



# Analitični CRM nam odkrije povsem nove marketinške probleme – Primeri različnih panog

---

**THE  
POWER  
TO KNOW®**

Maja Škrjanc, SAS Adriatic Region

# Cilj


- Skozi primere prikazati:
  - Na kakšne načine uporabiti analitične tehnike (data mining) v okviru aCRM v različnih organizacijah
  - Kakšni so rezultati
  - Nove izzive na podlagi rezultatov:
    - za nadaljni razvoj organizacije
    - Povečanje poslovnih koristi
  - Ključne faktorje za uspeh uvedbe aCRM
  
- Zaključek



**THE  
POWER  
TO KNOW®**

## Primeri iz Adriatic regije

# Primeri iz Adriatic regije



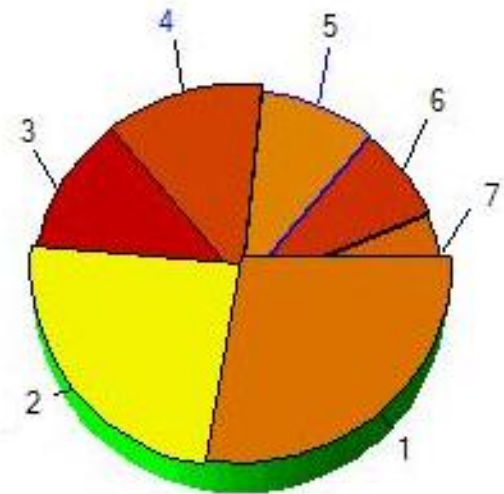
# Primer 1: mobilni operater

- Poslovni problem:
  - Stranke iz predplačniškega razmerja
  - Naloga: "Pokažite nam, kaj lahko naredite" in poslovne koristi
- IT infrastruktura:
  - Brez podatkovnega skladišča, podatki v tabelah (ne-relacijskih)
  - Ni bilo ustreznega HW na voljo
  - Podatki: niso brisali ničesar, bogati podatki
- Ljudje:
  - Motivirani, vendar brez predznanja, odprti za ideje
- Rezultati:
  - Segmentacija strank po obnašanju
  - Model za napovedovanje prestopa na naročniško razmerje:
    - Akcija za prehod na naročniška razmerja 😊
  - Analiza novih tarifnih planov – simulacija po vseh uporabnikih
  - Trajanje: 2 meseca

# Segmentacija strank po obnašanju

## Segmenti:


1. Ne-aktivne stranke (*x09.757 strank - 27,6 %*)
2. Uporabniki posebnih SMSov (*x39.064 strank - 23,7 %*)
3. Poslušalci (*x34.980 strank - 12,7 %*)
4. Govorijo dolgo (*x33.360 strank - 12,6 %*)
5. Inštruktorji (*x71.509 strank - 9,3 %*)
6. Zlati segment (*x42.887 strank - 7,7 %*)
7. Nočne ptice (*x16.764 strank - 6,3 %*)



