



8. Osnove poslovne analitike uključujući R i SQL

Šta je poslovna analitika (engl. *business analytics* - BA)? Koje probleme rešava i koje alate koristi? Šta su R i SQL? Kako je BA povezan s R i SQL? Postoje li primeri dobre prakse u kojima se ti softveri koriste za rešavanje logističkih poslovnih problema?

Na ova i slična pitanja pokušaćemo dati odgovore u sledećem poglavlju.

8.1 Šta je poslovna analitika?

BA predstavlja holistički pristup analizi podataka i poslovnom odlučivanju. To je okruženje vođeno podacima s ciljem poboljšanja poslovnih performansi kompanije pružanjem temelja za informisanje donošenje odluka. To je sistemski proces razmišljanja koji primenjuje kvalitativne, kvantitativne i statističke računarske alate i metode za analizu podataka, sticanje uvida, informisanje i podršku donošenju odluka. Svaka određena analiza može da koristi različite tehnike uključujući dijagnostičke, prediktivne, preskriptivne i optimizacione modele (Power i dr., 2018). Mikalef i dr., (2019) daju plan za akademsko istraživanje i praktičnu primenu, ističući transformativni potencijal analitike kada se pravilno integriše u organizacione procese. U skladu s tim, autori navode da BA zahteva od organizacija da radikalno redizajniraju način na koji se takvim inicijativama pristupa, kako se dizajniraju i usavršavaju, kako se planiranje resursa i orkestriranje izvršava i strateški usklađuje, kao i da ponovno vrednuju svoje očekivane rezultate izvođenja, njihovu povezanost sa strateškim ciljevima i, kao rezultat toga, razviju odgovarajuće KPI-eve (Mikalef et al., 2019).

Glavni zadaci BA su osigurati kanal znanja kako bi se osigurala koherentna veza između sirovih podataka i poslovnih odluka. Opšti cilj je poslovna učinkovitost kroz 'vertikalizaciju', upotrebljivost i integraciju s operativnim sistemima (Kohavi i dr., 2002). BA ima mnogo područja primene i povezanih izvedenica: finansijska analitika, analitika lanca snabdevanja, analitika krize, analitika znanja, marketinška analitika, analitika kupaca, analitika usluga,



analitika ljudskih resursa, analitika talenata, analitika procesa, analitika rizika (Holsapple i dr., 2014.).

Postoje tri vrste platformi poslovne analitike:

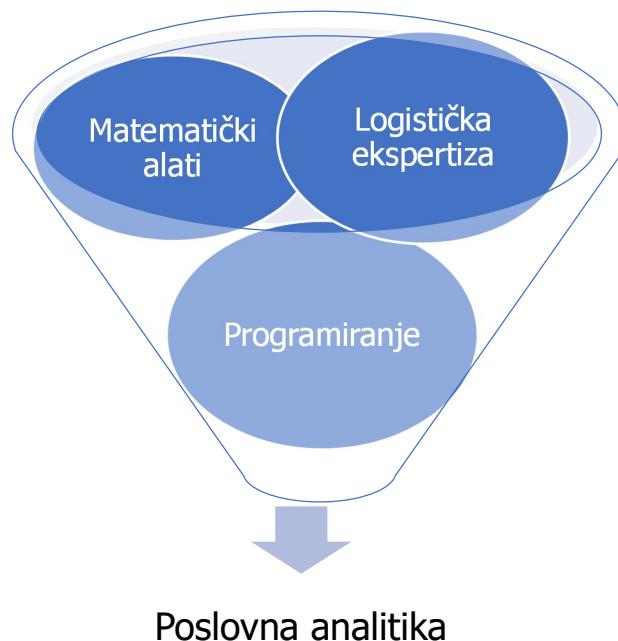
- **Opisne** – posmatraju postojeće podatke i daju sažetak statistike i osnovnu vizualizaciju.
- **Prediktivne** – koriste postojeće podatke za procenu najverovatnijih budućih scenarija.
- **Preskriptivne** – automatski obrađuju veliku količinu podataka (engl. *big data*), poslovna pravila, tržišne uslove itd. Ove platforme koriste metode mašinskog učenja i veštačke inteligencije. Cilj je potpuno automatizovano donošenje odluka o tome koje akcije kompanija treba preduzeti s obzirom na trenutnu situaciju kako bi postigla željene poslovne ciljeve.

