će se, nakon što prebacimo preostalih pet poslovnih sustava u prikazan ciljni koncept, svi novi poslovni sustavi, koji su u nastajanju i za koje još nemamo stabilnu strukturu podataka, izvještavanje odvijati tako da će poslovni korisnik dati zahtjev *database* programeru Agencije koji će preko upita na transakcijsku ili ODS bazu dohvatiti traženi izvještaj i proslijediti ga korisniku, npr. *monitoring* predanoga zahtjeva za potporom jedan je novi poslovni sustav u Agenciji koji u okvirima ciljne slike funkcionira na takav način.

Projekti za prebacivanje preostalih poslovnih sustava Agencije su u tijeku. Kada i preostale sustave prebacimo na OLAP, moći ćemo reći da smo završili s izvještajnim konceptom broj tri i da od tada izvještajni i analitički sustav Agencije živi u svom ciljnom konceptu (Slika 31.).

Prije puštanja u rad centralnoga modela izvještavanja napravili smo promjene unutar procedure za razvoj softvera u Agenciji. Svaka buduća funkcionalna specifikacija kojom se nadograđuje sustav Agencije sada u sebi sadrži pitanje: Na koji način nadogradnja sustava utječe na postavljeni

centralni izvještajni model? To je podsjetnik da vlasnik procesa i BI konzultant naprave analizu i utjecaj nadogradnje sustava na centralni model izvještavanja i OLAP kocke. Ako se utjecaj utvrdi, prepoznaje se prioritet same promjene pa se pristupa pisanju funkcionalne specifikacije za nadogradnju OLAP sustava odmah ili se može pričekati da se prikupi više zahtjeva za nadogradnjom OLAP-a, ako to poslovni proces dozvoljava. Promjena poslovnih procesa očitovala se u tome što smo uspostavom OLAP-a dobili ETL proces unutar kojeg smo dosta formalizirali ETL proceduru. To je značilo da sve izvore podataka moramo imati dostupnim na serverskoj infrastrukturi i da izvore podataka ne može bilo tko brisati jer bi nam rušio postavljeni centralni izvještajni model, što smo također definirali u procedurama vezanim za razvoj softvera, procedurama vezanim za infrastrukturu i sigurnost informacijskoga sustava Agencije.

Edukacije za korisnike sustava održane su prilagođene tipu korisnika samoga sustava. Tako su organizirane edukacije za *database* programere gdje se pojašnjavalo kako je sam sustav nastao i gdje je edukacija bila usmjerena na tehnički aspekt funkcioniranja sustava. Tom tipu edukacija prisustvovali su i napredniji korisnici sustava. Za naprednije korisnike sustava i *database* programere bila je organizirana i edukacija vezana za mogućnosti Power BI alata kao alata koji se spaja na OLAP kocku i mogućnosti koje on pruža vezano za izradu nadzornih ploča i izvještavanja. Na kraju, organizirana je edukacija i za ostale poslovne korisnike sustava na kojoj se pokazivalo povezivanje *exela* na OLAP sustav gdje su se korisnici na stvarnim primjerima educirali i otkrivali mogućnosti izvještavanja i analize koristeći se *exel via* OLAP - om.

3.5 VREDNOVANJE SUSTAVA

U okviru faze testiranja i isporuke provodili smo testove prihvaćanja, čime smo vrednovali postavljeni sustav. Prvo smo testove proveli za sve mjere za 2014. godinu i to tako da smo uspoređivali podatke u OLAP - u i ISAP - u (transakcijski sustav Agencije). Uspoređivani podatci bili su: količine, iznosi, broj gospodarstva. Podatke iz ISAP-a dohvaćali smo s pomoću SQL upita. U *exel* dokumentu: „Izravna plaćanja 2014 – testovi prihvaćanja“, postoji dio koji smo nazvali „Kontrola“ i taj podatak predstavlja razliku između podataka u OLAP - u i podataka u ISAP - u. Kada je test bio ispravan, razlike nije bilo, odnosno podatak je bio 0. Znači, ako nije postojala razlika u navedenoj tablici između OLAP - a i ISAP - a smatralo se da je nadogradnja OLAP - a uspješno dovršena i kvalitetno vrednovana što je bio preduvjet za potpisivanje primopredajne dokumentacije. Osim tog načina, vrednovanje smo proveli i tako da smo u *test case* (TC) scenarijima jasno definirali scenarije koje smo željeli provjerili prilikom vrednovanja

isporučenoga sustava na testnu okolinu. Primjer jednog *test casea* nalazi se u Tablici 6. Razlika od gornjega modela jest u tome što smo se koristili već gotovim izvještajima koje su postojali u našem ISAP sustavu i uspoređivali ih s podatcima dobivenim preko OLAP-a.

Tablica 6. *Test case* scenarij za provjeru kompenzacija (izvor: Agencija)

Rb	Opis koraka	Rezultat
1	Prijaviti se u OLAP sustav kako je opisano u poglavlju Prijava u sustav (TC1Spajanje na OLAP kroz Excel)	Sustav prikazuje *excel pivot* tablicu te je spreman za početak rada
2	Odabrati „Kompenzacija HPA“, „Kompenzacija HPK“ iz popisa mjera „Isplate“	Sustav prikazuje odabrane mjere na *pivot* tablice te se desno prikazuju u koloni „Values“
3	Odabrati atribut „Vremenska razdoblja“ iz dimenzije „Datum“	Sustav prikazuje odabrane mjere prema odabranim vremenskim razdobljima
4	Filtrirati 2012. godinu iz „Column Labels“	Sustav prikazuje odabrane mjere za 2012. godinu, čime smo izolirali traženu mjeru za usporedbu
5	Prijaviti se u ISA sustav	Sustav prikazuje početnu stranicu ISA sustava
6	Odabrati karticu Financije > Plaćanja	Sustav prikazuje stranicu Financija
7	Iz popisa na vrhu stranice odabrati „Izvještaji“ --> „Izvještaji“	Sustav prikazuje padajući izbornik s popisom izvještaja koji se mogu odabrati

8	Iz padajućega izbornika odabrati izvještaj „II Izvještaj po županijama sumarno“ te kliknuti gumb „Prikaži“	Sustav prikazuje opcije koje možemo odabrati za ovaj izvještaj
9	Odabrati „Sve županije“, „Datum od“ upisati 01.01.2012., „Datum do“ upisati 31.12.2012., „Visina isplate na žiro“ odabrati Bilo koja, „Visina isplate ukupno“ odabrati Bilo koja, za „Tip klijenta“ odabrati Sve te kliknuti „Prikaži izvještaj“ na dnu ekrana	Sustav generira izvještaj prema parametrima koje smo mu zadali te nam prikazuje odabrane podatke za Republiku Hrvatsku
10	Usporediti brojku iz sustava ISA s brojkom koju smo dobili kroz OLAP	Uočiti da su brojke za 2012. godinu za Republiku Hrvatsku identične, što znači da smo dobili vjerodostojan podatak

Prema istom modelu testirali smo i ostale poslovne podatke potrebne za poslove izvještavanja i analitike, kao što su npr: „Uplate po dugovima“, „Iznos prijeboja s poreznim dugom“, „Ukupno isplaćeno“, „Iznos obveze“, „Kompenzacija dugovi“, „Broj gospodarstava odobreno“, „Broj gospodarstava poslano na isplatu“ i mnoge druge.

Vrednovanje sustava usporedbom podataka u izvještajima iz staroga i novoga sustava, važno je s više aspekata:

1. Postupkom vrednovanja sustava dobit ćemo potvrdu da sustav dobro radi, ako prikazuje podatke koje smo do sada smatrali točnim i istinitim.
2. Drugi aspekt vezan je uz same korisnike sustava jer usporedbom staroga i novoga sustava djelatnici stječu povjerenje u novi sustav, što je prvi preduvjet da se njime počnu koristiti.
3. Treći aspekt govori o činjenici da se djelatnici prilikom testiranja i na edukacijama prvi put u praksi susreću s prednostima koji donosi novi sustav:

a. podatci se brže dohvaćaju
b. bez posebnih tehnoloških znanja korisnici izvještaje kreiraju prema svojim potrebama
c. korištenje više različitih alata za prikaz podataka (*Excel, Access, PoverBI* ...)
d. isti podatci promatraju se iz različitih dimenzija, što omogućava gledanje na sustav s različitih aspekata poslovanja
e. OLAP sustav je analitički koncipiran, što znači da on daje odgovore na poslovna pitanja na koja je teže odgovoriti koristeći se klasičnim izvještajnim sustavima kao npr.:
    i. Na koji se način ukupno isplaćeni iznos za sve vrste plaćanja za 2014. godinu može usporediti s ukupno isplaćenim iznosom iz 2013.?
    ii. Na koji se način učinkovitost isplate tekućega razdoblja može usporediti s istim razdobljima tijekom proteklih pet godina?
    iii. Prema kojim kategorijama i koliko je novca isplaćeno klijentima protekle godine i na koji način su se mijenjali ti iznosi tijekom vremena?
    iv. Koliki iznos novca je isplaćen za određenu vrstu potpore prema županijama ovaj mjesec u ovoj godini u odnosu na isti mjesec prošle godine?
    v. Koliko je iznos odobren za svaku županiju prema traženom iznosu te kakav je bio taj omjer prošle godine?
    vi. Pronalaženje najuspješnijih i najmanje uspješnih klijenata i/ili gospodarstava ili županija prema različitim kriterijima.

Uočavanjem ovih prednosti osigurava se bolje i brže prihvaćanje i korištenje implementiranoga sustava poslovne inteligencije.

3.6 PRIMJERI KORIŠTENJA SUSTAVA

Primijetili smo da različiti korisnici unutar iste poslovne vertikale ili korisnici različitih poslovnih vertikala, za kocke koje smo razvili preferiraju različite mogućnosti korištenja izvještajnoga i analitičkoga sustava. Npr. djelatnici poslovne vertikale programa ruralnoga razvoja, više nego djelatnici poslovne vertikale programa izravnih potpora, koriste se mogućnostima spajanja *exela* na OLAP. To ne znači da se djelatnici poslovne vertikale programa izravnih potpora njime ne koriste, već se koriste, ali u manjeg opsegu. Djelatnici poslovne vertikale programa izravnih potpora više se spajaju na ODS i preko *Accessa* koriste se tablicama predefiniranih *exporta* kojima se onda koriste za izradu kompleksnijih izvještaja, projekcija i analiza podataka (Slika 32.).

Slika 32. Predefinirani *exporti* preko ODS-a (izvor: Agencija)

Exel za povezivanje na OLAP kocku rabimo za definiranje raznih poslovnih izvještaja za nadležno ministarstvo i za menadžment Agencije, gdje gledamo ostvarivanje postavljenih ciljeva postavljenih strateškim planom. Također, svaki djelatnik i nadležni rukovoditelj može pratiti svoju učinkovitost, tj. učinkovitost djelatnika i količinu posla koju je obavio u jedinici vremena. Ako su efikasnost štoperica i kalkulator pojedinoga djelatnika, učinkovitost (efektivnost) bi se odnosila na organizaciju posla, tj. obavlja li posao djelatnik na pravi način. Pregledi podataka, naročito grafički pogledi na podatke, omogućuju nam razne prijedloge u poboljšanju poslovnih procesa i korištenje resursa unutar njih. Mogućnosti pregleda podataka ovise o količini dimenzija i mjera u sustavu i njihovim kombinacijama. Multidimenzionalnost nam omogućuje veliki broj prikaza izvještaja o mjerama kroz dimenzije i na temelju njih donošenja raznih poslovnih zaključaka koje možemo pretvoriti u kvalitetne poslovne odluke, ako sustavno pratimo njihove trendove kroz vrijeme. Tu zadaću Agencija ostvaruje prema nadležnom ministarstvu, gdje osim klasičnoga izvještavanja predlažu i promjene u smjeru pojednostavljenja poslovnih procesa i promjene vezane uz politiku potpora u RH.

Visoki menadžment Agencije daje prednost prikazu podataka preko nadzornih ploča koje su napravili naši *database* programeri koristeći se PowerBI alatima jer tako iz viših pregleda podataka mogu odlaziti prema nižim pregledima istih podataka, *drop down* metodom (Slike 33 – 35.).

Slika 33. Ulaz u nadzornu ploču Agencije vezano uz isplate potpora (izvor: Agencija)

Slika 34. Nadzorna ploča za „Pregled isplata za proizvodnu 2019. godinu“ (izvor: Agencija)

Slika 35. *Drop down* podataka za potpore za „Osječko baranjsku županiju“ (izvor: Agencija)

Također, nadzorne ploče ostvarile su najveći učinak kada na sastancima u nadležnom ministarstvu Agencija na jedan brz i interaktivan način može pokazati tražene podatke ministru i njegovim najbližim suradnicima. Nadzorne ploče pokazale su se kao brz izvor podataka kada je naš menadžment na terenu i kada treba odgovarati na pitanja novinara ili korisnika potpora. Tada se koristi pristup nadzornim pločama preko pametnih telefona zbog responzivnoga dizajna – parametar kvalitetno izrađenih mrežnih stranica koji svojom rezolucijom mora odgovarati potrebama korisnika i uređajima koje oni upotrebljavaju (Slika 36.).

Slika 36. Interaktivna nadzorna ploča za pametni telefon za potpore (izvor: Agencija)

U svim državnim agencijama koje se bave isplatom potpora uvijek je najveći izazov bio odgovoriti na trenutnu potrebu ministarstva kada npr. predstavnik ministarstva iznenada odlazi na neko područje RH ili je npr. sazvan hitan sastanak u ministarstvu s predstavnicima raznih skupina proizvođača, udruga i slično, gdje im hitno trebaju podatci o isplatama potpora za neko područje RH, za neke proizvodne kulture, grla stoke, proizvođače itd. Upotrebom alata i tehnologije poslovne inteligencije u Agenciji ta potreba ministarstva više ne izaziva dodatan stres jer upotrebom *exela* kroz OLAP u maloj jedinici vremena dolazimo do svih traženih podataka. Štoviše, sada smo u prilici uvijek dati izvještaj više o traženoj temi, dok smo s prijašnjim modelima izvještavanja uvijek konkretno davali točno ono što je traženo, ne jer smo smatrali da je preciznost vrlina već zato što nam resursi (vrijeme, ljudi) kao i model izvještavanja kojim smo se koristili nije omogućavao inovativnije izvještavanje o traženom. U tu svrhu koristimo se *exel via* OLAP, preko kojeg dohvaćamo tražene podatke i izrađujemo potrebne izvještaje (Slike 37 – 39.).