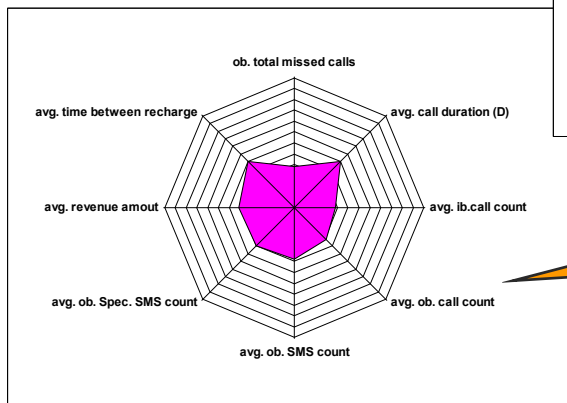

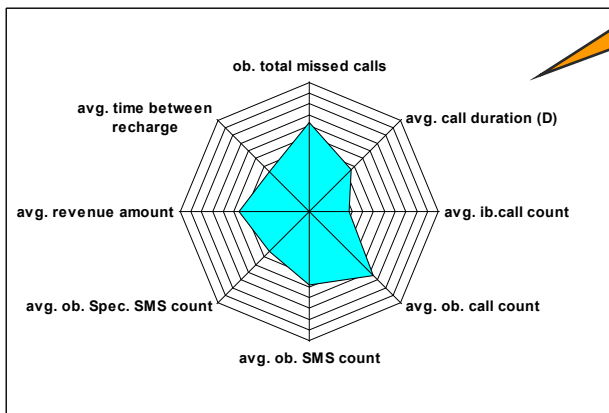

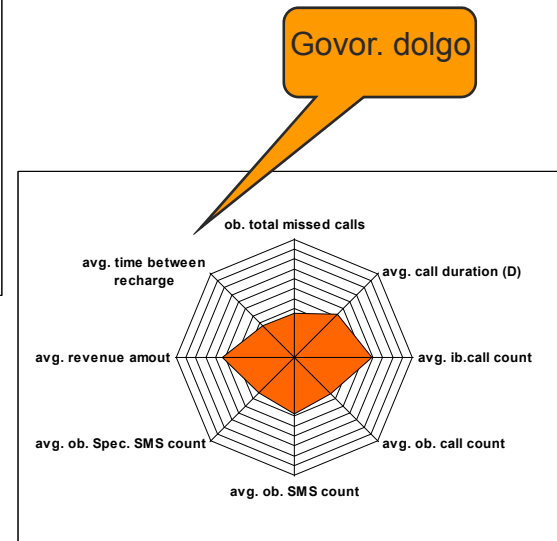
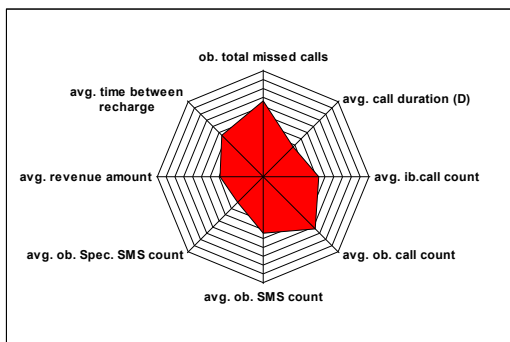
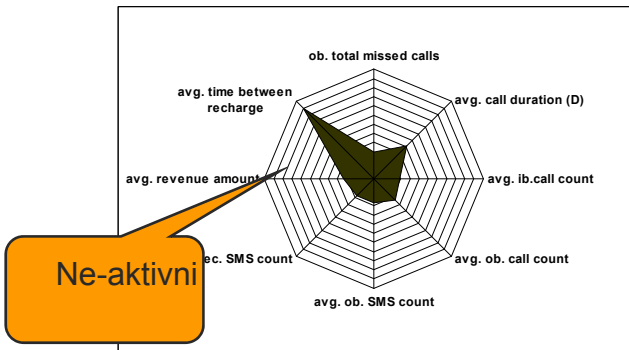
# Opis segmenta

## 5. Inštruktorji (x71.509 strank)

- **Zelo visoko odhodno aktivnost:**
  - Kličejo veliko v tujino
  - Uporaba wap storitve je visoka
  - Povprečno trajanje klica
  - Uporaba sms storitve je visoka, še posebej posebnih SMS
- **Veliko število zgrešenih klicev**
- **Nizka dohodna aktivnost**
- **Polnijo več od povprečja**
- **Imajo tretji najvišji prihodek**