Zanimanje za *big data* i poslovnu analitiku eksponencijalno je poraslo tokom protekle decenije (Mikalef i dr., 2019). Savremeni BA ukorenjen je u stalnom napretku sistema za podršku odlučivanju. Ovaj napredak uključuje sve snažnije mehanizme za sticanje, generisanje, asimilaciju, izbor i emitovanje znanja relevantnog za donošenje odluka. S obzirom na nasleđe podrške odlučivanju, poslovna analitika nužno učestvuje u tim mehanizmima i iskorišćava ih. Znanje koje se mora obraditi kreće se od kvalitativnog do kvantitativnog, a BA uključuje obe vrste znanja, kako je prikladno za donošenje odluke (Kohavi i dr., 2002). Razlog zašto bi neka organizacija trebala primeniti BA je u problemima koje rešava. Problemi koje BA ističe su problemi smanjenja učinkovitog upravljanja preduzećem. Shodno tome, postoji nekoliko razloga za primenu BA (Holsapple i dr., 2014):

- Ostvarivanje konkurentske prednosti;
- Podrška strateškim i taktičkim ciljevima organizacije;
- Bolji organizacioni učinak;
- Bolji ishodi odluka;
- Bolji ili informisaniji procesi odlučivanja;
- Proizvodnja znanja;
- Dobijanje vrednosti iz podataka.



Bez obzira na vrstu platforme koja se koristi u BA za rešavanje i podršku procesu donošenja odluka u svakoj kompaniji, postoje tri ključna stuba svakog BA rešenja (slika 8.1). Generalno, BA zauzima mesto u spektru između računarske nauke/matematike/nauke o podacima (s jedne strane) i poslovanja i menadžmenta (s druge strane). Poslovna analitika zahteva i tehničko i poslovno znanje. Glavni problem u dizajniranju BA je to što granice nisu jasne (Power i dr., 2018). Shodno tome, za izvođenje BA potrebni su matematički alati za identifikaciju, izdvajanje i predstavljanje uvida na pravi način putem tabela, grafika, formula itd. Dodatno, alati za programiranje služe kao podrška ovoj vrsti aktivnosti i omogućavaju brze proračune bez grešaka, u poređenju s tradicionalnim pristupom papira i olovke. Poslednje, ali ne manje važno, potrebna je logistička ekspertiza u određenom području ili poslovnom problemu kako bi se odredili ključni uticajni faktori i povezani ekosistem.



Slika 4.48Ključni stubovi BA u kontekstu lanca snabdevanja i logistike.

Ključni potrošač je poslovni korisnik, čiji posao, verovatno u *merchandisingu*, marketingu ili prodaji, nije direktno povezan s analistikom *per se*, ali koji obično koristi analitičke alate za poboljšanje rezultata nekog poslovnog procesa duž jedne ili više dimenzija (kao što su profit i vreme do tržišta). Poslovni korisnici ne žele imati posla s naprednim statističkim konceptima; žele jednostavne vizualizacije i rezultate relevantne za zadatak (Kohavi i dr., 2002).



8.2 Šta je R?

R je integrirani paket softverskih mogućnosti za manipulaciju podacima, proračun i grafički prikaz (R Core Team, 2019). Između ostalog, ima i sledeće:

- učinkovito rukovanje i skladištenje podataka,
- skup operatora za proračune na nizovima, posebno matricama,
- velika, koherentna, integrisana zbirka posrednih alata za analizu podataka,
- grafičke mogućnosti za analizu i prikaz podataka bilo direktno na računaru ili u štampanoj kopiji, te dobro razvijen, jednostavan i učinkovit programski jezik (nazvan 'S') koji uključuje uslove, petlje, korisnički definisane rekurzivne funkcije i mogućnosti unosa i izlaza (većina funkcija koje pruža sistem napisane su u S jeziku).