Datum.GMD	2019					
Row Labels	Broj gospodarstava podneseno	Broj gospodarstava traženo	Broj gospodarstava utvrđeno	Iznos traženo zahtjev	Iznos utvrđeno izračun	Iznos za isplatu MOP
[redacted]	1	1	1	81.199,52	81.199,52	73.367,88
Dobrobit životinja u svinjogojstvu	1	1	1			
Osnovno plaćanje	1	1	1	36.930,72	36.930,72	32.308,56
Osnovno plaćanje/ Zeleno plaćanje/ Prerraspodijeljeno plaćanje, iz posebne nacionalne rezerve za razminirano :	1	1	1			
Prerraspodijeljeno plaćanje				9.492,01	9.492,01	9.492,01
Proizvodno vezana plaćanja za proteinske usjeve	1	1	1			
Rasplodne krmače	1	1	1	9.010,00	9.010,00	9.010,00
Zeleno plaćanje				25.766,79	25.766,79	22.557,31
[redacted]	1	1	1	12.913,89	12.913,89	11.589,47
Osnovno plaćanje	1	1	1	6.245,25	6.245,25	5.463,61
Osnovno plaćanje/ Zeleno plaćanje/ Prerraspodijeljeno plaćanje, iz posebne nacionalne rezerve za razminirano :	1	1	1			
Prerraspodijeljeno plaćanje				2.311,34	2.311,34	2.311,34
Zeleno plaćanje				4.357,30	4.357,30	3.814,52
[redacted]	1	1	1	14.963,10	14.963,10	13.444,44
Osnovno plaćanje	1	1	1	7.161,55	7.161,55	6.265,26
Osnovno plaćanje/ Zeleno plaćanje/ Prerraspodijeljeno plaćanje, iz posebne nacionalne rezerve za razminirano :	1	1	1			
Prerraspodijeljeno plaćanje				2.804,91	2.804,91	2.804,91
Proizvodno vezana plaćanja za voće	1	1	1			
Zeleno plaćanje				4.996,64	4.996,64	4.374,27
[redacted]	1	1	1	5.599,75	5.599,75	5.030,66
Osnovno plaćanje	1	1	1	2.683,38	2.683,38	2.347,51
Osnovno plaćanje/ Zeleno plaćanje/ Prerraspodijeljeno plaćanje, iz posebne nacionalne rezerve za razminirano :	1	1	1			
Prerraspodijeljeno plaćanje				1.044,13	1.044,13	1.044,13
Zeleno plaćanje				1.872,24	1.872,24	1.639,02
[redacted]	1	1	1	8.810,63	8.810,63	8.067,75
Osnovno plaćanje	1	1	1	3.503,18	3.503,18	3.064,74
Osnovno plaćanje/ Zeleno plaćanje/ Prerraspodijeljeno plaćanje, iz posebne nacionalne rezerve za razminirano :	1	1	1			
Plaćanja u gorsko planinskim područjima	1	1	1			
Plaćanja u područjima s posebnim ograničenjima	1	1	1			
Plaćanja u područjima sa značajnim prirodnim ograničenjima	1	1	1	1.373,11	1.373,11	1.373,11

Slika 37. Prikaz izravnih plaćanja za poljoprivrednika za 2019. godinu (izvor: Agencija)

Datum.GMD	2019					
Row Labels	Broj gospodarstava podneseno	Broj gospodarstava traženo	Broj gospodarstava utvrđeno	Iznos traženo zahtjev	Iznos utvrđeno izračun	Iznos za isplatu MOP
Zagrebačka	8.702	8.702	8.702	205.549.699,30	198.702.670,69	179.142.362,60
Virovitičko-podravska	5.074	5.074	5.074	336.434.417,88	332.530.848,78	299.110.569,52
Požeško-slavonska	4.174	4.174	4.174	168.663.806,58	166.055.549,90	150.243.011,37
Brodsko-posavska	5.620	5.620	5.620	246.888.451,55	242.158.091,80	217.707.496,94
Zadarska	4.870	4.870	4.870	156.853.314,48	151.519.081,80	133.648.686,08
Osječko-baranjska	7.944	7.944	7.944	818.393.800,81	797.211.194,08	697.390.210,92
Šibensko-kninska	3.326	3.326	3.326	88.508.422,45	85.300.560,55	75.386.643,63
Vukovarsko-srijemska	5.789	5.789	5.789	437.363.036,58	429.412.795,34	382.330.287,13
Splitsko-dalmatinska	5.080	5.080	5.080	95.293.142,45	90.805.041,30	82.572.107,79
Istarska	3.599	3.599	3.599	109.782.646,39	106.929.478,79	96.020.717,69
Dubrovačko-neretvanska	4.003	4.003	4.003	32.993.193,70	32.447.335,33	29.897.794,30
Krapinsko-zagorska	6.919	6.919	6.919	78.890.122,69	77.503.522,07	71.155.068,20
Međimurska	3.354	3.354	3.354	102.717.160,66	100.590.594,16	90.807.715,12
Grad Zagreb	2.452	2.452	2.452	86.267.539,75	75.385.036,03	67.912.502,11
Sisačko-moslavačka	6.300	6.300	6.300	267.277.621,28	260.288.071,66	235.415.427,41
Karlovačka	4.865	4.865	4.865	141.832.093,72	138.238.361,17	126.716.828,98
Varaždinska	5.918	5.918	5.918	102.687.635,83	100.531.508,29	90.826.248,99
Koprivničko-križevačka	7.907	7.907	7.907	291.291.917,00	286.189.858,29	261.028.192,95
Bjelovarsko-bilogorska	8.802	8.802	8.802	361.352.824,33	352.449.800,08	318.075.237,71
Primorsko-goranska	1.462	1.462	1.462	69.152.072,12	65.568.604,60	58.429.055,97
Ličko-senjska	4.159	4.159	4.159	241.027.725,04	234.203.165,17	206.882.391,99
BEGUNJE	1	1	1	5.754,49	5.754,49	5.162,58
BOLZANO	1	1	1	4.511,51	4.511,51	4.162,97
BREŽICE, DOBOVA	1	1	1	14.010,20	14.010,20	12.755,96
DOLENJSKE TOPLICE	1	1	1	7.121,75	7.121,75	6.576,90
ESSEN	1	1	1	13.654,18	13.654,18	12.259,28
FROHNLEITEN	1	1	1	5.639,18	4.894,08	4.390,66
GIESELHORING	1	1	1	22.972,80	22.972,80	19.615,35
GRADAC	1	1	1	73.473,96	73.473,96	68.461,44
HEILBRONN	1	1	1	49.520,80	49.520,80	46.719,74
KIRCHFIDISCH	1	1	1	14.273,21	14.273,21	11.253,77
KRŠKO	1	1	1	7.665,29	7.665,29	7.026,25
LONDON	1	1	1	20.696,07	20.696,07	19.097,21

Slika 38. Prikaz potpora izravnih plaćanja po županijama za 2019. godinu (izvor: Agencija)

Row Labels	Broj gospodarstava podneseno 2019	Broj gospodarstava traženo 2019	Broj gospodarstava utvrđeno 2019	Iznos traženo zahtjev 2019	Iznos utvrđeno izračun 2019	Total Broj gospodarstava podneseno	Total Broj gospodarstava traženo	Total Broj gospodarstava utvrđeno	Total Iznos traženo zahtjev	Total Iznos utvrđeno izračun
Dobrobit životinja u govedarstvu	1.132	1.132	1.132	44.366.780,01	44.333.793,78	1.132	1.132	1.132	44.366.780,01	44.333.793,78
Dobrobit životinja u kozarstvu	121	121	121	686.343,89	682.301,34	121	121	121	686.343,89	682.301,34
Dobrobit životinja u ovčarstvu	678	678	678	6.927.248,34	6.921.138,94	678	678	678	6.927.248,34	6.921.138,94
Dobrobit životinja u peradarstvu	87	87	87	12.833.328,26	12.833.328,26	87	87	87	12.833.328,26	12.833.328,26
Dobrobit životinja u svinjogojstvu	333	333	333	21.957.019,44	21.957.019,44	333	333	333	21.957.019,44	21.957.019,44
Duhan	545	545	545	38.494.298,55	38.494.298,55	545	545	545	38.494.298,55	38.494.298,55
Korištenje feromonskih, vizualnih i hranidbenih klopki	936	936	936	12.789.170,31	12.771.144,62	936	936	936	12.789.170,31	12.771.144,62
Maslinovo ulje	14.282	14.282	14.282	14.735.792,30	14.551.418,30	14.282	14.282	14.282	14.735.792,30	14.551.418,30
Mehaničko uništavanje korova unutar redova višegodišnjih nasada	2.537	2.537	2.537	32.873.550,52	32.417.416,59	2.537	2.537	2.537	32.873.550,52	32.417.416,59
Metoda konfuzije štetnika u višegodišnjim nasadima	66	66	66	879.403,07	879.403,07	66	66	66	879.403,07	879.403,07
Mliječne krave	7.337	7.337	7.337	83.007.000,00	81.370.000,00	7.337	7.337	7.337	83.007.000,00	81.370.000,00
Obrada tla i sjetva na nagibu za oranične jednogodišnje kulture	35	35	35	85.249,75	85.249,75	35	35	35	85.249,75	85.249,75
Očuvanje izvornih i zaštićenih vrsta i kultivara poljoprivrednog bilja	4.787	4.787	4.787	5.826.254,00	2.572.254,75	4.787	4.787	4.787	5.826.254,00	2.572.254,75
Očuvanje suhozida	1.739	1.739	1.739	7.841.682,93	7.647.443,56	1.739	1.739	1.739	7.841.682,93	7.647.443,56
Očuvanje travnjaka velike prirodne vrijednosti	536	536	536	9.650.173,64	9.478.346,62	536	536	536	9.650.173,64	9.478.346,62
Očuvanje ugroženih izvornih i zaštićenih pasmina domaćih životinja	3.168	3.168	3.168	56.015.882,08	53.806.183,91	3.168	3.168	3.168	56.015.882,08	53.806.183,91
Očuvanje živica	60	60	60	20.756,80	19.422,90	60	60	60	20.756,80	19.422,90
Održavanje ekstenzivnih maslinika	355	355	355	2.726.362,43	2.715.120,44	355	355	355	2.726.362,43	2.715.120,44
Održavanje ekstenzivnih voćnjaka	59	59	59	198.759,15	198.290,47	59	59	59	198.759,15	198.290,47
Osnovno plaćanje	109.463	109.463	109.463	1.405.393.418,58	1.395.924.448,23	109.463	109.463	109.463	1.405.393.418,58	1.395.924.448,23
Osnovno plaćanje/ Zeleno plaćanje/ Prerraspodijeljeno plaćanje, iz p	109.463	109.463	109.463			109.463	109.463	109.463		
Pilot mjera za zaštitu kosca (Crex crex)	95	95	95	564.339,36	557.927,76	95	95	95	564.339,36	557.927,76
Pilot mjera za zaštitu leptira	10	10	10	50.451,33	48.668,16	10	10	10	50.451,33	48.668,16
Plaćanja u gorsko planinskim područjima	65.777	65.777	65.777	128.549.829,98	122.978.036,68	65.777	65.777	65.777	128.549.829,98	122.978.036,68
Plaćanja u područjima s posebnim ograničenjima	65.777	65.777	65.777	23.834.775,65	23.608.041,70	65.777	65.777	65.777	23.834.775,65	23.608.041,70
Plaćanja u područjima sa značajnim prirodnim ograničenjima	65.777	65.777	65.777	328.875.984,91	326.528.221,25	65.777	65.777	65.777	328.875.984,91	326.528.221,25
Plaćanja za održavanje ekoloških poljoprivrednih praksa i metoda	4.994	4.994	4.994	193.204.848,58	184.421.197,96	4.994	4.994	4.994	193.204.848,58	184.421.197,96
Plaćanja za prijelaz na ekološke poljoprivredne prakse i metode	4.994	4.994	4.994	90.038.172,26	84.757.913,67	4.994	4.994	4.994	90.038.172,26	84.757.913,67
Plaćanje za mlade poljoprivrednike	15.587	15.587	15.587	65.809.662,49	56.399.422,04	15.587	15.587	15.587	65.809.662,49	56.399.422,04

Slika 39. Prikaz izravnih plaćanja prema vrsti potpore za 2019. godinu (izvor: Agencija)

4 STUDIJA SLUČAJA UVOĐENJA SUSTAVA ZA ANALITIČKU OBRADU PODATAKA ZA ISPLATU POTICAJA U POLJOPRIVREDI

4.1 OPIS INSTITUCIJE I DJELATNOSTI[55]

Agencija je javno tijelo nadležno za operativnu provedbu mjera izravne potpore, mjera ruralnoga razvoja, mjera za pomorstvo i ribarstvo (u dijelu delegiranih funkcija) i mjera zajedničke organizacije tržišta, kao i vođenje upisnika i registara te održavanje i korištenje Integriranoga administrativnog i kontrolnog sustava (IAKS-a) preko kojega se zaprimaju, obrađuju i kontroliraju izravna plaćanja poljoprivrednicima. U koordinaciji s Ministarstvom poljoprivrede provodi mjere Zajedničke poljoprivredne politike (ZPP) i Zajedničke ribarstvene politike (ZRP) koje se financiraju iz državnoga proračuna i proračuna (fondova) Europske unije (EU): Europskoga fonda za jamstva u poljoprivredi (EFJP) iz kojega se financiraju mjere izravne potpore i mjere zajedničke organizacije tržišta, Europskoga poljoprivrednog fonda za ruralni razvoj (EPFRR) iz kojega se financiraju mjere ruralnoga razvoja i Europskoga fonda za pomorstvo i ribarstvo (EFPR) iz kojega se financiraju mjere za pomorstvo i ribarstvo. Agencija svoj rad temelji na akreditiranim procesima i procedurama od strane Europske komisije. Svoj rad obavlja iz središnjega ureda u Zagrebu, 21 podružnice te četiri ispostave. Agencija upravlja sljedećim upisnicima i bazama podataka:

- Upisnik poljoprivrednika s 165.712 registriranih poljoprivrednika
- ARKOD sustav za digitalnu identifikaciju zemljišnih parcela – evidencija uporabe poljoprivrednoga zemljišta u digitalnom obliku. Podatke o ARKOD parcelama korisnik može vidjeti putem AGRONET aplikacije, ako posjedujete korisničko ime i zaporku.
- AGRONET aplikacija – web aplikacija putem koje poljoprivrednici pregledavaju podatke o svom gospodarstvu i u kojoj elektronski popunjavaju jedinstveni zahtjeve za potpore za tekuću godinu.
- Prateći registri (vinogradarski registar, registar primarnih proizvođača hrane, registar subjekata u ekološkoj proizvodnji, registar sušara, upisnik maslinika, upisnik voćnjaka, upisnik dopunskih djelatnosti na OPG-u)
- ISAP (Informacijski sustav agencije za plaćanja) – centralizirana elektronska baza podataka (za istovremeni unos podataka sa svih 26 lokacija Agencije u RH)
- Prostorni podatci i servisi – sukladno „Strateškom planu Nacionalne infrastrukture prostornih podatka (NIPP) za razdoblje 2017. – 2020.“ Agencija je evidentirana kao subjekt NIPP-a i, sukladno navedenoj obvezi, Agencija omogućava pregledavanje i

[55] https://www.apprrr.hr/o-nama/ 1.6.2019.

dohvaćanje prostornih podataka iz ARKOD sustava svim zainteresiranim korisnicima (Arkod podatci, obilježja krajobraza, ekološki značajne površine, vinogorja, itd.).

