

Data mining

v procesu

vymáhání pohledávek

Miloš Uldrich

Pohledávka je charakterizována řadou proměnných. Z hlediska statistického modelování jde o proměnné, podle kterých lze pohledávky shlukovat dle různých hledisek. Dataminingové modelování ale může pomoci i jinde než pouze v selekci případů. Může významně usnadnit klasifikaci jednotlivých případů a vylepšit dosud stanovené scénáře zacházení s jednotlivými případy.

Začneme trochu „odlehčenějším“ pohledem. „Dobrý den, jsem pohledávka, tedy nárok na příjem peněžních prostředků od konkrétních subjektů ve stanovené době a výši. Odpočívám v databázi mezi dalšími pohledávkami po splatnosti, někdy pouze v excelovském souboru. Charakterizuje mě relativně nízká výše dluhu, pohlaví dlužníka, kterým je muž středního věku s velkým poklesem kreditních plateb na svém účtu. V nedaleké budoucnosti mě čeká přehazování mezi různými kanceláři, kdy se na mě každý podívá, někde zavolá, napíše, ale asi nikdy nenajdu klid v šanonu ‚vyřízeno‘. Mně je jasné, že spolupráce s dlužníkem není často jednoduchá, ale proč to musí trvat tak

dlouho?“ „Já ti řeknu proč,“ ozve se sousední pohledávka. „Protože si neumějí spočítat, že některé kroky jsou v tomto případě zbytečné! To můj dlužník byl veden v databázi SOLUS a hned věděli, že standardní postup je ztráta času. A u tebe je to také jasné, i když v žádné databázi nejsi.“ „A na základě čeho to počítáš? Nedala by se nějak spočítat pravděpodobnost toho, že z tohoto konkrétního dlužníka jednou něco dostanou?“ snažila jsem se pochopit situaci. „Dala, ale to by mě tady musel někdo poslouchat,“ ozve se pan Data Miner. „Na základě zkušeností z předchozích tisíců záznamů se dá spolehlivě vypořádat, z koho co vymůžeme, a z koho nic. Na základě vašich předchůdců

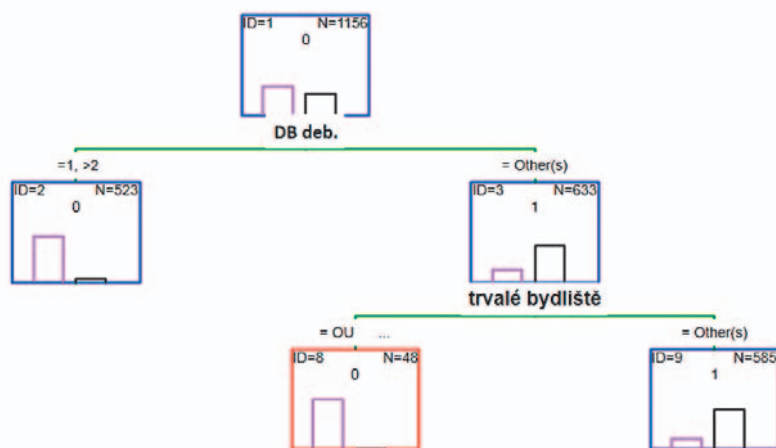
jsem se naučil různé kombinace vstupních údajů, které vedou k úspěšnému vyřízení pohledávky za pomoci běžných instrumentů, a také kombinace, které s velkou pravděpodobností, už v rané fázi procesu, ukazují na pohledávku, kterou už nikdo nevymůže. Na základě těchto zkušeností jsem potom sestrojil rozhodovací strom, jak s pohledávkou zacházet. Z historických dat jsem se naučil, které kombinace vstupů s velkou pravděpodobností ukazují na ‚toxickou‘ pohledávku, tedy tu, kterou již zpravidla nikdo nevymůže, a které kombinace ukazují na pravděpodobně slušně vymahatelnou pohledávku,“ dokončil vysvětlování pan Data Miner.