Glavne prednosti R-a su činjenica da je R besplatan i da postoji puno dostupne pomoći online. Prilično je sličan drugim programskim paketima kao što je MatLab (nije besplatan), ali je lakši za korišćenje od programskih jezika kao što su C++ ili Fortran (Torfs i Brauer, 2014). R je u velikoj meri sredstvo za nove metode interaktivne analize podataka. Brzo se razvijao i proširio velikom kolekcijom paketa. Međutim, većina programa napisanih u R-u u suštini su prolazni, napisani za jednu analizu podataka (R Core Team, 2019).

[Instalacija R-a i R Studija](#)

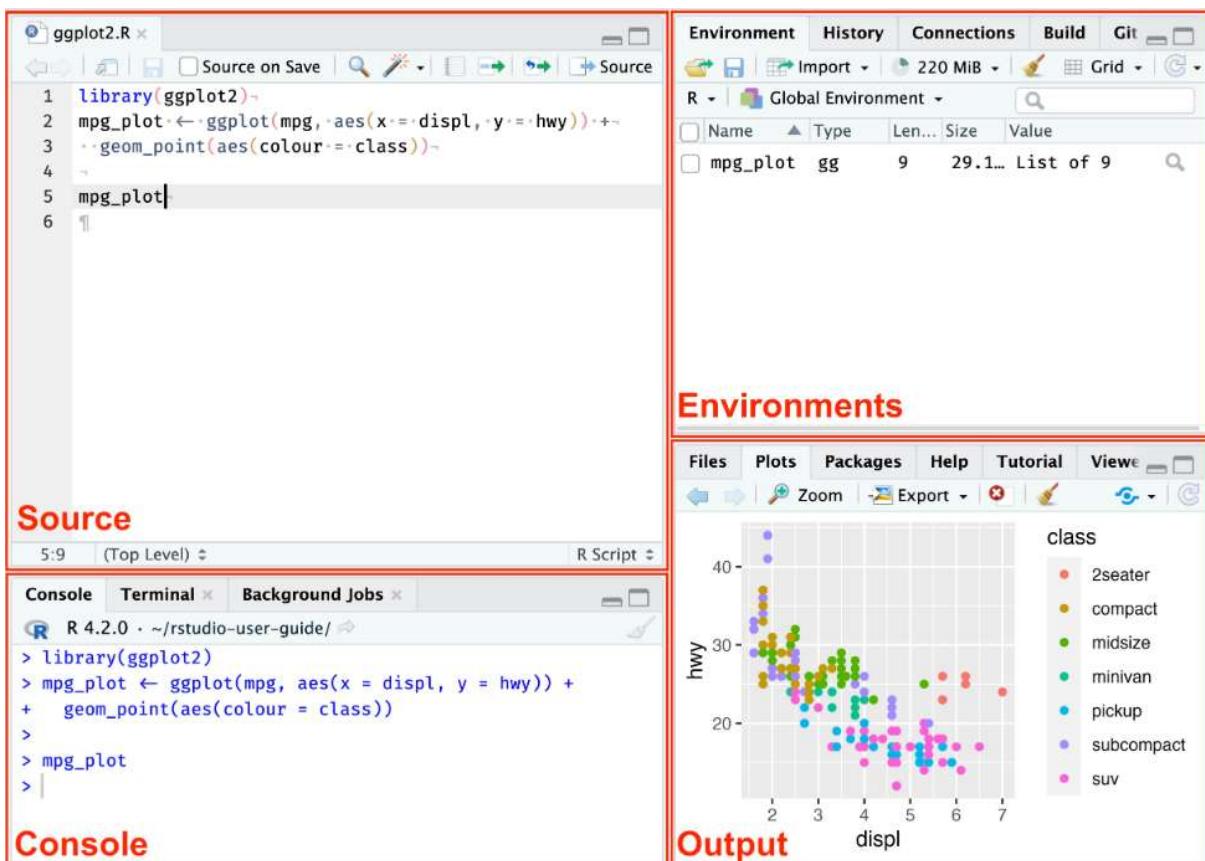
Da biste instalirali R, idite na cran.r-project.org i kliknite na preuzimanje R za određeni operativni sistem na vašem računaru (obično Windows) (slika 8.2).