Rad Agencije kontrolira Upravno vijeće koje imenuje Vlada RH čiji je predsjednik ministar poljoprivrede. Rad Agencije nadzire: Samostalna služba za akreditaciju Agencije pri Ministarstvu poljoprivredne, Sektor za unutarnju reviziju Agencije, kao i razna tijela unutar EU - a, sve s ciljem osiguravanja učinkovitoga sustava upravljanja i kontrole. Agencija obavlja sljedeće poslove:

1. organizira financijske, računovodstvene i izvještajne funkcije za plaćanje svih potpora u poljoprivredi (nacionalne i EU mjere)
2. prati i provodi zakonske i ostale akte iz područja tržišno - cjenovne i strukturne potpore u poljoprivredi i ribarstvu
3. obavlja poslove intervencija na domaćem tržištu, poticanja prodaje i potrošnje, uravnoteženja ponude i trgovinske mjere
4. provodi intervencijsku kupovinu i prodaju, povlačenje poljoprivrednih proizvoda s domaćega tržišta
5. provodi mjere promicanja trženja i poboljšanja kakvoće poljoprivrednih proizvoda, potpore pripremi poljoprivrednih proizvoda za tržište i potpore potrošnji
6. provodi i plaća potpore vezane uz mjere ruralnoga razvoja
7. provodi mjere kroz cjelokupni SAPARD/ IPARD program te ostale pretpristupne fondove
8. uspostavlja i provodi integrirani administrativni i kontrolni sustav (IAKS)
9. izrađuje izvještaje prema nacionalnom dužnosniku za ovjeravanje, Nacionalnom fondu Ministarstva financija i Upravi za ruralni razvoj pri Ministarstvu poljoprivrede
10. razvija razne oblike međunarodne suradnje (ostvarena je suradnja s 33 države).

Agencija ima postavljenu viziju, misiju, vrijednosti u koje vjeruje i ciljeve[56]:

vizija – unaprijediti životni standard hrvatskih poljoprivrednika i ribara uz očuvanje i uravnotežen razvoj ruralnih prostora

misija – misija Agencije za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju jest biti strateški partner poljoprivrednika, potaknuti uspješno poslovanje na poljoprivrednim gospodarstvima uz profesionalno i odgovorno korištenje resursa, znanja i inovacija koje pridonose razvoju i održivosti hrvatske poljoprivrede.

vrijednosti u koje vjerujemo

- na usluzi smo poljoprivrednicima – profesionalno, djelotvorno i informativno postupanje

[56] https://www.apprrr.hr/o-nama/ 1.6.2019.

- poštovanje i uvažavanje korisnika, zaposlenika i suradnika
- korištenje stečenoga znanja i inovacija
- kvaliteta, jednakost i etika u poslovanju

ciljevi Agencije: operativna provedba Zajedničke poljoprivredne politike i Zajedničke ribarske politike, Osiguranje kvalitetne IT podrške za provedbu potpora, Osiguranje operativnih i funkcionalnih registara i Akreditacija Agencije za korištenje sredstava poljoprivrednih fondova EU – a koja zahtijeva usklađenost s akreditacijskim kriterijima, kao i otklanjanje revizijskih nalaza.

4.2 POSLOVNI PROBLEM OPISAN KROZ CILJEVE PROJEKTA

Agencija je javna institucija Republike Hrvatske preko koje EU isplaćuje velike količine novca poljoprivrednicima. Zbog toga je podložna stalnim revizijama poslovanja od strane EU komisije, unutarnje revizije Agencije i nadležnog tijela Agencije pri Ministarstvu poljoprivrede. Sve to utječe na poslovanje Agencije koje je uređeno prema standardima, poslovnim normama i dobrim praksama. Agencija ima međunarodni certifikat ISO/IEC 27001:2013 za sustav upravljanja informacijskom sigurnošću. Također je akreditirala sve svoje poslovne procese prema visokim zahtjevima EU – a da bi mogla obavljati poslove isplate novčanih poticaja. Da bi dobila akreditaciju, Agencija je morala izraditi vrlo složenu informatičku podršku za svoj rad te uspostaviti Integrirani administrativni i kontrolni sustav (IAKS) preko kojeg zemlje članice EU - a zaprimaju, obrađuju i kontroliraju plaćanja poljoprivrednicima. Tako je uspostavljen registar svih poljoprivrednika (**Upisnik poljoprivrednih gospodarstava)**, zatim digitalna identifikacija zemljišnih parcela (**ARKOD)**, centralizirana elektronska baza podataka za istovremeni unos podataka s 25 lokacija Agencije (**ISAP)**, zaštićena web aplikacija pomoću koje poljoprivrednici popunjavaju zahtjeve za poticaj (**AGRONET)** i svakodnevna **dostava podataka (FTP)** za sva grla stoke iz Hrvatske poljoprivredne agencije za poljoprivredno gospodarstvo. Agencija je 2013.godine dobila odluku o akreditaciji, nakon što je njen rad revidiralo nekoliko nezavisnih revizorskih tijela te nakon što je otklonjeno svih 200 revizijskih nalaza od kojih je 79 bilo blokirajućih. Cilj revizija bio je uvjeriti EU da je Republika Hrvatska uspostavila upravljački i kontrolni sustav koji osigurava dodjelu novčanih sredstava poljoprivrednicima. Sve su to bili pokretači da se Agencija, za ispunjavanje tih visokih kriterija u poslovanju, okreće novim tehnološkim rješenjima, metodologijama i dobrim poslovnim praksama u razvoju softvera jer smo jedino tako mogli ispuniti postavljene nam poslovne ciljeve.

Dolaskom novih ljudi u Agenciju 2012. godine, nakon upoznavanja s aktualnim problemima vezanim uz izvještavanje, projekt uspostave OLAP izvještajnog modela Agencije postao je moguć. Ključno je bilo poznavanje mogućnosti OLAP tehnologije preko prijašnjega iskustva novozaposlenih kroz dotadašnje OLAP projekte.

Ostale donesene odluke koje su pomogle uspostavu OLAP-a bile su sljedeće:

1. Prelazak s vodopadnoga modela razvoja softvera na agilne metodologije razvoja softvera (Scrum). S obzirom na karakteristike vodopadnoga modela razvoja softvera u kojem se dugo čekalo na isporuke novih funkcionalnosti za korisničko testiranje uveo se agilni pristup pa se to vrijeme dosta skratilo. Sada se sve događa u više manjih iteracija (*sprint*), radi se brže i lakše se upravlja procesom razvojem softvera u Agenciji. Pozornost u razvoju softvera jest na „must have“ funkcionalnostima. „Nice to have“ funkcionalnosti svedene su na minimum.
2. Zapošljavanje vlastitih *database* programera u Agenciji bio je potez kojim se željelo postići da se kroz projekt uspostave OLAP izvještajnoga sustava s vanjskim izvođačem kolege educiraju za samostalan razvoj ostalih OLAP kocki za ostale poslovne vertikale Agencije, čime bi postali samodostatni za nastavak razvoja projekta poslovne inteligencije. Stjecanje iskustva kroz rad je najbolja edukacija jer se na konkretnim problemima u projektu s iskusnim stručnjakom iz tog područja brže i lakše uči.
3. Promjena modela razvoja softverskih projekata – Agencija je vremenom povećavala svoje poslovanje uslijed dobivanja novih poslova i povećavanja kompleksnosti dosadašnjih poslova. Posljedica toga je povećana potreba za informatizacijom poslovnih procesa. Međutim, povećana potreba za informatizacijom u svim poslovnim vertikalama nije praćena specijalizacijom razvojnih timova, već je postojao jedan razvojni tim za čitavu Agenciju. Međutim, došli smo do faze kada su potrebe poslovnih vertikala toliko narasle da se više nisu mogle razvijati unutar jednoga razvojnog tima, a zbog velikog broja funkcionalnosti koje je trebalo razviti sukobljavali su se jednako važni prioriteti iz različitih poslovnih vertikala. Sve je to zahtijevalo jednu reorganizaciju modela razvoja softvera u Agenciji na način da svaka ključna poslovna vertikala dobije svoj poseban razvojni tim. Razvojni timovi postali su manji, lakše upravljivi, čime su se riješile nagomilane stavke koje su čekale na razvoj. Ova promjena pokazala se poslije kao pun pogodak jer smo tako mogli definirati i OLAP projekt kao poseban projekt koji ima svoj poseban razvojni tim što osigurava kontinuitet i uspjeh projekta.

Ciljevi uspostave izvještajnoga sustava u Agenciji:

1. ***Učiniti poslovni proces izvještavanja kontinuiranim procesom, jednako vrijednim, bilo kojoj poslovnoj vertikali Agencije, za sve ključne poslovne procese Agencije***

   Pojašnjenje cilja: Do uspostave ovoga projekta poslovno izvještavanje bilo je u sklopu jedinstvenoga ugovora o nadogradnji i održavanju sustava informatizacije svih poslovnih vertikala Agencije. Drugi problem koji se javljao u tom modelu, gdje postoji preveliki broj potreba, a nedostatak resursa na projektu (novac i ljudi), jest taj da se tada informatizira samo ono najpotrebnije što ne ugrožava *core* poslovanje firme, čime sve ostalo pada u drugi plan pa tako i poslovno izvještavanje. S druge strane, sve više raste potreba za kontinuiranim izvještavanjem prema visokom menadžmentu i nadležnom ministarstvu.

2. ***Smanjiti opterećenje izrade izvještaja vanjskih izvođača radi proizvodnje ad hoc i predefiniranih izvještaja i predefiniranih eksporta podataka iz sustava***

   Pojašnjenje cilja: Velika količina potrebnih izvještaja, eksporta podataka iz sustava uslijed poslovnih potreba povećavali su opterećenje na resurse vanjskoga izvođača koji to nije mogao pratiti pa smo stalno dolazili u situaciju da iz *sprinta* u *sprint* moramo birati koje ćemo funkcionalnosti informatizirati između jednakovrijednih poslovnih potreba iz različitih ili istih poslovnih vertikala Agencije.

3. ***Povećati brzinu dohvata izvještaja i eksporta podataka iz sustava***

   Pojašnjenje cilja: Poslovno izvještavanje (predefinirani izvještaji) i potrebni *eksporti* iz sustava bili su unutar poslovnih aplikacija. Takav model izvještavanja usporavao je rad informacijskoga sustava Agencije u cjelini. Dohvat izvještaja i potrebnih *eksporta* iz sustava trajali su dugo s obzirom na količinu podataka koji su bili potrebni. Predefinirani izvještaji i potrebni *eksporti* iz sustava za kontrolu poticaja ili analizu bili su dosta zahtjevni, a kako su se izvlačili tijekom radnoga vremena direktno iz transakcijskih baza, sve je dosta usporavalo sustav, što je ostalim djelatnicima Agencije otežavalo rad.

4. ***Izraditi procesno orijentiran centralni izvještajni sustav namijenjen poslovnim korisnicima za operativno i analitičko izvještavanje***

   Pojašnjenje cilja: Sve tipične probleme u izvještavanju Agencija je osjetila. Pri tome mislimo na nedostupnost informacija u vremenu kada ih trebamo, nepovjerenje u podatke, u ovisnosti tko ih dohvaća jer se koriste različitim izvorima podataka pa su se i izvještaji razlikovali, netransparentnost tokova podataka, prava pristupa i nadzor nad podatcima.

5. ***„Jedna verzija istine“***

   Pojašnjenje cilja: Davanjem različitih podataka u istim ili sličnim izvještajima ili davanje istih podataka koji se u različitim izvještajima drugačije nazivaju ili tumače, prema trećim

osobama, uzrokuje problem nepovjerenja u izvještajni sustav Agencije. S obzirom da nam se to znalo događati, „Jedna verzija istine“ navedena je kao poseban cilj.

6. ***Povećati brzinu izrade izvještaja uz maksimalno osiguranje točnosti izvještavanja***

   Pojašnjenje cilja: Davanje naloga izvođaču za *ad hoc* izvještajem, čekanje da se izvještaj i dobije jer često nije prioritet visoke razine, dovodi do toga da poslovi izvještavanja stoje, što povećava nezadovoljstvo. S druge strane, stalna promjena i uvođenje novih ljudi (u Agenciji i na strani izvođača) koji još dovoljno ne poznaju procese i podatke dovodi do sumnje u točnost izvještaja.

7. ***Osigurati izvještajni sustav da napredni poslovni korisnici mogu raditi analizu podataka***

   Pojašnjenje cilja: Prema godišnjem izvješću o radu za 2019. godinu (proizvodna godina 2018.) u svrhu provjere i ispunjavanja obveza za ostvarivanje potpore i zaštite financijskih sredstava EU - a i Republike Hrvatske, Agencija ima sljedeće brojčane pokazatelje (Tablica 7.).

