

Kalibrace scoringových modelů

Finanční matematika v praxi III
Hotel Podlesí
3. – 4. září 2013

Pavel Plát

pavel.plat@rb.cz

Raiffeisenbank a.s., Policy & Analysis



AMathNet
síť pro transfer znalostí v aplikované matematice

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

1. Scoringový model

Business pohádka...

- Banka poskytuje klientům úvěry a spravuje úvěrové portfolio
- Z hlediska plnění závazků vůči bance je každý klient/kontrakt hodnocen buď jako dobrý nebo jako špatný (default)
- Někteří klienti mají vyšší šanci, že se dostanou do problémů než jiní.
- O každém klientu/kontraktu má banka nějaké informace
- Na základě aktuální situace klienta/kontraktu chceme predikovat schopnost plnit závazky vůči bance v následujícím období
- Hodnocení klienta je jednoznačně definované a opakovatelné

...a trocha formalismu

- Označme \mathbf{K} množinu všech klientů/ kontraktů
- $D_k = \begin{cases} 0 & \text{jestliže } k \in \mathbf{K} \text{ je dobrý} \\ 1 & \text{jestliže } k \in \mathbf{K} \text{ je špatný} \end{cases}$
- Používáme pravděpodobnostní model, tj. chceme predikovat pravděpodobnost defaultu
 $PD = P(D_k = 1)$
- Situace klienta/kontraktu $k \in \mathbf{K}$ je popsána bodem ve vhodně zvoleném měřitelném prostoru (obvykle \mathbf{R}^n)
 $x_k = (x_{k,1}, \dots, x_{k,n})$
- $P(D_k = 1 \mid x_k) = p(x_k)$
- SCORE: $\mathbf{R}^n \rightarrow \mathbf{R}$

1. Scoringový model


K čemu je skorekarta?

Jasně definovaná pravidla

- Automatizace
- Objektivita
- Opakovatelnost

Optimalizace využití informace

- Využití „soft“ ukazatelů
- Kombinace více ukazatelů



$$P(D = 1 \mid \text{SCORE} = x, \text{ v čase } t) = q(x, t)$$

- $q: R^2 \rightarrow [0,1]$
- q je v x monotonní

2. Kalibrované a nekalibrované score

Nekalibrované score

- Stejné základní ukazatele vstupující do výpočtu vedou v různém čase ke stejné hodnotě nekalibrovaného score
(nekalibrované score „pana Nováka“ se v čase nemění)
- Závislost PD na hodnotě nekalibrovaného score se v čase mění

$$q(\mathbf{x}, t) = P(D = 1 \mid \text{SCORE}^{\text{(NONCAL)}} = \mathbf{x}, \text{ v čase } t)$$

- $t_1 \neq t_2$, pak

$$q(x, t_1) \neq q(x, t_2)$$

- Rizikovitost v závislosti na nekalibrovaném score vypočteném různými scorekarty není obecně srovnatelná. Dvě různé scorekarty:


$$q_1(x, t) \neq q_2(x, t)$$

2. Kalibrované a nekalibrované score

Standardní stupnice a kalibrované score

Standardní stupnice

- Definuje vztah mezi hodnotou score a pravděpodobností defaultu



Kalibrované score ($\text{SCORE}^{\text{CAL}}$)

- Platí v čase invariantní vztah mezi hodnotou score a pravděpodobností defaultu definovaný pomocí standardní stupnice
- Stejně základní ukazatele vstupující do výpočtu vedou v různém čase k různé hodnotě kalibrovaného score
(pravděpodobnost selhání „pana Nováka“ se v čase mění, tzn. má v čase různé kalibrované score)

$$p(\mathbf{x}) = P(\mathbf{D} = 1 \mid \text{SCORE}^{\text{CAL}} = \mathbf{x})$$

- Rizikovost v závislosti na kalibrovaném score vypočteném různými scorekarty je srovnatelná. Dvě různé scorekarty:

$$p_1(x) = p_2(x)$$

2. Kalibrované a nekalibrované score

A co my? (RBI standardní stupnice)

Score	Poměr šancí	ln(poměr šancí)	PD
460	2.25	0.811	30.77%
500	4.5	1.504	18.18%
540	9	2.197	10.00%
580	18	2.890	5.26%
620	36	3.584	2.70%
660	72	4.277	1.37%
700	144	4.970	0.69%
740	288	5.663	0.35%
780	576	6.356	0.17%
820	1152	7.049	0.09%