The screenshot shows the official CRAN (Comprehensive R Archive Network) website. The top navigation bar includes links for 'cran.r-project.org', 'The Comprehensive R Archive Network', and various search and download options. On the left, there's a sidebar with links to 'CRAN Mirrors', 'What's new?', 'Search', 'CRAN Team', 'About R', 'R Homepage', 'The R Journal', 'Software', 'R Sources', 'R Binaries', 'Packages', 'Task Views', 'Other', 'Documentation', 'Manuals', 'FAQs', 'Contributed', 'Donations', and 'Donate'. The main content area is titled 'Download and Install R' and contains instructions for precompiled binary distributions. It lists links for 'Download R for Linux (Debian, Fedora/Redhat, Ubuntu)', 'Download R for macOS', and 'Download R for Windows' (which is highlighted with a red box and a red arrow). Below this, it says 'R is part of many Linux distributions, you should check with your Linux package management system in addition to the link above.' Further down, under 'Source Code for all Platforms', it provides links for the latest release (R-4.3.2), alpha/beta releases, daily snapshots, and source code for older versions. The 'Questions About R' section links to 'answers to frequently asked questions'. The 'Supporting CRAN' section encourages financial contributions to the R Foundation.

Slika 4.49 Stranica za preuzimanje softvera R.

Ovo će preuzeti softver R, a postupak instalacije je isti kao i za bilo koji drugi softver. Kada se R softver instalira, biće bez naprednog integrisanog razvojnog okruženja (engl. *integrated development environment* - IDE) koje pomaže korisnicima u izradi različitih analiza. Iako je moguće napraviti bilo kakvu analizu samo s instaliranim R-om, poželjno ga je upariti s nekim modernim IDE-om, poput RStudija, koji je jedan od najpopularnijih IDE-a. Postupak instaliranja RStudija sličan je osnovnom R softveru. Idite na <https://posit.co/download/rstudio-desktop/>, potražite RStudio Desktop licencu otvorenog koda, preuzmite je i instalirajte. Nakon instaliranja programa R i RStudio korisnik će imati sledeći ekran korisničkog interfejsa (slika 8.3).



Slika 4.50Korisnički interfejs i R i Rstudio (RStudio, 2024).

RStudio korisnički interfejs ima 4 primarna prozora (RStudio, 2024.):

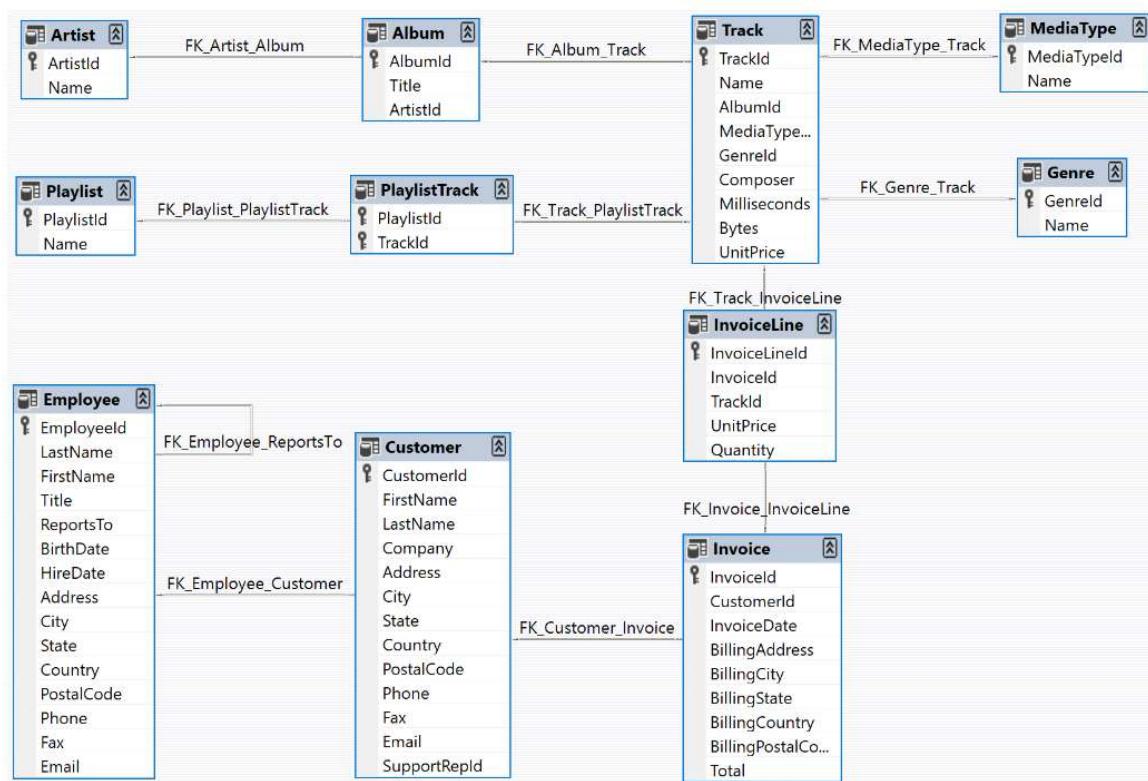
- „Source“ (srp. Izvor);
- „Console“ (srp. Konzola);
- „Environments“ (srp. Okruženje), koji sadrži kartice Okruženje, Istorija, Veze, Izrada, VCS i Vodič;
- „Output“ (srp. Rezultat), koji sadrži kartice Datoteke, Ploče, Paketi, Pomoć, Pregledač i Prezentacija.