Tablica 7. Brojčani pokazatelji za isplatu potpora za proizvodnu 2018. godinu (izvor: Agencija)

Rb	Broj zapisa u bazi	Pojašnjenje
1	30.000.000,00	Broj zapisa u bazi vezano uz izračun potpora u 2019. godini (izračuni prema vrsti potpore EU i HR dio)
2	60.000.000,00	Zapisi unakrsnih provjera unutar sustava
3	110.418 zahtjeva	Jedinstveni zahtjev za potpore
4	110.418 zahtjeva	Administrativne kontrole nad zaprimljenim zahtjevima
5	11.975 kontrole na terenu	Kontrole na terenu provedene nad 8.611 poljoprivrednih gospodarstava na kojima je izvršio provjeru nad 143.357,43 ha poljoprivrednih površina i 93.978 grla stoke
6	2,3 mlrd HRK	EU udio potpore za mjere izravne potpore
7	643 milijuna kn	Nacionalni udio za mjere izravne potpore
8	589 milijuna kn	EU udio za IAKS mjere ruralnog razvoja
9	103 milijuna kn	Nacionalni udio za IAKS mjere ruralnog razvoja

Iz tablice za 2018. vidljivo je da Agencija ima veliku količinu podataka za korištenje. 18.12.2019. godine Agencija je obilježila deset godina rada i postojanja, tijekom kojih je isplatila 34 milijarde HRK potpora, od čega 17 milijardi u zadnje tri godine. Cilj je da se iz ove količine podatka i povezivanjem ovih podataka s drugim podatcima iz sektora poljoprivrede, kvalitetnom i stručnom analitikom, dođe do znanja koja mogu poljoprivredu RH usmjeravati prema uspješnijim programima za poljoprivrednike.

4.3 KARAKTERISTIKE KONKRETNOGA SUSTAVA

Koncept OLAP izvještajnoga sustava Agencija će primijeniti na cjelokupno poslovanje. Cjelokupan projekt podijeljen je u više projekata, prema poslovnim područjima. Svako skladište podataka koje se izrađuje ima svog vlasnika koji može biti odjel, sektor ili pojedina osoba. Za sve poslovne procese u Agenciji ovim prvim projektom postavili smo jedinstveni model podataka. Ključni dijelovi tog modela podataka su dimenzije i mjere. Cilj projekta bio je prepoznati što više dimenzija, tj. pogleda na podatke (mjere). Projekt je prepoznat i odobren od najvišeg menadžmenta poduzeća, kompleksan je i sveobuhvatan. U implementaciji kompleksnijih BI sustava, kao što je ovaj, koristimo ODS bazu podataka gdje želimo, osim analitičkoga izvještavanja, omogućiti i operativno izvještavanje. ODS postaje sabirnica svih naših podataka što nam omogućuje da se kod izvještavanja ne spajamo na razne sustave već uvijek znamo da imamo jedan jedinstveni sustav za operativno izvještavanje kojim se svi koriste. Kao kruna projekta, nakon što smo pripremili ODS i DW, dolazi nastajanje multidimenzionalne kocke gdje korištenjem alata za izvješćivanje osiguravamo različite poglede nad činjenicama koje nas zanimaju. Taj skup alata za izvješćivanje zovemo poslovnom inteligencijom (BI).

Opseg implementacije

Zahtjevi koje smo obuhvatili odnose se na:

1. izradu „proof of concept“ sveobuhvatnoga centralnog izvještajnog sustava: operativna baza podataka (Operational Data Store – ODS), skladište podataka (Data Warehouse - DWH), multidimenzionalna baze podataka (OnLine Analytical Processing - OLAP), i ekstrakcija, transformacija i učitavanje (Extract/Transform/Load – ETL)
2. izradu OLAP kocke koja pokriva poslovno područje IAKS potpora (SIP): Program izravnih plaćanja i Program IAKS mjere ruralnoga razvoja
3. uspostavu infrastrukture s bazom metapodataka za automatizirano upravljanje sustavom i platformom za razvoj ETL procesa.

Model i opis modela

Model se sastoji od sljedećih komponenti (Slika 40.):

- *ODS DB* – baza u koju se učitavaju podatci s izvornih sustava u sirovom obliku, odnosno kao kopije tablica izvornih sustava, s napomenom da se podatci standardiziraju po tipu
- Skladište podataka koje se sastoji od sljedećih baza podataka:
    - *Stage DB* – baza koja se ne koristi za izvještavanje već za učitavanje sirovih podataka koji su nam potrebni za DWH model (podatke standardiziramo po tipu)

- *DWH Core DB* – podatci iz *stagea* se učitavaju u pripremljeni relacijski model za analitičko izvještavanje pri čemu se vrše sve potrebne transformacije nad podatcima (validacije, kalkulacije i agregacije). Na taj način podatci dobiju analitička svojstva i djelatnici Agencije preko OLAP kocke dobiju potrebnu analitiku

- Baza metapodataka – čuvaju se podatci o pokretanju ETL procesa uključujući eventualne greške koje nastanu tijekom izvođenja
- OLAP kocka za izravna plaćanja – multidimenzionalna baza podataka u koju se podatci procesiraju iz skladišta podataka kojoj korisnici pristupaju direktno iz BI alata. Za izravna plaćanja omogućeno je izvještavanje prema više dimenzija (klijent, gospodarstvo, lokacija, vrijeme …) te više različitih mjera (tražena količina, traženi iznos, isplaćeni iznos …)
- BI alati – alati namijenjeni poslovnim korisnicima za operativno i analitičko izvještavanje, bilo da se radi o standardiziranim izvještajima, *ad hoc* izvještajima, nadzornim pločama, analizi podataka ili nekim drugim oblicima izvještavanja gdje djelatnici Agencije podatke promatraju i prilagođavaju svojim poslovnim potrebama.

Slika 40. Model DWH/BI sustava za poslovno područje „SIP“ (izvor: Agencija)

Iz modela je vidljivo da se podatci dohvaćaju s izvornih sustava i pune u ODS bazu podataka. Iz ODS baze se ETL postupcima podatci transformiraju i pune u EXPORT shemu ODS baze podataka te u centralni izvještajni model koji se nalazi u DWH bazi podataka. EXPORT shemi korisnici mogu pristupati kroz različite alate koji imaju mogućnost spajanja na SQL server baze podataka (npr. *Access*). Iz modela koji se nalazi u DWH bazi podataka podatci se zatim procesiraju u multidimenzionalnu bazu podataka (OLAP) kojoj mogu pristupati izvještajni alati kao što je *excel*.

Poslovni procesi koji su u opsegu projekta

U okviru implementacije DWH/BI izvještajnoga sustava za poslovno područje iz Programa izravnih plaćanja i IAKS mjera ruralnog razvoja uključena je podrška za poslovne procese (Tablica 8.)

Tablica 8. Procesi unutar Programa izravnih potpora, SIP (izvor: Agencija)

Rb	Naziv procesa	Opis procesa	Vlasnik
1	Preuzimanje zahtjeva	Preuzimanje zahtjeva iz AGRONET-a	SKM
2	Administrativne kontrole	Višestruke provjere zahtjeva zadane regulativom	SKM
3	Izračuni potpora i plaćanja	Izračun iznosa odobrenih prava korisnicima po fondovima i mjerama	SKM
4	Odobravanje plaćanja	Zajednički modul koji služi za autoriziranje iznosa odobrenih potpora	SKM

Izvorni sustavi

Točnost podataka u operativnom spremištu podataka (ODS) i skladištu podataka (DW) nakon implementacije i testiranja ovisi o točnosti podatka u izvornom sustavu u kojem je podatak nastao. U ETL procesu, prilikom dohvata podataka iz izvornih sustava, ne generiraju se novi podatci niti se mijenjaju postojeći podatci. Za potrebe praćenja tokova podataka od izvornih sustava, preko ODS-a i DW, do multidimenzionalne baze podataka koristi se baza metapodataka. U Tablici 9. nalazi se prikaz izvornih sustava iz kojih će se prikupljati i obrađivati informacije.

Tablica 9. Izvorni sustavi za OLAP kocku

Rb	Naziv	Tip sustava	Namjena sustava	Vlasnik	Unos podataka	Tehnologija
1	ISAP	Alfanumerički	IAKS	SIP	Kontinuirano	Microsoft

Rječnik pojmova

Kako bi se osiguralo jednoznačno razumijevanje i tumačenje poslovnih pojmova koji se koriste u procesu izvještavanja, napisan je rječnik pojmova (Slika 41.).

Pojam	Klasifikacija	Kratica	Sinonimi	Izvorni sustavi	Područje	Značenje	Izračun	Napomena	Prijevod (engleski)	Kratica (engleski)
ABB	Dimenzija	-	-	ISAP	SIP	OLAP dimenzija koja omogućava prikaz podataka prema nazivu ABB-a. Naziv se prikazuje uz ABB kod. Također je vidljiva i dinamička hijerarhija ABB-ova koja omogućuje pogled od hijerarhijski najvišeg do najnižeg ABB-a.				
Datum	Dimenzija	-	-	ISAP	SIP	OLAP dimenzija koja omogućava prikaz podataka prema datumu na koji se pojedini promatrani podatak dogodio.				
Gospodarstvo	Dimenzija	-	-	ISAP	SIP	OLAP dimenzija koja omogućava prikaz podataka prema gospodarstvima.				
Klijent	Dimenzija	-	-	ISAP	SIP	OLAP dimenzija koja omogućava prikaz podataka prema klijentima.				
Lokacija	Dimenzija	-	-	ISAP	SIP	OLAP dimenzija koja omogućava prikaz podataka prema lokaciji na kojoj se pojedini podatak evidentirao.				
Mjera	Dimenzija	-	-	ISAP	SIP	OLAP dimenzija koja omogućava prikaz podataka prema mjerama.				

Slika 41. Izvod iz Rječnika pojmova (izvor: Agencija)

Dimenzije

Kako bi kreirali model podataka za analitičko izvještavanje, definirali smo i konformne dimenzije. To su dimenzije koje su zajedničke za dva ili više poslovnih područja (*data mart*) jer je spajanje različitih područja izvještavanja i analiza činjeničnih tablica moguće samo koristeći konformne dimenzije. Znači, one predstavljaju zajedničke poglede na mjere i činjenice u različitim poslovnim procesima. Detaljne definicije tablica dimenzija s pripadajućim kolonama definirali smo u *excel* datoteci (Slika 42.). Dimenzije koje promatramo vidljive su u Tablici 10. (Prilog VII.).

B45 DimGospodarstvo

	A	B	C	D	E	F	G	H	I	J
1	Shema	Tablica	Kolona	Naziv	Opis	Vrsta kolone	Tip kolone / tip agregacije	Tip podatka	Dodatno	Obavezno
36	DWH	DimDatum	IstiDatumProsliMjesecID	Isti datum prošli mjesec	Isti datum prošli mjesec	Dimenzija	Strani ključ (DimDatum)	int		Da
37	DWH	DimDatum	ZadnjiDatumProsliMjesecID	Zadnji - datum prošli mjesec - ID	Zadnji datum prošlog mjeseca	Dimenzija	Strani ključ (DimDatum)	int		Da
38	DWH	DimABB	IDABB	ID ABB	ID ABB-a, primarni ključ	Dimenzija	Primarni ključ	int		Da
39	DWH	DimABB	ABBSifra	ABB Šifra	Šifra ABB-a	Dimenzija	Šifra	int		Da
40	DWH	DimABB	ABBOznaka	ABB Oznaka	Oznaka ABB-a	Dimenzija	Atribut	int		
41	DWH	DimABB	ABBNaziv	ABB Naziv	Naziv ABB-a	Dimenzija	Atribut	varchar(255)		
42	DWH	DimABB	IzvorID	Izvor ID	Izvor ID	Dimenzija	Strani ključ (DimIzvor)	int		
43	DWH	DimABB	FondID	Fond - ID	Fond ID	Dimenzija	Strani ključ (DimFond)	int		
44	DWH	DimABB	KategorijaABB	ABB Kategorija	Kategorija ABB-a	Dimenzija	Atribut	varchar(255)		
45	DWH	DimGospodarstvo	IDGospodarstvo	ID Gospodarstva	ID Gospodarstva, primarni ključ	Dimenzija	Primarni ključ	int		Da
46	DWH	DimGospodarstvo	MIBPG	MIBPG	MIBPG	Dimenzija	Šifra	int		Da
47	DWH	DimGospodarstvo	GospodarstvoNaziv	Gospodarstvo naziv	Naziv gospodarstva	Dimenzija	Atribut	varchar(255)		
48	DWH	DimGospodarstvo	IBK	IBK	IBK trenutnog klijenta vezanog za gospodarstvo	Dimenzija	Atribut	int		
49	DWH	DimGospodarstvo	ZupanijaGospodarstva	Gospodarstvo županija	Županija gospodarstva	Dimenzija	Atribut	varchar(255)		
50	DWH	DimGospodarstvo	GradOpcinaGospodarstva	Gospodarstvo grad općina	Grad općina gospodarstva	Dimenzija	Atribut	varchar(255)		
51	DWH	DimGospodarstvo	NaseljeGospodarstva	Gospodarstvo naselje	Naselje gospodarstva	Dimenzija	Atribut	varchar(255)		
52	DWH	DimGospodarstvo	OIBGospodarstva	Gospodarstvo OIB	OIB gospodarstva	Dimenzija	Atribut	int		
53	DWH	DimKlijent	IDKlijent	ID Klijent	ID Klijenta, primarni ključ	Dimenzija	Primarni ključ	int		Da
54	DWH	DimKlijent	KlijentSifra	Klijent šifra	Šifra klijenta	Dimenzija	Šifra	int		Da
55	DWH	DimKlijent	IBK	IBK	IBK	Dimenzija	Atribut	int		
56	DWH	DimKlijent	TipKlijenta	Klijent tip	Tip klijenta	Dimenzija	Atribut	varchar(30)		
57	DWH	DimKlijent	VrstaKlijenta	Klijent vrsta	Vrsta klijenta	Dimenzija	Atribut	varchar(30)		
58	DWH	DimKlijent	ZupanijaKlijenta	Klijent županija	Županija klijenta	Dimenzija	Atribut	varchar(255)		
59	DWH	DimKlijent	GradOpcinaKlijenta	Klijent grad općina	Grad općina klijenta	Dimenzija	Atribut	varchar(255)		
60	DWH	DimKlijent	NaseljeKlijenta	Klijent naselje	Naselje klijenta	Dimenzija	Atribut	varchar(255)		
61	DWH	DimMjera	IDMjera	ID Mjera	ID Mjere, primarni ključ	Dimenzija	Primarni ključ	int		Da
62	DWH	DimMjera	MjeraSifra	Mjera šifra	Šifra mjere	Dimenzija	Šifra	int		Da
63	DWH	DimMjera	MjeraNaziv	Mjera naziv	Naziv mjere	Dimenzija	Atribut	varchar(255)		
64	DWH	DimMjera	MjeraTipProizvodnje	Mjera tip proizvodnje	Tip proizvodnje mjere	Dimenzija	Atribut	varchar(30)		
65	DWH	DimMjera	MjeraGodina	Mjera godina	Godina mjere	Dimenzija	Atribut	int		
66	DWH	DimFond	IDFond	ID Fond	ID Fonda, primarni ključ	Dimenzija	Primarni ključ	int		Da
67	DWH	DimFond	FondSifra	Fond šifra	Šifra fonda	Dimenzija	Šifra	varchar(10)		Da
68	DWH	DimFond	FondNaziv	Fond naziv	Naziv fonda	Dimenzija	Atribut	varchar(255)		