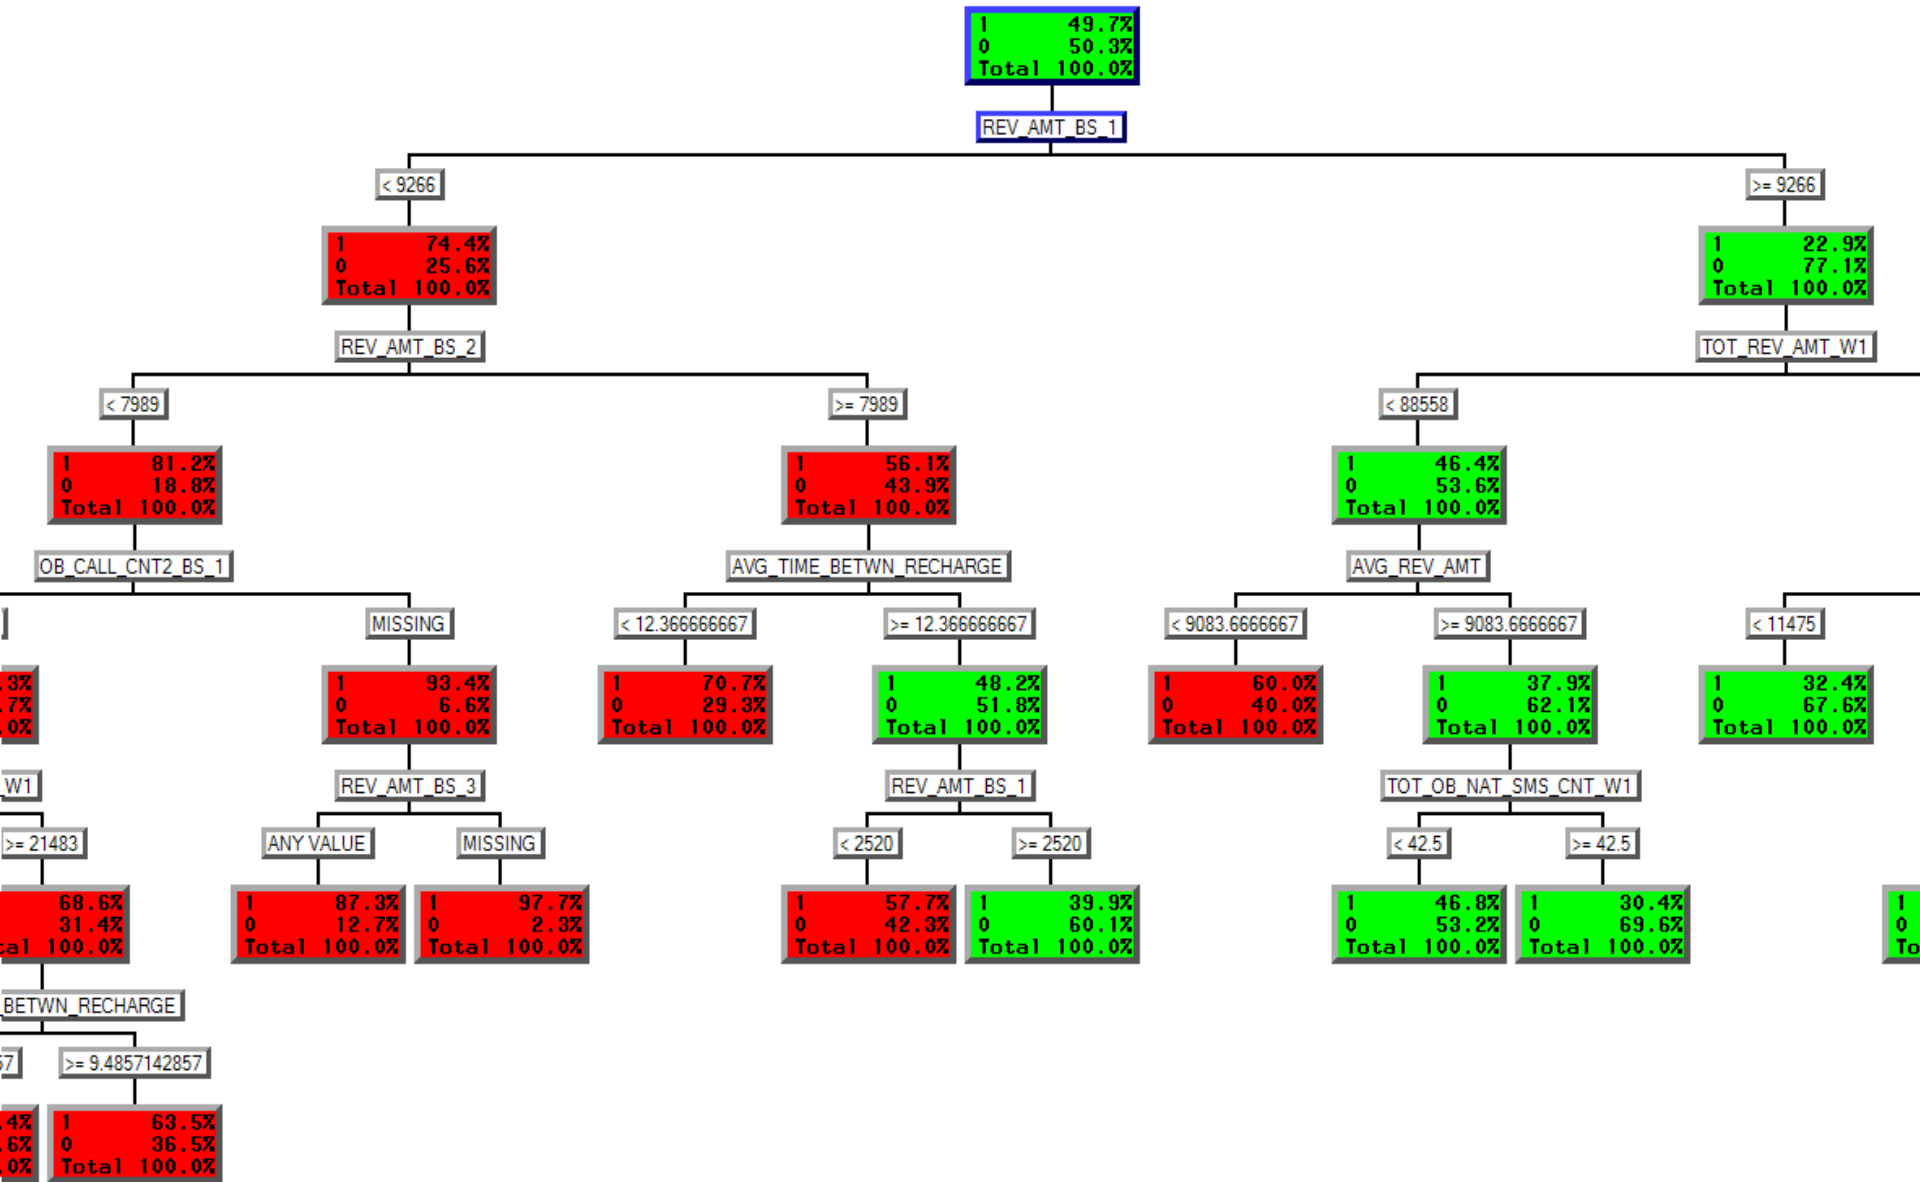
_FREQ_	Average Number Of Outbound Calls	Total Number Of Missed Outbound Calls	Total Number of Regular Outbound Calls	Average Duration Of Regular Outbound Calls	Average Number of Outbound SMSs	Average Number Of Outbound Special SMSs	Average Number Of Inbound Calls	Total Recharge Amount	Average Time Between Recharges	Total Number Of Recharges	Average Recharge Amount	Average Revenue Amount
xxx 71.509	417.952	356932403	40413163	30.4159	64.3701	1.64709	8.98346	555257246.09	22.3069	2037751	264.7414	xxx 502367