Svaki od prozora te pododeljak i opcije u njemu omogućavaju korisnicima izvođenje različitih operacija, kontrolu nad nekim analizama podataka ili strukturiraniji i jasniji pogled na proces analitike podataka koji je u toku.



8.3 Šta je SQL i kako je povezan s BA i R?

Chinook baza podataka je ogledna baza podataka koja se koristi za učenje i demonstraciju sistema za upravljanje bazom podataka (engl. *database management systems* - DBMS) i SQL upita. Dizajnirana je kao digitalna multimedijalna prodavnica koja koristi stvarne podatke iz iTunes knjižnice; izmišljena imena/adrese kupaca i zaposlenih; i slučajne podatke za informacije o prodaji. Baza podataka sadrži različite tabele koje predstavljaju podatke muzičke prodavnice, uključujući informacije o izvođačima, albumima, pesmama, kupcima, fakturnama i slično (slika 8.4).



Slika 4.51 Model podataka baze podataka Chinook.

Slika 8.4 prikazuje model podataka koji okružuje Chinook bazu podataka s različitim tabelama podataka i njihovim ključevima (jedinstveni identifikatori) i zajedničkim tabelama poput tabele PlaylistTrack. Tabele prenose različite informacije o određenoj digitalnoj prodavnici (tabela 8.1).

Tabela 4.3 Informacije sadržane u svakoj od tabela baze podataka Chinook.

Naziv tabele	Opis
--------------	------



Umetnik	Sadrži informacije o muzičkim umetnicima.
Album	Sadrži informacije o muzičkim albumima, od kojih je svaki povezan s izvođačem.
Zapis	Sadrži informacije o pojedinačnim muzičkim zapisima, uključujući reference na albume, vrste medija i žanrove.
Žanr	Sadrži informacije o muzičkim žanrovima.
Vrsta medija	Sadrži informacije o različitim vrstama medija (npr. audio, video).
Kupac	Sadrži podatke o kupcima, uključujući podatke za kontakt i podatke o predstavniku podrške.
Zaposleni	Sadrži informacije o zaposlenima, uključujući njihove uloge, veze s izveštajima i podatke za kontakt.
Fakture	Sadrži informacije o fakturama, uključujući pojedinosti o kupcima, podatke o naplati i ukupne iznose.
Linija fakture	Sadrži detaljne informacije o svakoj stavci na fakturi, uključujući reference na tragove i količine.
Popis pesama	Sadrži informacije o popisima za reprodukciju.
Zapis popisa pesama	Povezuje pesme s popisima za reprodukciju, pokazujući koje su pesme uključene u koje popise za reprodukciju.