Slika 42. Detaljne definicije tablica za konformne dimenzije (izvor: Agencija)

U nastavku (Tablica 11.) prikazujemo specifikaciju konformne dimenzije „Gospodarstvo“

Tablica 11. Konformna dimenzija „Gospodarstvo“ s atributima i hijerarhijom (izvor: Agencija)

Kolona	Naziv	Opis	Vrsta kolone	Tip kol. / tip agreg.	Tip podatka	Obavezno	Metodologija prikupljanja
IDGospodarstvo	IDGospodarstvo	IDGospodarstva, primarni ključ	Dimenzija	Primarni ključ	int	Da	ETL
MIBPG	MIBPG	MIBPG	Dimenzija	Šifra	int	Da	ETL
GospodarstvoNaziv	Gospodarstvo naziv	Naziv gospodarstva	Dimenzija	Atribut	varchar(255)		ETL
IBK	IBK	IBK trenutnog klijenta	Dimenzija	Atribut	int		ETL
ZupanijaGospodarstva	Gospodarstvo županija	Županija gospodarstva	Dimenzija	Atribut	varchar(255)		ETL
GradOpcinaGospodarstva	Gospodarstvo grad općina	Grad općina gospodarstva	Dimenzija	Atribut	varchar(255)		ETL
NaseljeGospodarstva	Gospodarstvo naselje	Naselje gospodarstva	Dimenzija	Atribut	varchar(255)		ETL
OIBNositelja	OIB Nositelja	OIB Nositelja	Dimenzija	Atribut	int		ETL
Naziv hijerarhije			Nivo	Naziv nivoa			
Županija – Grad općina – Naselje – Gospodarstvo			1	Županija gospodarstva			
			2	Grad općina gospodarstva			
			3	Naselje gospodarstva			
			4	Gospodarstvo			

Nepoznati članovi dimenzija

Dimenzije u skladištu podataka, prema najboljim praksama, ne bi trebale sadržavati NULL vrijednosti. NULL vrijednost je vrijednost koja se koristi za predstavljanje nepoznatoga dijela podataka. Stoga svaku vrijednost moramo definirali, uključujući i greške u podatcima koje se pojavljuju kod učitavanja u skladište podataka. S obzirom na to da podatak može biti nepoznat susrećemo se sa situacijom koju definiramo kao **neočekivanu NULL vrijednost** ili pogrešan podatak u činjeničnoj tablici, a predstavljaju je svi podatci u činjeničnim tablicama koji imaju vezu prema dimenziji, no ili nisu definirani ili se ne mogu povezati s niti jednim podatkom iz dimenzije. Međutim, ako se dogodi da neki podatak prilikom učitavanja u skladište podataka očekivano nije unesen, jer za to postoji neki poslovni razlog, upisati ćemo ga kao nepostojeći podatak. Tu situaciju okarakterizirati ćemo kao **očekivanu NULL vrijednost** u činjeničnoj tablici.

Mjere (činjenice)

Mjera je vrijednost mjerenja koja predstavlja činjenicu o entitetu sustava o kojem se izvještava. Mjere su podatci koji se na određeni način mogu agregirati, bilo da se radi o sumi, stanju, prosjeku, maksimumu, minimumu ili nekoj drugoj agregaciji. Mjere su podijeljene prema poslovnim procesima, a vezano uz poslovno područje „SIP“ u izvještavanju su podržani sljedeći poslovni procesi: Preuzimanje zahtjeva u ISAP, Administrativne kontrole, Izračuni potpora i plaćanja i Odobravanje plaćanja. Mjere su vidljive u Tablici 10. (Prilog VII.).

Veze između mjera i dimenzija

Kroz matricu mjera i dimenzija (bus matrica) prikazuju se veze između mjera i dimenzija, odnosno definira se mogućnost analize pojedinih mjera prema pojedinim dimenzijama koje predstavljaju različite poglede na podatke. Veza mjere i dimenzije može biti ostvarena ako postoji i u izvornom sustavu. Veze između mjera i dimenzija implementirane su prema bus matrici mjera i dimenzija, kao što je prikazano u Tablici 10. (Prilog VII.).

Arhitektura sustava

Svaki sustav moguće je gledati kroz različite perspektive. Kada se radi o kompleksnim sustavima, nemoguće je dobiti cjelovitu sliku sustava, a da pozornost ne usmjerimo na specifične aspekte sustava. Kod opisa arhitekture OLAP sustava Agencije, odabrani su pogledi na sustav koji zajedno daju cjelovitu sliku sustava: infrastrukturni, arhitekturni, procesni i sigurnosni pogled.

Infrastrukturni pogled daje sliku sustava koja opisuje sustav i njegove funkcionalnosti u koji spadaju fizičke komponente od kojih se sustav sastoji i veze koje povezuju komponente sustava u jednu cjelinu. Sa Slike 43. vidljivo je da je sustav podijeljen u tri sloja (troslojna arhitektura): sloj izvornih sustava, ODS/DWH/OLAP sloj i izvještajni sloj. Središnji dio sustava je ODS/DWH/OLAP server. On prihvaća podatke iz ISUPTSQL1 izvornog sustava i preko ETL procesa dostavlja podatke izvještajnim aplikacijama iz OLAP te ODS baze podataka. Način učitavanja u ODS/DWH/OLAP sloj je „pull“, frekvencija učitavanja je 1x dnevno, preko noći, kada izvještajni sustav nije u uporabi od strane korisnika. Očekivani volumen podataka je 7 GB godišnje. Izvještavanje je izvedeno korištenjem Microsoft Excel i Access alata.

Slika 43. Fizička arhitektura OLAP sustava Agencije (izvor: Agencija)

Arhitekturni pogled daje logičku sliku sustava kroz logičke razine počevši od izvornih sustava, preko *stage* i DWH baze, OLAP strukture, pa sve do izvještajnoga sloja sustava (Slika 44.). Arhitekturni pogled opisuje internu strukturu sustava i interakciju između komponenti sustava.

Slika 44. Dijagram logičke arhitekture (izvor: Agencija)

Logička arhitektura sustava izvedena je u četiri razine:

1. Operativno spremište podataka (ODS baza podataka)

ODS je jedinstveno i centralno mjesto unutar kojeg prikupljamo sve podatke iz transakcijskih sustava. To je centralno mjesto za operativno izvještavanje i bazna tablica za skladište podataka. Sastoji se od ODS baze podataka koja se periodički puni sirovim podatcima iz izvornih sustava. Unutar *exel* datoteke (Slika 45.) popisali smo nazive izvornih sustava, tablica, podataka i putanja unutar same aplikacije gdje su smješteni podatci koji dolaze iz izvornih sustava u ODS. Tako smo osigurali, kroz metapodatke, lakše korištenje, pronalaženje i putovanje kroz potrebne podatke.

	A	B	C	D	E	M
1	Shema	Tablica	Kolona	Naziv	Opis	Napomena
233	ISAP	MOP - obrađeni paketi		H305 - Broj rata		ISA > Odobravanja plaćanja > Izrada naloga > Obrađeni paketi > Prikaži stavke > Export u Excel
234	ISAP	MOP - obrađeni paketi		H306 - ABB kod mjere		ISA > Odobravanja plaćanja > Izrada naloga > Obrađeni paketi > Prikaži stavke > Export u Excel
235	ISAP	MOP - obrađeni paketi		H307 - Postotak CC umanjenja		ISA > Odobravanja plaćanja > Izrada naloga > Obrađeni paketi > Prikaži stavke > Export u Excel
236	ISAP	MOP - obrađeni paketi		H403 - Podsektor		ISA > Odobravanja plaćanja > Izrada naloga > Obrađeni paketi > Prikaži stavke > Export u Excel
237	ISAP	MOP - obrađeni paketi		SPANID - Razdoblje plaćanja		ISA > Odobravanja plaćanja > Izrada naloga > Obrađeni paketi > Prikaži stavke > Export u Excel
238	ISAP	JRDŽ - Animals migration		MIBPG		CSV datoteka učitana u ISAP
239	ISAP	JRDŽ - Animals migration		animal type code		CSV datoteka učitana u ISAP
240	ISAP	JRDŽ - Animals migration		animal code		CSV datoteka učitana u ISAP
241	ISAP	JRDŽ - Animals migration		JIBG		CSV datoteka učitana u ISAP
242	ISAP	JRDŽ - Animals migration		IKG		CSV datoteka učitana u ISAP
243	ISAP	JRDŽ - Animals migration		datum prijave dolaska		CSV datoteka učitana u ISAP
244	ISAP	JRDŽ - Animals migration		datum prijave odlaska		CSV datoteka učitana u ISAP
245	ISAP	JRDŽ - Animals migration		Date of begin		CSV datoteka učitana u ISAP
246	ISAP	JRDŽ - Animals migration		Date of end		CSV datoteka učitana u ISAP
247	ISAP	JRDŽ - Animals		Date of birth		CSV datoteka učitana u ISAP
248	ISAP	JRDŽ - Animals		Father animal code		CSV datoteka učitana u ISAP
249	ISAP	JRDŽ - Animals		Father animal breed		CSV datoteka učitana u ISAP

Slika 45. Shema podataka za potpore iz transakcijskih sustava na ODS (izvor: Agencija)

Tablice u ODS bazi jednake su strukture kao i u izvornom sustavu, što podrazumijeva iste nazive tablica i kolona. Za razliku od izvornih sustava, tablice u ODS bazi nemaju definirane primarne ključeve niti su međusobno povezane stranim ključevima. Podatci se iz izvornih sustava u ODS bazu prikupljaju kroz metadata *framework* izvođača u sirovom obliku, bez transformacija, osim standardizacije prema tipu podataka. Također smo postavili *trigere* na transakcijsku bazu koja bilježi promjene podataka. Međutim, trenutno se ODS baza puni po principu „sve unutra sve van“, noćni *load* počinje u 22 sata, a završava do 8 ujutro. S obzirom na to da nam sada punjenje prelazi 8 sati kada počinje radno vrijeme u Agenciji, uslijed povećanja količine podataka koja dolazi iz izvornih sustava, uskoro prelazimo na inkrementalni način punjenja ODS-a. Svaka baza izvornoga sustava jedna je shema unutar ODS baze podataka. Osim sirovih podatka iz izvornih sustava, unutar ODS baze kreirana je i EXPORT shema u koju se pune podatci iz ostalih shema ODS baze, koji služe za operativno izvještavanje. U ODS-u trenutno imamo 190 tablica i 25 *viewa*.

2. Skladište podataka (DWH baza podataka)

Skladište podataka je centralno mjesto prikupljanja podataka za analitičko izvještavanje. Sastoji se od DWHDB baze podataka koje se pune ETL procesom. Model skladišta podataka je denormalizirane zvjezdaste strukture. Unutar *star* sheme razlikujemo dimenzijske od činjeničnih tablica. Dimenzijskim tablicama osiguravamo različite poglede na podatke, dok su u činjeničnim tablicama mjere koje je moguće agregirati. U DWHDB-u trenutno imamo 53 tablica i 59 *viewa*. Skladišta podataka poslovnih područja (eng. *data martovi*), Slika 46., između sebe se isprepliću tako da jedno skladište podataka može koristiti dimenzije drugog skladišta, npr. dimenzija datum koristit će se unutar svih kocaka. Činjenični podatci se ne koriste između skladišta podataka i tako se osigurava da korisnik koji ima pristup jednoj kocki, jednom poslovnom području, ne može vidjeti npr. “odobrene iznose” koji se nalaze unutar drugoga poslovnog područja, iz druge kocke.

Slika 46. Prikaz skladišta podataka i OLAP kocaka unutar BI projekta (izvor: Agencija)

3. Multidimenzionalna baza podataka (OLAP)

Multidimenzionalna baza podataka osigurava nam kreiranje multidimenzionalne kocke. Kocka u sebi sadrži agregirane podatke kojima se koristimo za analizu i izvještavanje. U sljedećim tablicama (12 – 17), prikazan je dio strukture OLAP kocke za SIP.

