

## Ali napovedna analitika danes pozna nas bolje, kot se poznamo sami?

### Procesi so različni – ljudje tudi – del II. (primer iz prakse)

#### **Povzetek:**

*Napovedna analitika je danes vse pogosteje uporabljena v realnih primerih, kjer pomaga izboljšati učinkovitost in uspešnost izvajanja procesov. Na primeru bomo pokazali, kako smo z njeno uporabo izboljšali proces in kako je potekal postopke izdelave in uporabe napovednega modela.*

**Ključne besede:** Prediktivna analitika, BI, KPI, Stranka,

**Vloga:** MNG BPM CIO HRM MKT BA

Obvladovanje zapadlih terjatev je vedno vroča tema vsake organizacije, zagotovo tudi bank. Dvigovanje operativne učinkovitost vodi v bolj optimizirano izvajanje procesov, s čim manjšim obsegom ročnega dela in administrativnih postopkov. Učinkovitost lahko povečamo s selektivnim ciljanjem pravih dolžnikov, s pravo strategijo in ob pravem času. To skrajša čase plačila, zniža stroške in poveča realizacijo. S tem se lahko izterjevalci posvetijo pravim primerom na prav način ter izkoristijo svoje poznavanje stranke in njenega poslovanja v polni meri. Danes se temu lahko približamo z uporabo sodobnih [napovednih orodij](#).

### Primer izterjave

Kako to izpeljati? Kot poslovni analitiki smo pregledali vedenje strank v preteklosti in izbrali več kot **50 kazalk ali parametrov** (ključni so navedeni na sliki spodaj), **ki bi lahko vplivali na vedenje stranke** (kot je znesek računa, velikosti podjetja in gospodinjstva, osebne podatke o stranki, izpolnjevanje dogovorov, uporabo kanalov komunikacije, itd.). Na osnovi tega smo razvili **napovedni model** z več kot 10.000 poslovnimi pravili, katerega namen je **napovedati obnašanje posameznih strank in proces optimizirati "on-line"**.

Model napove, ali bo posamezen izdan račun / obveznost poravnana pravočasno. Potem poslovna pravila vgrajena v proces sprejmejo določene odločitve in razdelijo naloge posameznim osebam, s točno določeno vsebino in navodili, kaj je potrebno storiti in kako.


### Izbrani ključni parametri vpliva na vedenje strank

Kazalka - parameter	Prispevek k odločitvi [%]
doba do zapadlosti kredita (v mesecih)	31,43
delež zastavnega razmerja (vrednost zavarovanja/vrednost kredita)	29,11
starost pojmeta (v letih)	28,20
čas od zadnjega v celi poplačanega kredita do sedaj (v letih)	24,74
delež lastništva posloводства	22,21
čas od zadnjega neplačila do sedaj (v letih)	22,11
delež sredstev v kapitalu	20,32
neplačilo v preteklih letih	17,70
delež neodplačanega kredita v preteklosti	16,73

Pred uporabo je potrebno model vsega tega še »naučiti«, kar se naredi na podlagi zgodovinskih podatkov, ki jih o preteklem obnašanju strank pripravimo iz zgodovine poslovanja z njimi. Zgodovinske vrednosti po posameznih kazalkah in dejanski rezultat v preteklosti (je stranka zamudila s plačilom ali ne), pomagajo v iterativnem postopku strojnega učenja naučiti model in utežiti prispevek posamezne kazalke k končni izračunani verjetnosti. Na takšen način naučen model je nato zrel za uporabo v vsakdanjem življenju. Prvi rezultati so bili zelo presenetljivi.

Spodnja slika prikazuje porazdelitev vseh opazovanih primerov po 2 kazalkah v dvodimenzionalnem prostoru (ker je zelo težko prikazati celoten prostor za več kot 50 dimenzij, smo naključno izbrali dve). Posamezne točke predstavljajo konkreten primer; rdeče točke prikazujejo terjatve, ki so bile pravočasno poravnane, črne točke pa pomenijo zamujena plačila. V skrajno levem kvadrantu je napovedni rezultat, v sredini je to, kar se je realno zgodilo, na skrajni desni pa je razlika.

Porazdelitev vseh opazovanih primerov po 2 kazalkah v dvodimenzionalnem prostoru



Model ni pravilno napovedal le 3 primerov od skupno 192, kar predstavlja 1,5%. Ta natančnost je veliko večja, kot bi jo dosegel človek - recimo skrbnik stranke ali referent v računovodstvu, saj znaša 98,4% (slika spodaj). Najverjetneje tudi mi sami ne bi vnaprej vedeli, ali bomo res tako odreagirali ali ne :).

