

Doporučovací modely založené na rekurentních neuronových sítích

Autor: Ing. Ladislav Martínek

Vedoucí práce: Ing. Tomáš Řehořek, Ph.D.

Katedra aplikované matematiky, Fakulta informačních technologií, České vysoké učení technické v Praze

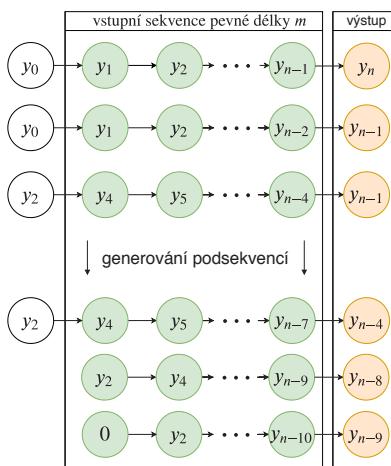


Motivace

- Problematika doporučovacích systémů a top-n doporučování
- Aplikace doporučovacích algoritmů v offline světě
- Využití přirozené sekvenční povahy interakcí
- Vývoj uživatelských preferencí v čase
- Opakování oblíbených položek

Předzpracování sekvenčních dat

- Klíčová část pro natřenování úspěšného modelu
- Prováděno pomocí slučování interakcí v časovém okně, výběr cílového typu interakce (nákup) nebo generování podsekvencí



Datové sady

- 3 datové sady, kde 2 anonymizované sady (D1, D2) byly společně se servery pro trénování poskytnuty firmou Recombee s.r.o
- Databáze yoochoose, D1 (obchod s nábytkem), D2 (primární dataset představující obchod rozvážející jídlo)
- Parametry D2
 - # interakcí: **344 809 934**
 - # uživatelů: 3 625 903
 - # položek: 2 295
 - hustota interakční matici 2.182 %

Cíle práce

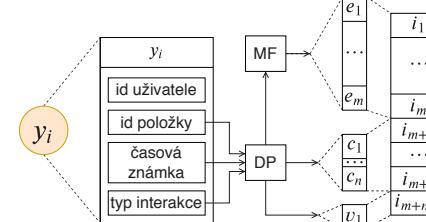
- Analýza interakčních dat a jejich zpracování
- Využití maticové faktORIZACE pro tvorbu vhodné reprezentace položek (embeddings)
- Návrh a implementace algoritmu pro tvorbu modelů založených na RNN
- Testování různých modelů a jejich hyperparametrisaci a diskuze výsledků

Reprezentace položek - tvorba embeddingů

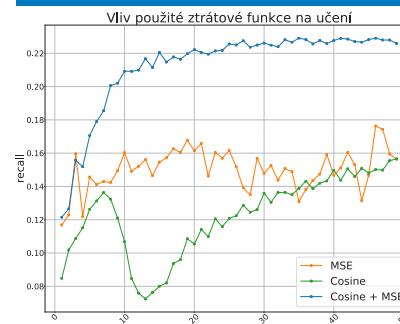
- Generování embeddingů pomocí maticové faktORIZACE (MF) upravené pro použití na datech tvořených pomocí implicitní zpětné vazby
- Využití kontextových dat v podobě časové známky a váhy interakce
 - Navrženy 3 způsoby zpracování časové známky
 - Diskretizace v rámci sekvence nebo celého datasetu a nebo normalizovaná absolutní hodnota

$$\mathbf{p}_u = (\mathbf{Q}\mathbf{C}^u\mathbf{Q}^T + \lambda\mathbf{I})^{-1}\mathbf{Q}\mathbf{C}^u\mathbf{z}_u^T$$

$$\mathbf{q}_i = (\mathbf{P}\mathbf{C}^i\mathbf{P}^T + \lambda\mathbf{I})^{-1}\mathbf{P}\mathbf{C}^i\mathbf{z}_i^T$$



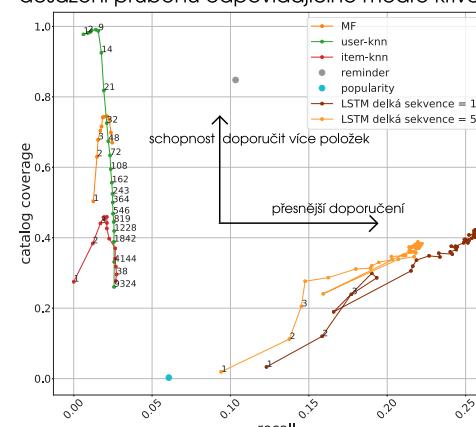
Experimenty



- Provedeno velké množství experimentů, především na datové sadě D2
- Použita metrika recall

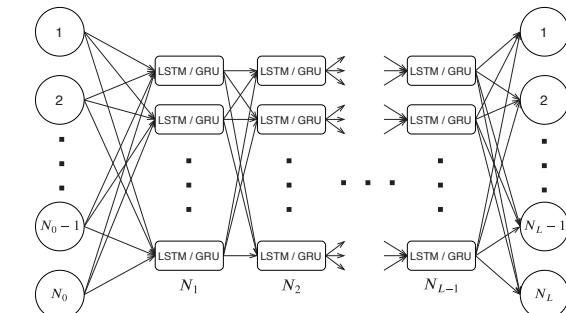
$$Recall@N = \frac{\#true-positive}{\#true-positive + \#false-negative}$$

- Kombinace s metrikou catalog coverage
- Vlevo je patrný vývoj metriky recall v průběhu trénování, kde bylo pro kvalitu modelu klíčové dosažení průběhu odpovídajícího modré křivce



Rekurentní model

- Shodná velikost vstupní a výstupní vrstvy
- Systémy jsou rekurentní
- Vstupní vrstva doplňována o kontextová data interakcí, především o časovou známku a její váhu



$$\begin{aligned} \mathcal{L} = & -\omega_1 \cdot \sum_{i=1}^m y_i \cdot \hat{y}_i \\ & + \omega_2 \cdot \sqrt{\sum_{i=1}^m y_i^2} \cdot \sqrt{\sum_{i=1}^m \hat{y}_i^2} \\ & + \omega_3 \cdot \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \\ & + \omega_4 \cdot (y_{m+n+1} - \hat{y}_{m+n+1})^2. \end{aligned}$$

Výsledky a závěr

- Zjištěny závislosti mezi velikostí embeddingů a velikostí modelu a jejich vliv na úspěšnost
- Zjištěn vliv délky sekvence na úspěšnost
- Podařilo se dosáhnout více jak dvojnásobného recallu oproti zvoleným standardním metodám

- Předzpracování má velký význam na kvalitu výsledného modelu
- Nutnost optimalizace hyperparametrů MF pro dosažení kvalitních embeddingů
- Model je již delší dobu nasazen při real-time doporučování a také real-time vybavování
- Diplomová práce byla zpracována pod záštitou firmy Recombee s.r.o