Tablica 12. Specifikacija kocke (izvor: Agencija)

Kocka	Opis	Lokacija	Referentni proces	Korisnici podataka
SIP	Kocka za odobravanje izravnih plaćanja	DWH/OLAP server	Središnji izvještajni sustav	Administratori, OLAP korisnici

Tablica 13. Popis dimenzija u sustavu (izvor: Agencija)

Naziv dimenzije	Opis	Izvor podataka
ABB	dimenzija s ABB šiframa	OLAP.DimABB
Barkod	dimenzija s barkodovima	OLAP.Barkod
Datum isplate	dimenzija s kalendarom	OLAP.Datum
Datum odobravanja	dimenzija s kalendarom	OLAP.Datum
Datum poslano na isplatu	dimenzija s kalendarom	OLAP.Datum
Klijent	dimenzija s listom klijenata	OLAP.DimKlijent
Natječaj	dimenzija s listom natječaja	OLAP.Natjecaj
Operacija	dimenzija s listom operacija	OLAP.Operacija
Fond	dimenzija s listom fondova	OLAP.Fond
Gospodarstvo	dimenzija s listom gospodarstava	OLAP.Gospodarstvo
Omotnica	dimenzija s listom gospodarstava	OLAP.DimOmotnica
Potpora	dimenzija s listom potpora	OLAP.DimPotpora
Proizvodna godina	dimenzija s kalendarom	OLAP.Datum
Tip plaćanja	dimenzija s listom tipova plaćanja	OLAP.DimTipPlacanja

Tablica 14. Primjer jedne od dimenzija razložene na atribute (izvor: Agencija)

Dimenzija Datum odobravanja				
Naziv atributa	***Opis***	***Jedinstveno ime***		
Godina	Godina	[Datum odobravanja].[Godina].[Godina]		
Fin. godina	Godina	[Datum odobravanja].[Financijska godina].[Financijska godina]		
Mjesec	Mjesec	[Datum odobravanja].[Mjesec].[Mjesec]		
Hijerarhije dimenzije Datum odobravanja				
Hijerarhija	*Atribut*	*Razina*	*Opis*	*Jedinstveno ime*
Razdoblja	Godina	1	Godina	[Datum odobravanja].[Vremenska razdoblja].[Godina]
	Kvartal	2	Kvartal	[Datum odobravanja].[Vremenska razdoblja].[Kvartal]
	Mjesec	3	Mjesec	[Datum odobravanja].[Vremenska razdoblja].[Mjesec]
	Dan	4	Dan	[Datum odobravanja].[Vremenska razdoblja].[Dan]

Tablica 15. Popis grupa mjera za kocku (izvor: Agencija)

Kocka	Grupa mjere	Izvor podataka	Korisnici
SIP	Brojevi gospodarstava	OLAP.FactBrojGospodarstavaKonacnoOdobreno OLAP.FactBrojGospodarstavaOdobrenoMOP OLAP.FactBrojGospodarstavaPodneseno OLAP.FactBrojGospodarstavaPopunjeno OLAP.FactBrojGospodarstavaPoslanoNaIsplatu OLAP.FactBrojGospodarstavaTrazeno OLAP.FactBrojGospodarstavaUtvrdjeno OLAP.FactBrojGospodarstavaVisegodisnjeSankcije OLAP.FactBrojGospodarstavaVisestrukeSukladnosti OLAP.FactBrojGospodarstavaZaIsplatuMOP OLAP.FactBrojGospodarstavaZaObradu	Admin, OLAP korisnici
	Iznosi	OLAP.FactOdobravanjeIznosi	Admin, OLAP korisnici
	Količine	OLAP.FactOdobravanjeKolicine	Admin, OLAP korisnici
	Prava na plaćanje	OLAP.FactPravaNaPlacanje	Admin, OLAP korisnici

Tablica 16. Matrica veza između dimenzija i grupa mjera za područje SIP-a (izvor: Agencija)

Dimenzija	Grupa mjera			
	Brojevi gospodarstava	Iznosi	Količine	Prava na plaćanja
Fond		✓	✓	
Gospodarstvo	✓	✓	✓	✓
Omotnica		✓	✓	
Potpora	✓	✓	✓	
Proizvodna godina	✓	✓	✓	✓
Tip plaćanja		✓		
Tip Retka Paketa		✓		
Datum	✓	✓	✓	✓

Tablica 17. Prikaz manjega isječka iz tablice mjera (izvor: Agencija)

Mjera	Operacija	Grupa mjera
[Measures].[Broj gospodarstava odobreno ISAP]	COUNT DISTINCT	Brojevi gospodarstava
[Measures].[Broj gospodarstava podneseno]	KALKULACIJA	Brojevi gospodarstava
[Measures].[Broj gospodarstava za isplatu MOP]	KALKULACIJA	Brojevi gospodarstava
[Measures].[Iznos odobreno MOP]	SUM	Iznosi
[Measures].[Iznos utvrđeno smanjenja i isključenja]	KALKULACIJA	Iznosi

4. Metadata baza podataka

Svi sustavi su heterogeni jer unutar sustava imamo različite tehnologije, proizvođače, različite strukture podataka (različite šifre za iste podatke, različite jezike, pisma, valute, mjerne jedinice itd.). Upravljanje heterogenim sustavima najbolje je pomoću metapodataka. U Agenciji smo kreirali bazu metapodataka kojom se koristimo za dokumentiranje i automatizirano upravljanje sustavom, npr. u njoj između ostaloga čuvamo podatke o pokretanju ETL procesa i greške koje nastanu tijekom izvođenja. Implementaciju baze metapodataka napravili smo nakon instalacije i konfiguracije infrastrukture i prije implementacije operativnoga spremišta i skladišta podataka.

Prednosti korištenja metapodataka u Agenciji jesu: automatizacija sustava, brzina implementacije, standardizacija sustava, inkrementalno učitavanje podataka, znamo tko su vlasnici podataka, pratimo tijek podataka i promjene nad podatcima, nadzor i administracija sustava. Model metapodataka u Agenciji sastoji se od tri dijela (Slika 47.):

U poslovne metapodaci spadaju podatci od serverske razine do razine kolone u tablici. U poslovne metapodatke također spadaju svi izvorni sustavi, operativno spremište podataka, skladište podataka, multidimenzionalna baza podataka i izvještajni alati Agencije. *Tehnički metapodatci* – sadrže definicije procesa sustava što su npr. ETL procesi za učitavanje podataka, procesi za eksport podataka, backup/restore procedure i sl. *Operativni metapodatci* – omogućuju nam automatizirani monitoring i administraciju sustava i sadrže logove pojedinačnih pokretanja procesa i grešaka koje su se eventualno dogodile tijekom pokretanja.

Slika 47. Model metapodataka u Agenciji (izvor: Agencija)

Procesni pogled opisuje procese u sustavu, uključujući proces učitavanja podataka (ETL) te proces upravljanja konfiguracijom sustava. Procesni pogled daje redoslijed svih koraka procesa i s pomoću njega pratimo na koji se način procesi unutar sustava odvijaju. Na taj način imamo

pregled kako funkcionira sustav kao cjelina. Proces učitavanja podataka sastoji se od sljedećih koraka:

1. učitavanje tečaja s WEB servisa na kojemu se nalazi službeni mjesečni tečaj za valutu
2. učitavanje podataka u ODS bazu – podatci iz ISA (poslovni podatci vezani uz potpore)
3. punjenje EXPORT sheme u ODS bazi – to su predefinirani pogledi (*viewovi*) na neke skupine podataka iz sustava koje se često koriste
4. učitavanje dimenzijskih podataka u DWH bazu (dimenzije SIP)
5. učitavanje dimenzijskih podataka u DWH bazu (*fact tabele* SIP)
6. procesiranje kocke – završni korak u procesu učitavanja podataka jest procesiranje OLAP baze u SQL Server Analysis Services serveru, u kojem se popunjavaju podatci iz skladišta podataka u dimenzije i mjere koje se nalaze u strukturi kocke unutar baze.

Sigurnosni pogled opisuje korištene načine autentikacije i autorizacije korisnika kod pristupa sustavu te mehanizme ograničavanja pristupa podatcima. Sigurnosni pogled definira sigurnosne dijelove sustava kao što su:

Mrežna sigurnost i prijenos podataka – Sustav se koristi standardnom mrežnom infrastrukturom i sigurnosnom politikom Agencije. SQL Serveru pristupa se preko standardnoga porta xxxx, dok se SQL Server Analysis Services Serveru pristupa preko standardnog porta xxxx.

Spremanje osjetljivih podataka – Podatci su spremljeni na hardverskoj i sistemskoj infrastrukturi fizički smještenoj u Agenciji. Fizički pristup bazama podataka i datotekama dozvoljen je isključivo administratorima sustava u Agenciji.

Sigurnosna politika – Definira korištenje informacijskih sustava na razini Agencije.

Korisnički pristup – Autorizacija je riješena tako da je korisnicima koji pristupaju sustavu dodijeljena određena uloga u ActiveDirectory sustavu. Nakon što se korisnik uspješno autentificira u sustavu, prema definiranim ulogama, na razini ActiveDirectorya (Tablica 18.), dodjeljuju mu se i prava vezana uz pristup podatcima. Pregled autorizacijskih mehanizama donosi Slika 48.

Tablica 18. Uloge i prava korisnika sustava (izvor: Agencija)

Uloga/AD grupa	Opis uloge	Prava za ulogu	AD grupa
Administrator sustava	Uloga koju imaju administratori sustava	Čitanje i pisanje svih podataka nad DWH Stage i Core i OLAP DB	DB administratori iz Sektora za informatiku
OLAP korisnik	Poslovni korisnici za analizom i izvještavanjem	Čitanje svih podataka u OLAP bazi podataka	Korisnici iz Sektora za izravna plaćanja

Slika 48. Autorizacijski mehanizmi (izvor: Agencija)

Backup i restore procedura – *Full backup* DWHCore baze podataka događa se automatski, svaku nedjelju prema proceduri (Slika 49.). Na dnevnoj razini radi se diferencijalni *backup* iste baze. *Backup* možemo pokrenuti i ručno s obavezno uključenom opcijom "Copy-only Backup" kako se ne bi poremetili *backup* planovi. U slučaju potrebe ručni *backup* baze podataka moguće je napraviti koristeći se SQL Server Management Studio i sam postupak je definiran kroz alat u proceduri Agencije. *Restore procedura* – po svojoj prirodi ne spada u kritične sustave i odvija se prema proceduri (Slika 50.). U slučaju ispada sustava, *restore* sustava napravi se unutar jednoga dana. U slučaju potrebe, *restore backupa* baze podataka moguće je napraviti koristeći se SQL Server Management Studio i sam postupak je definiran kroz alat u proceduri Agencije.

Slika 49. Hodogram *backup* procedure (izvor: Agencija)

Slika 50. Hodogram *restore* procedure (izvor: Agencija)

Upravljanje kapacitetom – Kako bi se osigurao nesmetani rad OLAP sustava, moramo paziti o diskovnom prostoru na kojem su smještene baze podataka (podatci i logovi). Procjena rasta količine podataka u razdoblju od jedne godine prikazuje Tablica 20.

Tablica 19. Procjena rasta količine podataka u razdobljuod jedne godine (izvor: Agencija)

Podatkovni sustav	Trenutna količina podataka	Procjena količine podataka kroz 1 god.
SQL Server – skladište podataka, DWHStage i DWHCore baze – podatci i logovi	18 GB	28 GB
SQL Server Analyis Services – OLAP – podatci i logovi	300 MB	470 MB

4.4 OCJENA USPJEŠNOSTI IMPLEMENTIRANOGA SUSTAVA

1. Kocke sa svojim dimenzijama osigurale su nam drugačiji pogled na podatke jer povećavaju broj kombinacija pogleda nad podatcima. Time smo povećali broj različitih izvještaja i osigurali dublji analitički pogled na podatke kojeg do sada nismo imali. Te kombinacije koje nam sada omogućuju drugačije poglede istih stvari pomogle su nam kod donošenja sigurnijih poslovnih odluka za Agenciju, ali i za nadležno Ministarstvo poljoprivrede koje Agencija i izvješćuje. Nakon što sve poslovne vertikale Agencije posložimo unutar OLAP tehnologije, povezivanje tih sustava, kao i povezivanje s drugim sustavima unutar poljoprivrede, omogućilo bi u prvoj fazi osiguravanje još raznovrsnijeg izvještavanja iz postojećih podataka, dok u drugoj fazi možda i pokretanje procesa rudarenja podataka i otkrivanja skrivenoga znanja koje ti podatci nose.
2. Uspostavom automatiziranoga procesa punjenja centralnoga izvještajnog sustava s bazom metapodataka i stvaranjem agregiranih podataka povećala nam se brzina dohvata izvještaja i eksporta podataka iz sustava kao i smanjenje opterećenja na IT djelatnike i naprednije korisnike sustava. Nekada su nam za izradu izvještaja trebali dani, sada minute ili sati. Zbog toga se povećalo ukupno korištenje podataka Agencije jer nam za izradu izvještaja sada treba puno manje vremena. Iskustva korisnika kažu da je izrada izvještaja postala više kao „igra“. Djelatnici rado obavljaju posao jer na brz, intuitivan i nov način stvaraju izvještaje potrebne za svoj svakodnevni rad.
3. Automatizacijom procesa preko baze metapodataka osigurali smo da se za svaki element sustava zna izvorni podatak, kao i povijest njegovih transformacija. Tako sustav izvještava sam o sebi. Sada pratimo porijeklo (eng. lineage) i tijek promjene podatka od promjena u izvornim sustavima (vanjskim i unutarnjim) preko ODS-a i dolaska podatka u OLAP. Jasno možemo utvrditi tko je promijenio i kada se promijenio podatak, čime rizičan sustav isplate potpora postaje kontroliraniji.
4. Promjenom modela razvoja softvera, gdje je svaka poslovna vertikala dobila svoj specijalizirani razvojni tim, osigurali smo prostor da se projekt uspostave centralnoga izvještajnog sustava na OLAP tehnologiji prepozna kao posebna poslovna vertikala, kao jednako vrijedan projekt svim ostalim poslovnim vertikalama, čime je OLAP projekt dobio svoj razvojni tim koji se samo time bavi. Time smo osigurali kontinuitet projekta i povećali šanse bržega završetka projekta.
5. Ulaskom podataka u OLAP za tu poslovnu vertikalu imamo jednu verziju istine. Jednu verziju istine osiguravaju procesi standardizacije koji obuhvaćaju:
    a. podatci kojima se koristimo za izvještavanje su centralizirani (ODS i OLAP kocke)

b. zna se tko ima pristup podatcima
c. jedinstvena sučelja za pristup podatcima
d. formalizirani su načini kako podatci izlaze iz sustava (*dashboard, exel, PowerBI*).