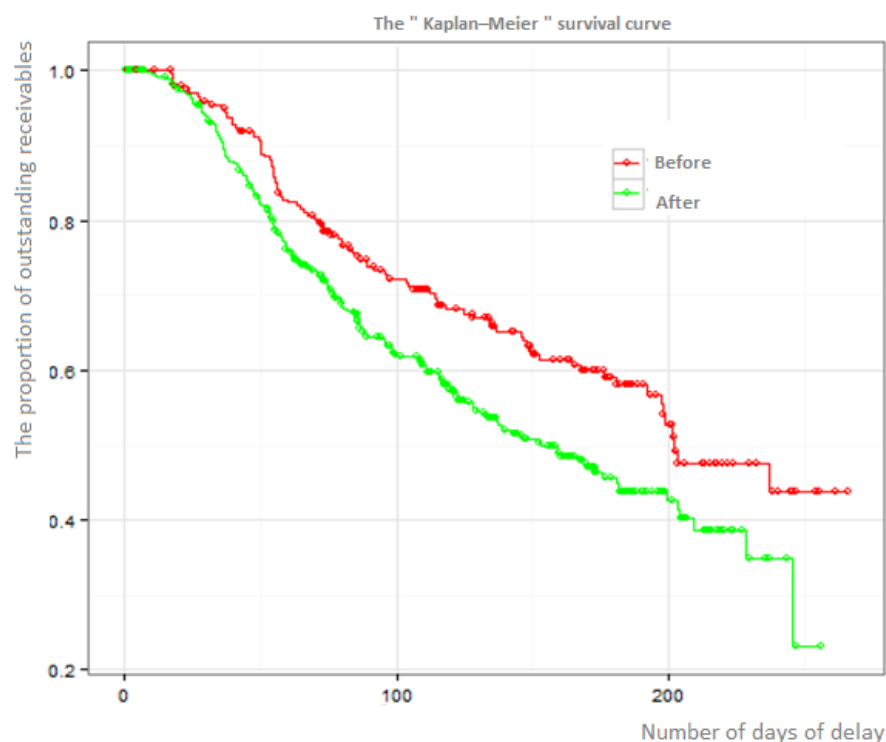
## Točnost napovedi modela

```
## Confusion Matrix and Statistics
##
##           Reference
## Prediction  default no-default
## default      9         1
## no-default   2        180
##
## Accuracy : 0.984
## 95% CI : (0.955, 0.997)
## No Information Rate : 0.943
## P-Value [Acc > NIR] : 0.0041
##
##
## 'Positive' Class : default
##
```

Po razvoju oz. izdelavi modela sledi njegova uporaba v operativnem poslovanju. Glede na napoved neplačila moramo organizirati delo tako, da **optimalno izkoristimo vire**, ki jih ima organizacija na voljo za izterjavo. Tiste primere, kjer je napoved verjetnosti neplačila recimo pod 20%, enostavno pustimo pri miru, saj bodo stranke zagotovo plačale (morda s kakim dnem zamude). Tiste, ki imajo verjetnost neplačila višjo od denimo 80%, nima smisla spominjati in opozarjati, saj nima sredstev in ne bomo dosegli prav veliko. Velja pa pripraviti vse potrebno za unovčitev zavarovanj in sodno izterjavo. V resnici se moramo **aktivno ukvarjati samo s primeri, ki imajo verjetnost neplačila med 20% do 80%**. Tu lahko dosežemo dobre rezultate tudi z majhnim vložkom našega časa in dela.

Končni učinek je smiselno prikazati recimo z uporabo **krivulje preživetja**. Ta prikazuje porazdelitev vseh zapadlih plačil glede na povprečno število dni zamude plačila. Večja kot je površina pod krivuljo, več imamo zapadlih neplačanih terjatev in več imamo sredstev »zunaj«. Manjša kot je skupna površina, bolj delamo v izterjavi in manj imamo denarja »zunaj«.

## Krivulja preživetja



Kot prikazuje slika zgoraj, se **z uporabo napovedne analitike** krivulja spusti z rdeče na zeleno. To pomeni, da smo z manj viri dosegli več in pobrali več sredstev. **Dobro poznavanje strank** je ključno za vsako družbo. A v primeru, ko moramo obravnavati veliko število naših strank, ko moramo to izvajati na dnevnem nivoju in je učinek odvisen od našega dela in truda, je smiselno uporabiti napovedno analitiko za optimizacijo našega dela.

**Strojno učenje** je danes tako močno in zmogljivo, da lahko v resnici prekaša naše izkušnje in znanje. Njegova uporaba prodira v vse pore poslovanja, predvsem v **prodajo** (navzkrižna prodaja, dani popusti, planiranje naročil), kjer sledimo večji fleksibilnosti in boljši uporabniški izkušnji, kot tudi v **zaledne procese** (kot je zgoraj opisani primer izterjave), kjer primarno sledimo večji učinkovitosti izvajanja nalog.