8.4 Kako su povezani poslovna analitika, SQL i R?

Veza između BA, SQL i R je prirodna jer bi svi poslovni podaci trebali da se skladište u SQL bazama podataka. Ovo je još uvek idealistički cilj budući da još uvek postoji loše upravljanje podacima u nekim delovima malih i srednjih preduzeća koja još uvek ne razumeju u potpunosti snagu podataka. U velikim kompanijama to je davno prepoznato i podaci su pravilno strukturirani u bazama podataka (SQL ili nekoj drugoj, ali najčešće u SQL-u). S druge strane, analizu podataka moguće je izvršiti u SQL-u, ali je u tu svrhu bolje koristiti statistički orijentisani softver, gde je u fokusu R, kao jedna od najpopularnijih statističkih platformi za analizu podataka.

Shodno tome, SQL i R mogu se smatrati savršenim alatom za saradnju kada je problem u pitanju iz područja BA. Postoji nekoliko glavnih razloga, a jedan od njih je taj što se BA podaci svakodnevno menjaju i ažuriraju u skladu s realnim tržištem i aktivnostima kompanije: prodaja, zaposleni, prihodi itd. SQL baze podataka savršene su za beleženje tih promena i ažuriranje postojećih podataka, dok su R skripte vrlo dobre u automatizaciji zadataka kao i u dizajniranju novih paketa za analizu datih podataka. Razlog za to je što je R



više građen oko koncepta analize podataka, nego na opštem programiranju kao što je Python, na primer.

Upit SQL bazi podataka s R

R i SQL baze podataka imaju prirodnu vezu budući da je R uglavnom izgrađen za statističku analizu podataka, a većina transakcijskih podataka nalazi se u bazama podataka. "Način" na koji R radi za upravljanje manipulacijom podataka iz SQL baza podataka je preko DBI i RSQLite programskih paketa. DBI paket pruža standardizovani interfejs za interakciju s različitim DBMS-ovima, dopuštajući korisnicima povezivanje, postavljanje upita i dosledno upravljanje transakcijama u različitim bazama podataka. Paket RSQLite, koji se pridržava DBI interfejsa, posebno olakšava interakciju s bazama podataka SQLite, omogućavajući korisnicima izvršavanje SQL upita, preuzimanje podataka i izvođenje operacija baze podataka direktno iz R-a. Zajedno, ovi paketi pojednostavljaju proces rada s bazama podataka u R-u, nudeći kohezivan i učinkovit tok rada.

Kako bismo učinkovito demonstrirali izvođenje SQL operacije iz R-a i generisanje željenih uvida iz podataka u vezi s postojećim problemom, dali smo nekoliko isečaka koda na slikama 8.5 i 8.6.



```
---
```

```
title: "BUSINES ANALYTICS FOUNDATINS INCLUDING THE R AND SQL"
format: html
editor: visual
---
```

```
# R & SQL
```

```
## Loading libraries
```

```
```{r setup, warning=FALSE, message=FALSE}
library(DBI)
library(RSQLite)
```
```

```
## Connect to the Chinook SQLite database
```

```
```{r}
con <- dbConnect(RSQLite::SQLite(), dbname = "Chinook_Sqlite.sqlite")
```
```

```
## List all tables in the database
```

```
```{r}
tables <- dbListTables(con)
print(tables)
```
```

Slika 4.52Isečak koda za uspostavljanje veze između SQL-a i R-a i istraživanje tabela podataka sadržanih u SQL-u.

Prvi korak u postavljanju upita SQL bazi podataka putem R-a je uspostavljanje veze (slika 8.5). Slika prikazuje korišćenje DBI i RSQlite paketa koji omogućavaju uspostavljanje veze putem dbConect() funkcije. Rezultat veze i tabele podataka koji se otkrivaju putem gore navedene veze zatim se izvoze putem funkcija dbListTables() koje ispisuju popis svih podataka pronađenih putem veze: Album, Izvođač, Kupac, Zaposleni, Žanr, Fakture, Linija fakture, Vrsta medija, Popis pesama, Zapis popisa pesama, Zapis.