6. Uspostavom centraliziranoga procesa upravljanja izvještajnim sustavom preko izvornih sustava, ODS-a i kocki unutar OLAPA-a ispunili smo zahtjeve koje se odnose na: dostupnost informacijama, konsolidaciju izvještajnoga procesa radi povećanja kvalitete informacija, mogućnosti mjerenja učinkovitosti procesa, ograničenje pristupa povjerljivim podatcima, čime smo smanjili opterećenje na resurse IT - a.
7. Uspostavom centralnoga sustava izvještavanja, tehnički smo postavili sustav tako da postoji jedan izvor iz kojeg se dohvaćaju podatci za izvještaje. Tako smo smanjili broj predefiniranih i *ad hoc* izvještaja iz sustava koje su do sada dohvaćali IT stručnjaci. To smo osigurali edukacijom novih poslovnih korisnika koji sada sami dohvaćaju podatke.
8. Potaknuti izvještajnim sustavom Agencije, Ministarstvo poljoprivrede odlučilo se za sličan projekt, naziva PIUS (Poljoprivredni izvještajno upravljački sustav), unutar kojeg žele izgraditi kocke za ostale sustave u poljoprivredi koje će zajedno s podatcima iz OLAP-a Agencije stvoriti izvještajni OLAP sustav na razini Ministarstva poljoprivrede. Projekt je započeo 2020. godine, uspostavom Registra poljoprivrednih subjekta u poljoprivredi koji ima zadatak objediniti sve subjekte unutar poljoprivrede iz svih sustava koji su u portfelju Ministarstva te bi služio kao centralni sustav za upravljanje identitetima u poljoprivredi. To znači da taj sustav ne bi sadržavao sve informacije koje se u raznim podsustavima čuvaju o tim identitetima, već bi znao u kojim sustavima se identitet koristi i u kojoj ulozi, te bi omogućavao integriranim sustavima centralni „identity provider servis“. Izrada ovoga sustava preduvjet je za izradu i uspostavu kvalitetnoga izvještajnog upravljačkog sustava Ministarstva i kasnije možebitnog uključivanja Ministarstva u projekte integracija informacijskih sustava na nacionalnoj razini.
9. Ovaj projekt nam je i proširio paradigmu procesa razvoja softvera, koja je prije značila da projekti razvoja softvera počinju u Ministarstvu, a završavaju kada je novac na računu korisnika. Nova paradigma sada je proširena i glasi da proces razvoja softvera započinje u Ministarstvu, gdje se definiraju potrebni ulazni podatci, a završava u OLAP-u, gdje se dobiveni podatci spremaju i koriste za izvještavanje i analitiku.

5 ZAKLJUČAK

Uspostavom sustava za analitičku obradu podataka za isplatu poticaja u poljoprivredi, u Agenciji se dogodio jedan novi koncept unutar podataka. Uspostavom novoga koncepta znamo kako podatci putuju i što sve prolaze dok se u konačnici ne pokažu na nekom izvještaju. Sada je sve dobilo jedan viši smisao jer s jednom verzijom istine sigurnije nego do sada predstavljamo i šaljemo svoje podatke korisnicima i trećim osobama. Najvažnija od svega jest činjenica da sada sami više vjerujemo svojim izvještajima i podatcima jer znamo da oni izlaze iz jednoga centralnog i jedinstvenoga procesa. Ubrzali smo dohvaćanje izvještaja, čime smo povećali zadovoljstvo korisnika koji izrađuju izvještaje. Tako smo povećali svoju produktivnost i do sada jedan zamoran proces pretvorili u nešto zanimljivo, dinamično i lako dohvatljivo. Podigla se svijest o važnosti, količini i značenju podataka koje Agencija posjeduje. Osjećamo se zadovoljnije i uspješnije jer imamo sustav izvještavanja kojem vjerujemo i na koji smo ponosni, pogotovo kad vidimo da sustav nadilazi naše poslovne granice, kada vidimo da se drugi žele njime koristiti i na našim temeljima graditi svoje sustave izvještavanja na dobrobit cjelokupnoga sustava u poljoprivredi.

OLAP analitika pridonosi kvalitetnijem poslovnom odlučivanju koje može utjecati na poljoprivrednu politiku Ministarstva. Zakoni i pravilnici u poljoprivredi definiraju poslovne procese i podatke koje će se prikupljati i obrađivati u poslovnim sustavima Agencije. Agencija je informatizacijom poslovnih procesa za poslovne sustave koje su u njenoj nadležnosti osigurala da podatci sada završe u OLAP kockama. Možemo reći da je Agencija uspostavom OLAP izvještajnoga sustava poboljšala prirodni kružni tok kojim se prvotno postavljeni sustav može konstantno unaprjeđivati na temelju prikupljenih, obrađenih i analiziranih višedimenzionalnih podataka jer sada zbog većega broja kombinacija, pogleda na podatke, imamo veću količinu spoznaja nego što smo imali do sada. Te nove spoznaje mogu pridonjeti poboljšanju poslovnih procesa i programa postavljenih unutar hrvatske poljoprivrede.

Sljedeći korak koji čeka Agenciju ide u smjeru većeg uključivanja poslovnih korisnika u procese izvještavanja Agencije s ciljem ukorijenjenja implementiranih procesa izvještavanja u poslovne procese Agencije. Daljnji korak mogao bi ići i u smjeru boljega razumijevanja pojma rudarenja podataka i mogućnosti koje bi ta tehnologija donijela u otkrivanju skrivenoga znanja iz podataka Agencije, a sve za dobrobit hrvatske poljoprivrede.

LITERATURA

1. Bigus, J.P. (1996). Data Mining with Neural Networks
2. Ćurko, K. (2001.), Skladište podataka – sustav za potporu odlučivanju. Ekonomski pregled, 52 (7-8) 840-855
3. http://www.altaplana.com/olap/glossary.html, 25.04.2020.
4. https://hr.wikipedia.org/wiki/Poslovna_inteligencija, 23.4.2019.
5. https://www.gartner.com/it-glossary/business-intelligence-bi/ 3.7.2019.
6. https://panoply.io/data-warehouse-guide/data-warehouse-architecture-traditional-vs-cloud/, 20.11.2020.
7. https://www.xplenty.com/blog/etl-vs-elt/#etl, 2.5.2020.
8. https://www.xplenty.com/blog/etl-vs-elt/#etl, 2.5.2020.
9. https://en.wikipedia.org/wiki/Staging_(data), 16.04.2020.
10. https://www.hrleksikon.info/definicija/ascii.html, 3.5.2020.
11. https://en.wikipedia.org/wiki/Metadata_repository, 26.04.2020.
12. https://olap.com/types-of-olap-systems/, 8.5.2020.
13. https://cracklogic.com/olap-tutorial/, 12.5.2020.
14. https://docs.oracle.com/cd/E29633_01/CDMOG/GUID-428F33D4-04D0-4EDA-BA60-96EF3988C803.htm, 12.5.2020.
15. https://hbr.org/2012/10/big-data-the-management-revolution, 17.10.2020.
16. https://www.apprrr.hr/o-nama/ 1.6.2019.
17. Inmon, W.H. (1996.), Building the Data Warehouse (Second Edition). New York: John Wiley & Sons
18. Kimball, R., Ross, M. (2002.), The Data Warehouse Toolkit: The Complete Guide to Dimensional Modeling, (Second Edition), New York: John Wiley & Sons.
19. Kimball, R., Caserta, J. (2004.), The Data Warehouse ETL Toolkit: Practical Techniques for Extracting, Cleaning, Conforming and Delivering Data, Wiley
20. Kimball, R., Ross, M. (2013.), The Data Warehouse Toolkit: The Definitive Guide to Dimensional Modeling, 3rd Edition, New York: John Wiley & Sons
21. Liautaud, B. (2001.), E-Business Intelligence: Turning Information into Knowledge into Profit. McGraw-Hill, New York
22. Michalewicz, Z., Schmidt, M., Michalewicz, M., Chiriac, C., (2006.), Adaptive Business Intelligence. Springer
23. Panian, Ž., Klepac, G. (2003.), Poslovna Inteligencija, Zagreb, Masmedia
24. Panian, Ž., i suradnici (2007.), Poslovna inteligencija – studije slučajeva iz Hrvatske prakse, Zagreb, Narodne novine d.d.
25. Panian, Ž., Ćurko, K., i dr. (2010.), Poslovni informacijski sustavi, Zagreb, Element
26. Pejić Bach, M., (2003). Data Mining Applications in Public Organizations, IEEE
27. Pejić Bach, M., (2005). Rudarenje podataka u bankarstvu. Zbornik Ekonomskog fakulteta u Zagrebu, Vol. 3, No.1, str. 181 – 193.
28. Ponniah, P., (2001.) ,Data Warehousing Fundamentals. New York: John Wiley¸& Sons
29. Ponniah, P., (2008.), Data Warehousing Fundamentals For IT Professionals, Second Edition, New York: John Wiley & Sons.
30. Rud, Olivia (2009.), Business Intelligence Success Factors: Tools for Aligning Your Business in the Global Economy. Hoboken, N.J: Wiley & Sons
31. Srića, V. (2004.), Inventivni menadžer u 100 lekcija, 2. izdanje. Zagreb, Delfin, Znanje

POPIS SLIKA

Slika 1. Tradicionalni koncept poslovne inteligencije, str. 6
Slika 2. Koncept „Adaptive Business Intelligence“, str. 7
Slika 3. Životni ciklus sustava poslovne inteligencije (skica autora), str. 8
Slika 4: Prikaz procesa i strukture skladišta podataka (skica autora), str. 14
Slika 5. Glavni termini dimenzijskog modela i njihova međusobna povezanost, str. 15
Slika 6. Prikaz dimenzijskih modela podataka u obliku kocke (slika autora), str. 17
Slika 7. Prikaz dimenzijskog modela u obliku zvijezde, star shema (slika autora), str. 18
Slika 8. Dijagram troslojne arhitekture skladišta podataka, str. 19
Slika 9. ETL proces, str. 21
Slika 10. ELT proces, str. 22
Slika 11. Model apliciranja podataka prema P. Ponniah, str. 33
Slika 12. Primjer elemenata metapodataka za entity „Customer“, str. 34
Slika 13. Položaj metapodataka u skladištu podataka, str. 36
Slika 14. Rotacija podataka, str. 39
Slika 15. Raslojavanje podataka, str. 39
Slika 16. Isijecanje podataka, str. 40
Slika 17. Metode za detaljiziranje podataka (Drill Up i Drill Down), str. 40
Slika 18. Proces rudarenja podataka, prilog I, str. 99
Slika 19. Prikaz cjelokupnoga tijeka procesa za IAKS proces (izvor: Agencija), prilog II, str. 100
Slika 20. Prikaz procesnoga modela prema sudionicima u procesu (izvor: Agencija), prilog III, str. 101
Slika 21. Izravne potpore – detaljni procesni prikaz (izvor: Agencija), prilog IV, str. 102
Slika 22. Poslovni procesi Agencije (skica autora), str. 53
Slika 23. Metodologija implementacije prema Kimball-u (izvor: Agencija), str. 55
Slika 24. Proces održavanja i nadogradnji razvoja OLAP-a u Agenciji (izvor: Agencija), str. 58
Slika 25. Prvi koncept poslovnog izvještavanja u Agenciji (izvor: Agencija), str. 59
Slika 26. Izvještaji kroz modul „Poslovno upravljanje“ (izvor: Agencija), str. 59
Slika 27. Izvještaji via SSRS (SQL Server/Reporting Services) (izvor; Agencija), str. 59
Slika 28. Drugi koncept poslovnog izvještavanja u Agenciji (izvor: Agencija), str. 60
Slika 29. Treći koncept poslovnog izvještavanja u Agenciji (izvor: Agencija), str. 61
Slika 30. Alati poslovnog izvještavanja u Agenciji (izvor: Agencija), str. 61
Slika 31. Ciljna slika izvještajnog koncepta u Agenciji (izvor: Agencija), str. 62
Slika 32. Predefinirani exporti preko ODS-a (izvor: Agencija), str. 67
Slika 33. Ulaz u nadzornu ploču Agencije vezano za isplate potpora (izvor: Agencija), str. 67
Slika 34. Nadzorna ploča za „Pregled isplata za proizvodnu 2019 godinu“ (izvor: Agencija), str. 67
Slika 35. Drop down podataka za potpore za „Osječko baranjsku županiju“ (izvor: Agencija), str. 67
Slika 36. Interaktivna nadzorna ploča za pametni telefon za potpore (izvor: Agencija), str. 69
Slika 37. Prikaz podataka za poljoprivrednika za izravna plaćanja za 2019. (izvor: Agencija), str. 70
Slika 38. Prikaz podataka za županije za potpore izravnih plaćanja za 2019. (izvor: Agencija), str. 70
Slika 39. Prikaz podataka prema vrsti potpore za izravna plaćanja za 2019. (izvor: Agencija), str. 70
Slika 40. Model DWH/BI sustava za poslovno područje „SIP“ (izvor: Agencija), str. 78
Slika 41. Izvod iz Rječnika pojmova (izvor: Agencija), str. 80
Slika 42. Detaljne definicije tablica za konformne dimenzije (izvor: Agencija), str. 80
Slika 43. Fizička arhitektura OLAP sustava Agencije (izvor: Agencija), str. 82

Slika 44. Dijagram logičke arhitekture (izvor: Agencija), str. 83
Slika 45. Shema podataka za potpore iz transakcijskih sustava na ODS (izvor: Agencija), str. 83
Slika 46. Prikaz skladišta podataka i OLAP kocaka unutar BI projekta (izvor: Agencija), str. 84
Slika 47. Model metapodataka u Agenciji (izvor: Agencija), str. 87
Slika 48. Autorizacijski mehanizmi (izvor: Agencija), str. 89
Slika 49. Hodogram backup procedure (izvor: Agencija), str. 90
Slika 50. Hodogram restore procedure (izvor: Agencija), str. 90

POPIS TABLICA

Tablica 1. Usporedba OLAP sustava i skladišta podataka u radu s podatcima, str. 39
Tablica 2. Metode rudarenja podataka, str. 46
Tablica 3. Načini ostvarenja programa (izvor: Agencija), str. 54
Tablica 4. WBS za projekt uspostave izvještajnog sustava u Agenciji (izvor: Agencija), prilog V, str. 103
Tablica 5. Uloge i odgovornosti ljudi na projektu (izvor: Agencija), prilog VI, str. 104
Tablica 6. Test case scenario za provjeru kompenzacija (izvor: Agencija), str. 64 i 65
Tablica 7. Brojčani pokazatelji za isplatu potpora za proizvodnu 2018. (izvor: Agencija), str. 76
Tablica 8. Procesi unutar Programa izravnih potpora (SIP) (izvor: Agencija), str. 79
Tablica 9. Izvorni sustavi za OLAP kocku, str. 79
Tablica 10. Prikaz mjera i dimenzija za programe potpora u poljoprivredi (izvor: Agencija), prilog VII, str. 105
Tablica 11. Konformna dimenzija „Gospodarstvo“ (izvor: Agencija), str. 81
Tablica 12. Specifikacija kocke (izvor: Agencija), str. 85
Tablica 13. Popis dimenzija u sustavu (izvor: Agencija), str. 85
Tablica 14. Primjer jedne od dimenzija razložene na atribute (izvor: Agencija), str. 85
Tablica 15. Popis grupa mjera za kocku (izvor: Agencija), str. 86
Tablica 16. Matrica veza između dimenzija i grupa mjera za područje SIP-a (izvor: Agencija), str. 86
Tablica 17. Prikaz manjeg isječka iz tablice mjera (izvor: Agencija), str. 86
Tablica 18. Uloge i prava korisnika sustava (izvor: Agencija), str. 88
Tablica 19. Procjena rasta količine podataka u razdoblju od jedne godine (izvor: Agencija), str. 90