# 20% strank = 50% dohodka


#	Segment	Delež dohodka%	Delež strank %
<b>6</b>	<b>Zlati segment</b>	<b>27 %</b>	<b>8 %</b>
<b>4</b>	<b>Dolgo govorijo</b>	<b>22 %</b>	<b>12 %</b>
2	Uporab. posebnih SMSov	20 %	24 %
5	Inštruktorji	15 %	9 %
<b>1</b>	<b>Ne - aktivni</b>	<b>6 %</b>	<b>28 %</b>
3	Poslušalci	6 %	13 %
7	Nočne ptice	4 %	6 %



# Izzivi

- Migracija na naročniško razmerje:
  - Niso vsi po prvotno izbranih kriterijih primerni kandidati
- Pripravljena akcija za nove tarifne plane
  - Vsi materiali pripravljeni
  - Rezultati analize/simulacije pokazali velikansko izgubo
  - Rezultat: akcija ni stekla, pripravili nove – ustrežnejše tarifne plane in novo akcijo


# Primeri iz Adriatic regije




# Primer 2: banka

- Poslovna situacija:
  - Strateški cilj – zadrževanje strank (customer retention)
- IT infrastruktura:
  - Ravno dokončan uspešen projekt podatkovnega skladišča (DW):
    - Struktura podatkov ni bila primerna za analizo s podatkovnim rudarjenjem
    - Premalo zgodovine (6 mesecev)
    - Slaba kvaliteta podatkov
  - Edini vir podatkov mora biti podatkovno skladišče
  - Rešitev:
    - Razširitev podatkovnega skladišča
    - Naložitev podatkov iz trakov (2 meseca)
    - Kvaliteta podatkov (2 meseca)
- Ljudje:
  - Motivirani, slabše predznanje statistike, nič o podatkovnem rudarjenju
- Rezultat: popolnoma avtomatiziran proces za kreiranje, uporabo in spremljanje modelov:
  - za zadrževanje strank (2 modela za 2 segmenta)
  - Segmentacijo po obnašanju (1 model)
  - Model za navzkrižno prodajo izbranega produkta
  - Avtomatizirano kreiranje, spremljanje in upravljanje s kampanijami
  - Kompletan prenos znanja
  - Čas implementacije 1 leto

# Segmentacija po obnašanju strank v banki




1. Uporabniki kreditne kartice – XX,X%
2. Slabo trošijo – XX,X%
3. Aktivni potencial– XX,X%
4. Upokojeenci - XX,X%
5. Izjemni uporabniki produkta Y – XX,X%
6. Neaktivni– XX,X%
7. Slabo aktivni – XX,X%
8. Zlati segment – XX,X%



# Novi izzivi

- Organizacijski:
  - Direktorji segmentov
  - Direktorji produktov
  - Enotni kriteriji – nadzor osebnih bančnikov (prisila ali pomoč)
  
- Vsebinski:
  - Preliminarna analiza za model zadrževanja strank:
    - presenetljivi rezultati so spremenili fokus projekta:
      - » Stranke, ki so/bodo odšle <-> Speče stranke
  - Razlog odpovedi – predikcijski model je poleg verjetnosti podal tudi razlog odhoda
  - Navskrižna prodaja – rezultati modela se niso skladali z prvotnimi kriteriji za reklamno akcijo

# Primeri iz Adriatic regije






# Primer 3: Banka

- Poslovna situacija
  - En oddelek
  - Ocenjevanje kreditne sposobnosti (credit scoring)
- IT infrastruktura
  - Podakovni silos – na nivoju oddelka
  - Ekipa je vključila ljudi z IT znanjem
  - In je bila “lastnik” podatkov o strankah
- Ljudje:
  - Visoko motivirani, z visokim nivojem predznanja iz podatkovnega rudarjenja (izdelovanje “scorecardov” )
- Rezultat: “Mi imamo tako veliko konkurenčno prednost zaradi našega načina uporabe, da ne bi želeli naši konkurenci prav nič povedati kaj, sploh pa ne kako in kako uspešno to delamo.”