- score 660 = poměr šancí 72
- dvojnásobný poměr šancí každých 40 bodů

$$p(x) = \frac{1}{1 + \exp(i_{RBI} + s_{RBI} \cdot x)}$$

$$i_{RBI} = \ln(72) - \frac{660 \cdot \ln(2)}{40} \quad s_{RBI} = \frac{\ln(2)}{40}$$

- Lineární závislost mezi score a logaritmem poměru šancí:

$$\ln \left(\frac{1 - p(x)}{p(x)} \right) = i_{RBI} + s_{RBI} \cdot x$$

2. Kalibrované a nekalibrované score

A co my? (URG ratingová stupnice)

- Na základě kalibrovaného score je stanoven rating


Score	Rating	Score	PD (%)
< 500	4.5	< 500	> 18.18
[500 , 540)	4.0	[500 , 540)	(10.00 , 18.18]
[540 , 580)	3.5	[540 , 580)	(5.26 , 10.00]
[580 , 620)	3.0	[580 , 620)	(2.70 , 5.26]
[620 , 660)	2.5	[620 , 660)	(1.37 , 2.70]
[660 , 700)	2.0	[660 , 700)	(0.69 , 1.37]
[700 , 740)	1.5	[700 , 740)	(0.35 , 0.69]
[740 , 780)	1.0	[740 , 780)	(0.17 , 0.69]
≥ 780	0.5	≥ 780	≤ 0.17

2. Kalibrované a nekalibrované score

Kalibrované nebo nekalibrované score?

Nekalibrované score

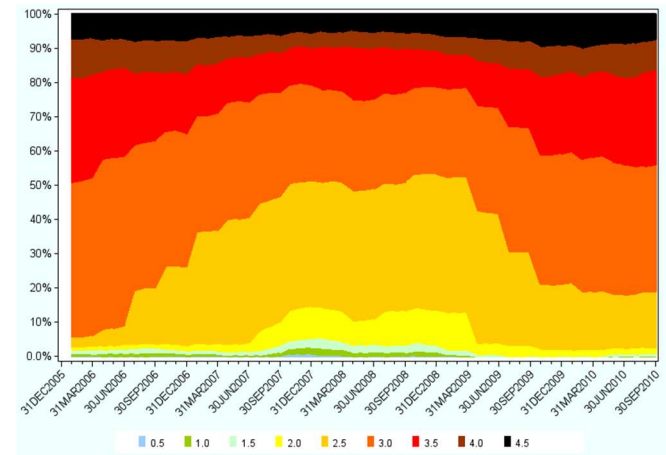
- Ratingová struktura:
 - Pokud banka nemění procesy, výrazně se nemění
 - Její vývoj odráží změny v portfoliu z pohledu ukazatelů vstupujících do scorekarty
 - Neříká mnoho o vývoji rizikivosti



- Scvhalovací strategie (Cut-off):
 - Je třeba měnit dle vývoje rizikivosti

Kalibrované score

- Ratingová struktura:
 - Dynamičtější
 - Nese informaci o rizikivosti portfolia
 - Srovnatelná mezi různými scorekartami



- Scvhalovací strategie (Cut-off):
 - Není třeba měnit

3. Kalibrace

Kalibrace

- **Cíl: Najít transformaci, která převede nekalibrované score na kalibrované**

- Hledáme $f_t: S^{(\text{NONCAL})} \rightarrow S^{(\text{CAL})}$ pro kterou platí:

$$q(x,t) = p(f_t(x))$$

- Předpoklady o tvaru funkce $q(x,t)$
 - Podobně jako při vývoji scorekarty můžeme použít logistickou transformaci
 - Lineární závislost $\ln(\text{ODDS})$ a score je příliš omezující předpoklad
 - Chceme umožnit korekci závislosti score na vybraných ukazatelích

$$q(x,t) = \frac{1}{1 + \exp(g_t(x) + \sum_{v \in SV} \gamma_{t,v} v)} \quad \Rightarrow \quad \ln \left(\frac{1 - q(x,t)}{q(x,t)} \right) = g_t(x) + \sum_{v \in SV} \gamma_{t,v} v$$

$$f_t(x) = -i_{\text{RBI}} / s_{\text{RBI}} + 1 / s_{\text{RBI}} \left(g_t(x) + \sum_{v \in SV} \gamma_{t,v} v \right)$$

3. Kalibrace

Odhad g_t

- **Potřebujeme konkrétnější specifikaci $g_t(\mathbf{x})$:**

$$g_t(\mathbf{x}) = \sum_i \beta_{t,i} h_i(\mathbf{x}),$$

- $h_i(\mathbf{x})$ jsou velmi jednoduché funkce score.
- Příklad: $h_i(\mathbf{x}) = x^i$ (polynomiální transformace score při kalibraci)