Rozhodovací strom

Dostupné proměnné se budou lišit podle vlastníka pohledávky. První signály přichází již z behaviorálních charakteristik, jako jsou například nižší obraty na účtech, nekruté inkaso, informace o nezaplacení tarifu, pojištění atd. Další proměnné, které potom charakterizují vlastní pohledávku po splatnosti, jsou například výše dluhu, fyzická či právnická osoba, počet jiných pohledávek, přítomnost v různých databázích dlužníků, exekuční řízení, kontaktní údaje apod.

Obrázek 1 ukazuje prvních několik uzlů rozhodovacího stromu. Histogramy uvnitř zachycují poměrné zastoupení skupiny úspěšných pohledávek (růžový „domeček“), tedy těch z daného počtu subjektů (N),

Obr. 1: Rozhodovací strom (DB deb. – debtors database, centralizovaná databáze dlužníků)



kteří banka nevyhovla, černý „domeček“ procento úspěšných pohledávek, které byly zařazeny do dané kategorie.

Z těchto několika málo uzlů je vidět, že šance na úspěšný proces (1), který končí kompletním umořením dluhu, významně klesá, pokud má již dlužník v databázi evidovanou alespoň jednu jinou pohledávku (ve schématu označeno =1, >2), firma či jedinec je v insolvenční či osobní bankrotu atd. Pokud osoba nemá žádné předchozí resty, je podstatně větší pravděpodobnost, že pohledávka nebude ztrátová. Dalším kritériem v pořadí pro tento konkrétní typ dat je místo trvalého bydliště. Pokud je bydlištěm městská radnice (OU), tak je jasné, že osoba je bez vlastního domova, případně má nějaké další důvody pro přihlášení na obecní úřadě, například strach z exekuce z předchozích pohledávek, šance na zaplacení pohledávky v tomto případě není prakticky žádná.

Tento příklad má pouze dva uzly a úspěšnost klasifikátoru je zde velká. Takovýto rozhodovací strom by se však v praxi dále větvil a pohledávka by se „probublávala“ do ostatních tříd. Další proměnné, které by měly významný vliv na potencionální vymahatelnost pohledávky, jsou například velikost dluhu, status dlužníka (právník/fyzická osoba) atd. Tyto proměnné by dále během průchodu stromem určovaly, jaká je šance na zaplacení dlužníkem. Model je vždy zatížen nějakou chybou odhadu, přesto lze při dodržení pravidel dataminingového modelování získat velmi dobré klasifikační modely, které mohou přinést důležitý úhel pohledu na pohledávku ještě v rané fázi vymáhání.

Výstupem analýz je tedy soubor pravidel, který ukazuje posloupnost rozhodnutí a významnost jednotlivých uzlů. Některé skutečnosti, respektive vlastnosti objektů (v grafu jako uzly), podle kterých se dataminingový model rozhoduje, nejsou zpravidla pro věřitele žádnou novinkou, přesto tyto modely zpravidla ukáží nový pohled na některé procesy vymáhání a významně obohatí nastavená pravidla celého procesu vymáhání a práce s pohledávkou. Tyto modely mohou upozornit na některou skutečnost, kterou jsme dosud přehlíželi. Velmi často také prokáží společný význam některých proměnných, které samy o sobě nikterak významné nejsou.

Využití dataminingového modelu, reprezentovaného konkrétním stromem, na nově přichozí pohledávky říkáme nasazení modelu (deployment). Nově přichozí soubor „oskórujeme“ dle pravidel našeho nejlepšího vybraného modelu a získáme pravděpodobnosti úspěchu jednotlivých případů.

Výstupem z modelu je tedy skóre úspěšnosti, tj. výše pravděpodobnosti, že pohledávku vymůžeme v nějakém konkrétním bodě procesu, na který jsme model „učili“ během trénovacího procesu.

Dalším využitím takovýchto analýz obecně je možnost obohacení interních pravidel, která se daného procesu týkají. I nepatrné zpřesnění procesu vymáhání může v úhrnu ušetřit velké množství času za posílání obsilek, telefonování apod. Stejně je tomu i u ostatních procesů například u akvizice zákazníků, retence apod.