Nakon što se veza uspostavi, postoji niz mogućih analiza koje se mogu sprovesti, zavisno od poslovnog cilja i budućoj upotrebi datih rezultata. Ovde ćemo, zbog ograničenja prostora, pokazati samo delić moguće analize podataka, s malim isečkom koda i skupom pravila koda potrebnih za izdvajanje informacija iz SQL-a. Kod vrši upite bazi podataka putem R-a i prikazuje najprodavanije albume, njihove autore i prodani broj (slika 8.6). Tabela 8.2 predstavlja rezultate upita podataka putem isečka koda na slici 8.6.



```
29+ ## Choose a Album table from the database
30+ ````{r}
31 query_album <- "SELECT * FROM Album LIMIT 10"
32 data_album <- dbGetQuery(con, query_album)
33 print(data_album)
34+
35
36+ ## Query to get album details along with artist names
37+ ````{r}
38 query_album_artist <- "
39 SELECT Album.AlbumId, Album.Title AS AlbumTitle, Artist.Name AS ArtistName
40 FROM Album
41 JOIN Artist ON Album.ArtistId = Artist.ArtistId
42 LIMIT 10"
43
44 data_album_artist <- dbGetQuery(con, query_album_artist)
45 print(data_album_artist)
46+
47
48+ ## Query to get the top-selling albums along with artist names
49+ ````{r}
50 query_top_selling_albums <- "
51 SELECT
52     Album.Title AS AlbumTitle,
53     Artist.Name AS ArtistName,
54     SUM(InvoiceLine.Quantity) AS TotalQuantitySold
55 FROM
56     InvoiceLine
57 JOIN
58     Track ON InvoiceLine.TrackId = Track.TrackId
59 JOIN
60     Album ON Track.AlbumId = Album.AlbumId
61 JOIN
62     Artist ON Album.ArtistId = Artist.ArtistId
63 GROUP BY
64     Album.AlbumId, Album.Title, Artist.Name
65 ORDER BY
66     TotalQuantitySold DESC
67 LIMIT 10"
68
69 # Execute the query
70 top_selling_albums <- dbGetQuery(con, query_top_selling_albums)
71 knitr::kable(top_selling_albums)
72+ ````
```

Slika 4.53Isečak koda za postavljanje upita SQL-u putem R-a i određivanje 10 najprodavanijih albuma.

Tabela 4.410 najprodavanijih albuma u digitalnoj prodavnici Chinook.

| Naslov albuma | Ime umetnika | Prodata količina |
|-------------------|------------------------------|------------------|
| Minha Historia | Chico Buarque | 27 |
| Greatest Hits | Lenny Kravitz | 26 |
| Unplugged | Eric Clapton | 25 |
| Acústico | Titãs | 22 |
| Greatest Kiss | Kiss | 20 |
| Prenda Minha | Caetano Veloso | 19 |
| Chronicle, Vol. 2 | Creedence Clearwater Revival | 19 |



| Naslov albuma | Ime umetnika | Prodata količina |
|--|------------------------------|------------------|
| My Generation - The Very Best Of The Who | The Who | 19 |
| International Superhits | Green Day | 18 |
| Chronicle, Vol. 1 | Creedence Clearwater Revival | 18 |

Literatura 8. poglavlja

- Holsapple, C., Lee-Post, A., & Pakath, R. (2014). A unified foundation for business analytics. *Decision Support Systems*, 64, 130-141.
- Kohavi, R., Rothleider, N. J., & Simoudis, E. (2002). Emerging trends in business analytics. *Communications of the ACM*, 45(8), 45-48.
- Mikalef, P., Boura, M., Lekakos, G., & Krogstie, J. (2019). Big data and business analytics: A research agenda for realizing business value. *Information & Management*. <https://doi.org/10.1016/j.im.2019.103237>
- Power, D. J., Heavin, C., McDermott, J., & Daly, M. (2018). Defining business analytics: An empirical approach. *Journal of Decision Systems*, 27(1), 40–53. <https://doi.org/10.1080/2573234X.2018.1507605>
- R Core Team. (2019). An introduction to R: Notes on R, a programming environment for data analysis and graphics. The R Foundation.
- RStudio. (2024). RStudio IDE cheatsheet: UI panes. Posit. <https://docs.posit.co/ide/user/ide/guide/ui/ui-panes.html>
- Torfs, P., & Brauer, C. (2014). A (very) short introduction to R. Hydrology and Quantitative Water Management Group, Wageningen University, The Netherlands, 1-12.