- Výsledný model:

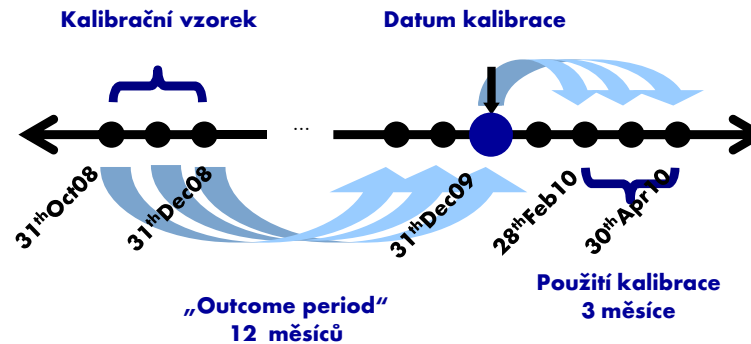
$$q(\mathbf{x}, t) = \frac{1}{1 + \exp\left(\sum_i \beta_{t,i} h_i(\mathbf{x}) + \sum_{v \in SV} \gamma_{t,v} v\right)}$$

- $\beta_{t,i}$ a $\gamma_{t,v}$ **mohu odhadnout pomocí logistické regrese**

3. Kalibrace

Kalibrační vzorek

- Můžeme použít data s ukončenou outcome period, tzn. 12 měsíců stará data



Stabilita versus aktuálnost

- Pro relevantní odhady v logistické regresi potřebuji dostatečný počet defaultních klientů
 - ⇒ **Pravidlo , které určí délku kalibračního vzorku podle počtu pozorovaných špatných klientů**
- Nejvíce chci zohlednit nejaktuálnější data
 - ⇒ **Každému pozorování přiřadím váhu podle jeho stáří**

3. Kalibrace

Délka kalibračního vzorku, váhová funkce

Váhová funkce

- Požadavky
 - Starší pozorování mají menší váhu
 - Nastavitelná rychlost zapomínání
- Formalizace:
 - $w: Z \times [0,1] \rightarrow \mathbb{R}$
 - $z_1 < z_2 \Rightarrow w_\alpha(z_1, \alpha) \leq w(z_2, \alpha)$
 - $\alpha_1 < \alpha_2 \Rightarrow w(z, \alpha_1) \geq w(z, \alpha_2)$

Další parametry

- TARGET_N_B - požadovaný počet defaultních klientů ve vzorku
- MIN_LS - minimální délka kalibračního vzorku
- MAX_LS - maximální délka kalibračního vzorku

- Délka kalibračního vzorku:

$$LS_{t,w} = \min \left(\max \left(\min \left\{ l : \sum_{i=0}^{l-1} w(-12-i, 1) \cdot n_B(t-12-i) \geq \text{TARGET_N}_B \right\}, \text{MIN_LS} \right), \text{MAX_LS} \right)$$

- Parametrizace váhové funkce:

$$\alpha_t = 1$$
$$\max \left\{ \alpha : \sum_{i=0}^{\text{MAX_LS}-1} w(-12-i, \alpha) \cdot n_B(t-12-i) \geq \text{TARGET_N}_B \right\}$$
$$0$$

když $LS_t < \text{MAX_LS}$

když $LS_t = \text{MAX_LS}$

když $\sum_{i=0}^{\text{MAX_LS}-1} w(-12-i, 0) \cdot n_B(t-12-i) \leq \text{TARGET_N}_B$

3. Kalibrace

A co my? (Parametrizace kalibrací)

- **$g_t(\mathbf{x})$**

- Lineární transformace

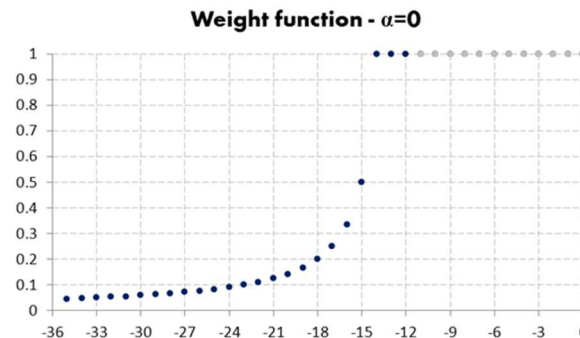
$$g_t(x) = \beta_{t,0} + \beta_{t,1}x$$

- Pokud je detekována nelinearita v závislosti mezi kalibrovaným score a logaritmem poměru šancí, pak