Co oblast, to jiný přístup

V rozhodovacím procesu, jak s pohledávkou naložit, hraje roli celá řada faktorů. Nastavení pravidel pro vymáhací proces se liší dle povahy pohledávky. Rozdíl pohledu na vymáhání se bude lišit podle toho, co je předmětem dluhu. Procedura vymáhání se bude odlišovat podle toho, dlužil-li osoba za energie, za tarif mobilnímu operátorovi, nebo přestala-li splácet úvěr. Některé rysy budou vždy shodné, ale jiné nikoliv, neboť pokud někdo nesplácí leasing na auto nebo to přežene s telefonováním, které se mu prodáží, neznamená to ještě, že nesplácí energie. V určitých procesech také není žádoucí zákazníka za každou cenu o dlužnou částku připravit, neboť je pravděpodobné, že se naštve a odejde ke konkurenci, a náklady na akvizici nově přichozícího zákazníka jsou nepoměrně větší. V určitých oblastech jde spíše o navrácení zákazníka do správných kolejí a o vytvoření nějakého kompromisního řešení (restrukturalizaci jeho dluhu), díky kterému zákazník stále setrvává u naší společnosti. V budoucnu z něj opět může být bonitní klient.

Dalším trendem ve vymáhání je návrat k individuálnímu posuzování. Opět záleží na povaze procesu. Pokud firma nakoupí pohledávky, je cílem vymoci jich co nejvíce a stanovit procento těch, které nemá smysl vymáhat. Pokud však mluvíme o přístupu k vymáhání u osoby, která je současně naším dlouholetým zákazníkem, budeme se pravidla lišit. Někdy se může stát, že kvalitní zákazník, který například spadá do některého atraktivnějšího zákaznického profilu (možné příklady zákaznických profilů ilustruje obrázek 2), si při změně účtu zapomenou změnit inkaso a platbu zpozdí a shodou okolností se mu operátor nedovolá, protože je na dovolené na jachtě. Dle expertních pravidel nastavených v interním systému je nyní tento zákazník na úrovni „běžných“ neplatičů, kteří se vyhýbají zodpovědnosti. Jde přitom

o respektovaného zákazníka. V takovýchto případech se mnohem více osvědčuje individuální přístup.

Banking	Mobile
Classic users	Heavy users
Shoppers /Transactioners	Stars
Borrowers	Professional users
Investors	SMS users
Travelers	Basic users
Non active	Non active

Obr. 2: Příklady zákaznických profilů

Tento přístup však musí být podpořen automatizací celého postupu, protože odpovědný pracovník nemůže procházet všechny dlužníky a rozhodovat se na základě platební historie, výše tarifu apod., komu zavolat a komu pošle SMS. Je třeba mít model, který spolehlivě klasifikuje ty zákazníky, které v žádném případě nechceme rozzlobit. Pokročilým modelováním tak můžeme relativně levně získat malou množinu velmi dobrých zákazníků, kteří sice z nějakého důvodu nezaplátili, ale s velkou pravděpodobností to nemá nic společného s jejich finanční situací, a možná ani nevědí, že k něčemu takovému došlo. U nich je na místě taktní upozornění. U standardních zákazníků se potom spokojíme s robotizovaným postupem v rané fázi procesu vymáhání (různé důrazné SMS zpráva, písemná forma apod.). Pokud jde však stále o našeho klienta, tak ani jeho nechceme ztratit, ale zároveň bychom rádi, aby částku uhradil, proto se v různých fázích používají různé motivační prvky, jako například odpuštění sankcí za pozdní platbu atd.

Nyní se nebudeme zabývat prevencí, která je při poskytování úvěru, tarifu apod. základní. Prevencí se rozumí správné vyhodnocení rizika před poskytnutím úvěru. Zde také dataminingové modelování hraje svou roli, tento článek měl poukázat na využití statistické analýzy dat v různých fázích již samotného vymáhacího procesu. Dataminingové modelování může výrazně pomoci s odhadem výtěžnosti konkrétní pohledávky v konkrétní fázi procesu a tím podpoří již definovaná firemní rozhodovací pravidla, která jsou založena na předchozích zkušenostech, legislativě a dalších kritériích. ■

Autor působí jako odborný konzultant ve společnosti StatSoft.