ŽIVOTOPIS

OSOBNI PODATCI

Ime i prezime:	Ivan Šćepanović
Datum rođenja:	09. prosinca 1969.
Adresa:	Bukovačka cesta 282B, 10000 Zagreb
Mobitel:	098 312459
e-mail:	ivan.scepanovic@apprrr.hr

OBRAZOVANJE

Razdoblje	Naziv ustanove	Smjer
2012. –	Ekonomski fakultet Sveučilišta u Zagrebu	Informatički menadžment
1989. – 1998.	Fakultet Agronomskih znanosti Sveučilišta u Zagrebu	Stočarstvo
1984. – 1988.	Centar za usmjereno obrazovanje Hvar	Ekonomski

ZNANJE I VJEŠTINE

Razdoblje	Ustanova	Usavršavanje	Znanje i vještine
2019.	Nenad Trajkovski	Radionica	Što je projekt i kako se projektno organizirati
2019.	Poslovna učinkovitost	Specijalistička edukacija	Analiza i vizualizacija podataka u Power BI
2018.	PMI	Radionica	Agile values and principles and how to apply them in the project environment
2018.	CROZ	Tečaj	Uvod u agilni pristup razvoju softvera
2018.	CROZ	Tečaj	Cjelovit pristup razvoju softvera
2014.	Ascendo	Tečaj	Identifikacija i dokumentiranje poslovnih procesa
2013.	Algebra	Seminar	Upravljanje kvalitetom u IT projektima
2007.	Algebra	Seminar	Projekt portfolio management
2006.	Algebra	Seminar	MS Project – Planiranje i upravljanje projektima
2005.	Algebra	Seminar	Financijsko planiranje i praćenje projekata
2005.	Algebra	Seminar	Osnovne tehnike projektnog managementa
2004.	Pro – Anima	Program usavršavanja	Programer poslovnih aplikacija – ASP.NET
2001.	Algebra	Program usavršavanja	Računalni operator za izradu internetskih stranica
			Napredno korištenje MS Office alata
			Vozačka dozvola A, B, C i E kategorije
			Engleski jezik – aktivno znanje u govoru i pismu

PROFESIONALNO ISKUSTVO

Razdoblje	Naziv firme	Radno mjesto
24.07.2017. – danas	Agencija za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju	Viši stručni savjetnik
01.11.2012. – 24.07.2017.	Agencija za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju	Pomoćnik ravnatelja za informacijsko upravljanje i sigurnost informacija
01.12.2004. – 01.11.2012.	Hrvatska poljoprivredna agencija	Načelnik odjela za ICT
01.06.2003. – 01.12.2004.	Hrvatski stočarski centar	Voditelj odjela za potpore i kredite
01.05.2002. – 01.06.2003.	Hrvatski stočarsko selekcijski centar	Viši stručni suradnik, Pododjel za uzgoj i selekciju goveda
01.08.2000. – 01.05.2002.	Hrvatski stočarsko selekcijski centar	Stručni suradnik, Pododjel za uzgoj i selekciju goveda
01.08.1999. – 01.08.2000.	Hrvatski stočarsko selekcijski centar	Stručni suradnik – vježbenik, Pododjel za uzgoj i selekciju goveda

PRILOZI

PRILOG I

Slika 18. Proces rudarenja podataka

PRILOG II.

Slika 19. Prikaz cjelokupnoga tijeka procesa za IAKS proces (izvor: Agencija)

PRILOG III.

Poljoprivrednik
AGRONET
Pregled zahtjeva za upis u registre
Pregled izmjena podataka
Pregled zvanja i izmjena zahtjeva
OSTALO
Ulaz podataka u ARKOD
Prijava stoke u ARZ
Djelatnici APPRRR
REGISTRI
UPG
EK
ZOT
Ostali registri
IK
Djelatnici APPRRR
ISAP
Kontrola zahtjeva
Kreiranje paketa
ISSP
Kontrola zahtjeva
Kreiranje paketa
ISUT
Kontrola zahtjeva
Pripremu i ažuriranje paketa
Djelatnici APPRRR
MOP
Obrada paketa
Izrada naloga
FINANCIJE
Obrada naloga
Obrada dugova
Izrada dokaznica
IZVJEŠTAVANJE
Izrada izvještaja
Generiranje IK Tablica
OLAP
Vanjske institucije
FINA
Obrada dokaznica za Plaćanje Garancija
Obrada naloga za isplatu
OKT
Pregled, unos i izmjena rezultata kontrole
Djelatnici APPRRR
PISARNICA
Uradbeni ažuriranje zahtjeva
Uradbeni ažuriranje odbijanja
KNT
Pregled, unos i izmjena rezultata kontrole
SAP
Obrada dokaznica
Izrada naloga za plaćanje
GIS
Pregled GEO portala
Ažurirani podaci i obavijesti
Zahtjev sa uvrdi i promjenom
Podaci o ŽIVGBilim periodima
Uradbeni ažuriranje zahtjeva
Podaci i zahtjevi
Rezultati OKT
Rezultati KNT
Odluke o dekvalifikaciji prava
Podaci o kontroli
Podaci o kontroli
Podaci o kontroli
Podaci o kontroli
Podaci o ažuriranju
Podaci o ažuriranju
Podaci o ažuriranju
Podaci o ažuriranju
Podaci o nalozima
Podaci o ažuriranju
Podaci o nalozima
Podaci o ažuriranju
Podaci o ažuriranju
Podaci o ažuriranju
Podaci o ažuriranju

PRILOG IV.

Slika 21. Izravne potpore – detaljni procesni prikaz (izvor: Agencija)

PRILOG V.

Tablica 4. WBS za projekt uspostave izvještajnoga sustava u Agenciji (izvor: Agencija)

Rb	Razina kontrole	Razina planiranja	Opis aktivnosti i isporuka
1	1. Uspostava infrastrukture	Dizajn infrastrukture sustava	Definiranje infrastrukture sustava i veza između komponenata
2		Instalacija i konfiguracija testne okoline	Instalacija i konfiguracija SQL Servera (ODS, DWH, OLAP i MetaData) i SharePointa
3		Instalacija i konfiguracija produkcijske okoline	Instalacija i konfiguracija SQL Servera (ODS; DWH, OLAP i MetaData) i SharePointa
4		Uspostava DWH/BI platforme	Uspostava baze metapodataka za dokumentiranje podataka i procesa, te razvojne ETL platforme
5		Migracija postojećeg OLAP-a	Migracija DWH i OLAP-a vezano uz izravna plaćanja na novu infrastrukturu
6	2. Poslovna analiza	Analiza zahtjeva	Objedinjena AS-IS i TO-BE analiza: organizacija, poslovna područja, poslovni procesi, izvorni sustavi i dostupni podaci; izvještaji
7		Kreiranje specifikacije zahtjeva	Kreiranje dokumenta Specifikacije zahtjeva u kojem se specificiraju modeli podataka, procesi prikupljanja i podataka, te izvještaji
8	3. Dizajn arhitekture	Dizajn modela baza podataka	Kreiranje logičkih modela ODS, DWH i OLAP baza podataka
9		Dizajn ETL arhitekture	Dizajn ETL procesa za dohvat/prihvat podataka
10		Kreiranje tehničke dokumentacije	Kreiranje dokumenta Specifikacije arhitekture sustava i dokumenta Upravljanja sustavom
11	4. Razvoj i implementacija sustava	Implementacija fizičkih modela baza podataka	Implementacija fizičkih modela ODS, DWH i OLAP baza podataka
12		Razvoj ETL procesa	Razvoj ETL procesa
13		Razvoj izvještaja	Razvoj standardiziranih izvještaja
14	5. Testiranje i isporuka	Testiranje sustava	Provođenje testiranja sustava u razvoju, isporuka na testno okruženje, provođenje testova prihvaćanja.
15		Kreiranje uputa za korištenje sustava	Kreiranje Uputa za korisnike
16		Edukacija ključnih korisnika	Provođenje edukacije vezano uz korištenje sustava
17		Isporuka sustava u produkcijsko okruženje	Isporuka u produkcijsko okruženje

PRILOG VI.

Tablica 5. Uloge i odgovornosti ljudi na projektu (izvor: Agencija)

Uloga	**Firma**	**Odgovornosti**
Voditelj projekta	Agencija	Sudjeluje u uspostavi projekta, provodi aktivnosti upravljanja projektom od strane naručitelja, te sudjeluje u primopredaji isporuka projekta.
Ključni korisnik (vlasnik poslovnog područja)	Agencija	Vlasnik je podataka i procesa koji su dio poslovnog područja kojim upravlja, sudjeluje u radionicama poslovne analize i specificiranju zahtjeva sustava, sudjeluje u usuglašavanju dokumenta Specifikacija zahtjeva, u testiranju, odobrava testove prihvaćanja kojim se potvrđuje točnost podataka, odobrava promjene u funkcionalnostima sustava u svojoj domeni upravljanja.
Korisnik	Agencija	Sudjeluje u radionicama poslovne analize i specificiranju zahtjeva sustava.
IT stručnjak	Agencija	Sudjeluje u osiguravanju hardverske i softverske infrastrukture od strane naručitelja i odgovoran je za omogućavanje pristupa izvorima podataka članovima projektnoga tima isporučitelja.
Voditelj projekta	Izvođač	Odgovoran je za uspostavu projekta, provodi aktivnosti upravljanja projektom od strane isporučitelja, te sudjeluje u primopredaji isporuka projekta.
Poslovni analitičar	Izvođač	Sudjeluje u radionicama poslovne analize koje uključuju dokumentiranje postojećeg stanja vezano uz organizacijsku strukturu, poslovna područja, poslovne procese, izvorne sustave i postojeće podatke na izvornim sustavima, te zahtjeve korisnika, uključujući potrebne podatke za izvještavanje, standardne izvještaje i nadzorne ploče. Kreira i s vlasnicima procesa usuglašava dokument Specifikacija zahtjeva, sudjeluje u testiranju rada sustava, osigurava korisničku dokumentaciju, te provodi edukaciju korisnika.
BI stručnjak	Izvođač	Sudjeluje u radionicama poslovne analize i savjetuje vezano uz upravljanje BI procesima. Odgovoran je za uspostavu testne i produkcijske infrastrukture. Odgovoran je za dizajn arhitekture sustava i modela baza podataka. Kreira i isporučuje dokument Specifikacije arhitekture sustava i dokument Upravljanja sustavom. Sudjeluje u razvoju, implementaciji i testiranju, te je odgovoran za isporuku funkcionalnosti sustava koji uključuje baze podataka, BI alate, izvještaje i nadzorne ploče.
DB stručnjak	Izvođač	Odgovoran je za dizajn ETL arhitekture, sudjeluje u razvoju, implementaciji i testiranju, te je odgovoran za isporuku funkcionalnosti sustava koji uključuje baze podataka i ETL procese za dohvat podataka.

PRILOG VII.

Tablica 10. Prikaz mjera i dimenzija za programe potpora u poljoprivredi (izvor: Agencija)

Mjere **Dimenzije**	Klijent	Gospodarstvo	Lokacija	Datum	ABB	Razredi	Mjera	Proizvodna godina
Količina traženo	●	●	●	●		●	●	●
Količina utvrđeno	●	●	●	●		●	●	●
Količina odobreno	●	●	●	●		●	●	●
Količina – poslano na isplatu	●	●	●	●	●	●	●	●
Iznos traženo	●	●	●	●		●	●	●
Inicijalni iznos	●	●	●	●		●	●	●
Iznos za isplatu	●	●	●	●		●	●	●
Odobreni iznos u MOPu	●	●	●	●	●	●	●	●
Iznos poslan na isplatu	●	●	●	●	●	●	●	●
Iznos poslan na isplatu dugovi korekcije i povrati	●	●	●	●	●	●	●	●
Iznos poslan na isplatu EU dio	●	●	●	●	●	●	●	●
Iznos poslan na isplatu dugovi korekcije i povrati EU dio	●	●	●	●	●	●	●	●
Iznos poslan na isplatu HR dio	●	●	●	●	●	●	●	●
Iznos poslan na isplatu dugovi korekcije i povrati HR dio	●	●	●	●	●	●	●	●
Višestruke sukladnosti – iznos poslan na isplatu	●	●	●	●	●	●	●	●
Višestruke sukladnosti – iznos poslan na isplatu3	●	●	●	●	●	●	●	●
Višestruke sukladnosti EU dio – iznos poslan na isplatu	●	●	●	●	●	●	●	●
Višestruke sukladnosti EU dio – iznos poslan na isplatu3	●	●	●	●	●	●	●	●
Višestruke sukladnosti HR dio – iznos poslan na isplatu	●	●	●	●	●	●	●	●
Višestruke sukladnosti HR dio – iznos poslan na isplatu3	●	●	●	●	●	●	●	●
Višegodišnje sankcije – iznos poslan na isplatu	●	●	●	●	●	●	●	●
Višegodišnje sankcije EU dio – iznos poslan na isplatu	●	●	●	●	●	●	●	●
Višegodišnje sankcije HR dio – iznos poslan na isplatu	●	●	●	●	●	●	●	●
Broj gospodarstava za obradu	●	●	●	●		●	●	●
Broj gospodarstava traženo	●	●	●	●		●	●	●
Broj gospodarstava odobreno	●	●	●	●		●	●	●
Broj gospodarstava poslano na isplatu	●	●	●	●	●	●	●	●