$$g_t(x) = \beta_{t,0} + \beta_{t,1}x + \beta_{t,1}x^2 + \beta_{t,1}x^3$$

- **Váhová funkce**

$$w(z, \alpha) = \frac{1}{(\max(1, -z - 13))^\alpha}.$$



- **Další parametry**

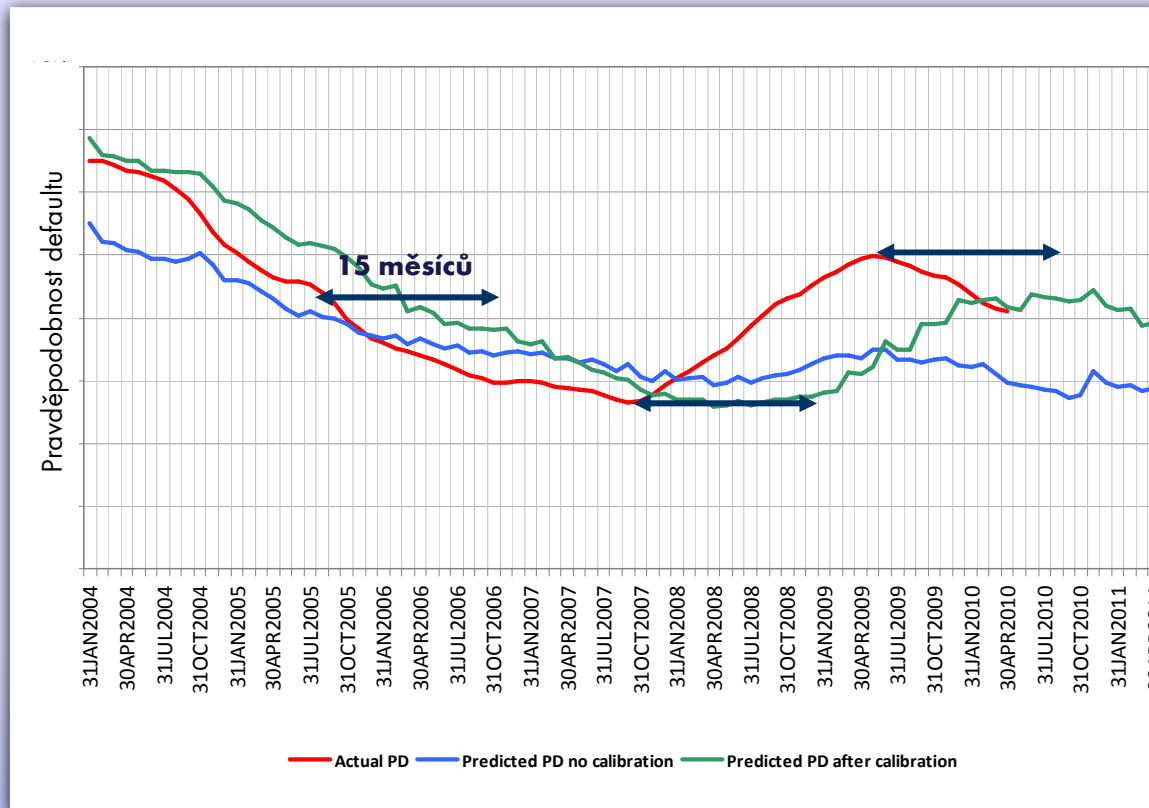
- $TARGET_{N_B} = 350$

- $MIN_{LS} = 3$

- $MAX_{LS} = 24$

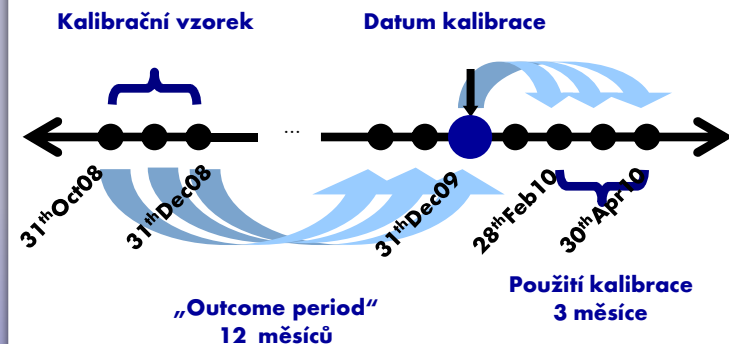
3. Kalibrace

„Forward looking“ kalibrace – motivace



▪ Chyba kalibrace založené na historii

- hlavní důvod je zpoždění mezi kalibračním vzorkem a obdobím použití kalibrace.