# Izzivi


- Sodelovanje med oddelkoma:
  - Za ocenjevanje tveganj
  - Za prodajo in marketing



## **Inovativnost:**

- Pre-scoring (predhodno ocenjevanje kreditne sposobnosti)
- Prodaja in marketing:
  - Navskrižna prodaja posameznih produktov
  - Združevanje posameznih ocen za specifično akcijo
  - Segmentacija in profiliranje
  - Goljufije/poneverbe
- Oddelek za ocenjevanje tveganj: credit scoring, ranking

# Primeri iz Adriatic regije



# Primer 4: Mobilni operater

- Poslovna situacija:
  - Uprava se je odločila za implementacijo avtomatiziranega procesa za napovedovanje:
    - Katera stranka ga bo zapustila (Churn prediction)
    - Upravljanja s kampanijami, tudi prek digitalnih kanalov (Campaign management, digital marketing)
    - ...pred 3 leti– neuspešna implementacija – zunanji izvajalci
  
- IT infrastruktura:
  - Podatkovno skladišče, dovolj dostopne zgodovine podatkov, pravi nivo detaljev
  
- Ljudje:
  - Visoko motivirani, nekaj predznanja iz statistike

# Rezultati in novi izzivi

- Rezultati:
  - Avtomatiziran proces za kreiranje, uporabo in upravljanje prediktivnih modelov in marketinških kampanij
  - 2 prediktivna modela za napovedovanje odhajanja strank (churn models)
  - Popoln prenos znanja na ekipo
  - Segmentacija obnašanja strank
  - Čas trajanja: 6 mesecev

## Izzivi

### **Učinkovitejši poslovni proces (hitrejši, učinkovitejši, neodvisen od IT oddelka)**

- Možnost izvedbe velikega števila (več kot 200 v 3 mesecih) kampanij zahteva več vsebine in idej:
  - bolj natančna in dodatna analiza obnašanja strank
  - merjenje in spremljanje učinkovitosti kampanij

# Ključni faktorji za uspeh uporaba podatkovnega **rudarjenja** v organizaciji



- Organizacija/ljudje:
  - Podpora uprave
  - Visoka motiviranost (kreativni pristop)
  - Sodelovanje med oddelki
- Procesi znanja:
  - Prenos znanja na ekipo v org (samostojno delo)
  - Razumevanje, kaj pomenijo podatki in rezultati predikcijskih modelov
- Infrastruktura:
  - IT oddelek mora biti vključen dovolj zgodaj:
    - Največji del časa implementacije odpade na pripravo podatkov
    - Kvaliteta podatkov (čisti podatki, nivo sumarizacij, dostopna zgodovina...)
  - **Rezultat mora biti avtomatiziran proces**

# Kaj smo se naučili 😊

- Pogosti komentarji:
  - Nimamo dovolj podatkov
  - Preveč imamo podatkov – moramo narediti vzorec
  - Najprej moramo zaključiti projekt podatkovnega skladišča
- Ni pravila, kje mora biti organizacija za uvedbo analitičnih metod, mora pa biti jasno kaj je cilj:
  - Učenje na napakah drugih je bolj neboleče
- Bodite pripravljeni:
  - Podatki: zbiranje, **NE BRIŠITE** podatkov, ohranite nivo detalja
  - Izobrazite vaše ekipe

# Zaključek

- Izkoristite vaše podatke – iztisnite sok z uporabo podatkovnega rudarjenja (Data Mining):

ker lahko!

- Začetni vložek (IT, infrastruktura) – rezultat mora biti avtomatiziran proces
- Naslednja omejitev je le kreativnost vaših ljudi
- Bodite drugačni – naj vaše stranke verjamejo, da poznate njene/njegove navade, lastnosti, želje s personaliziranim sporočilom, ki to pokaže
- Izkoristite še boljše digitalne kanale (SMS, mail)





**THE  
POWER  
TO KNOW®**