▪ Je možné kalibrovat lépe? Snad ano!

- prediktivní model pro PD (červená křivka) s použitím makroekonomických veličin
- použít makroekonomickou predikci PD k úpravě kalibrační transformace

3. Kalibrace

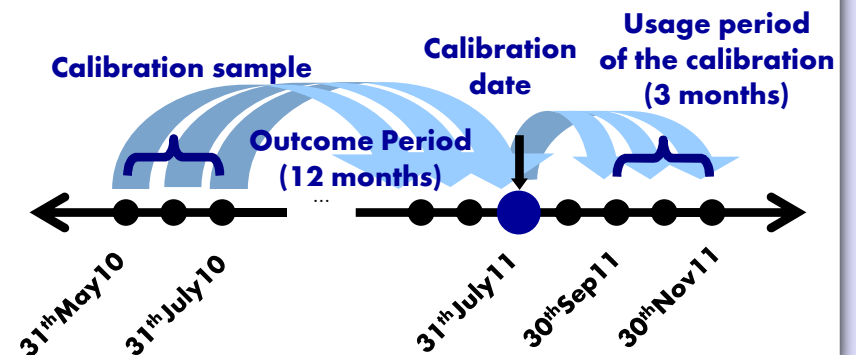
Historie vs. budoucnost

Historická kalibrace

- Kalibrace založená na historickém kalibračním vzorku.
- Logistická regrese s jedním prediktorem SCORE* (nekalibrované score).

Výstup:

- $f_t(x)$
- $SCORE^{(CAL,history)} = f_t(SCORE^{(NONCAL)})$



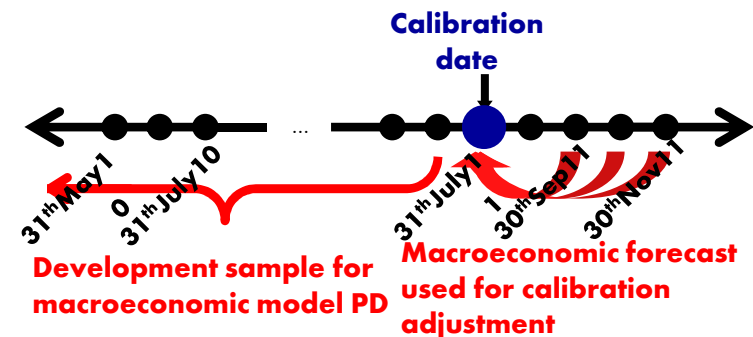
Predikce PD

- Predikce PD založená na makroekonomickém modelu.

Výstup:

- $PD_m^{(macro)}$ - makroekonomická predikce váženého PD v měsíci m

$$PD^{(target)} = \frac{1}{3} \sum_{m \in \text{období použití kalibrace}} PD_m^{(macro)}$$



3. Kalibrace

Úprava historické kalibrace dle predikce PD

- Korekce interceptu kalibrační transformace získané z historické kalibrace tak aby PD predikované pomocí výsledného kalibrovaného score bylo na kalibračním vzorku rovno požadované hodnotě dle makroekonomické predikce. Tzn je třeba nalézt takové Δ aby platilo

$$PD^{(target)} = \frac{1}{N} \cdot \sum_{\substack{\text{contract } i \in \\ \text{calibration sample}}} \frac{1}{1 + \exp\left(\ln(72) - \frac{660}{40} \ln(2) + \frac{\ln(2)}{40} (\Delta + f_i(\text{SCORE}_i^{(NONCAL)}))\right)}$$

- Iterativní algoritmus pro výpočet Δ (ukončit když $\Delta^{(j+1)} - \Delta^{(j)}$ je dostatečně malé):

$$\Delta^{(0)} = 0, PD^{(i)} = \frac{1}{N} \sum \frac{1}{1 + \exp\left(\ln(72) - \frac{660}{40} \ln(2) + \frac{\ln(2)}{40} (\Delta^{(i)} + f_i(\text{SCORE}_i^{(NONCAL)}))\right)}$$

$$\Delta^{(i+1)} = \Delta^{(i)} + \frac{40}{\ln 2} \left(\ln \frac{1 - PD^{(target)}}{PD^{(target)}} - \ln \frac{1 - PD^{(i)}}{PD^{(i)}} \right)$$

- Výstup:

- $\text{SCORE}^{(CAL)} = \Delta + f_i(\text{SCORE}^{(NONCAL)})$
(finální kalibrovaný score)

