

CoFi^{RANK}

Maximum Margin Matrix Factorization for Collaborative Ranking

Markus Weimer

Karatzoglou

Quoc Viet Le

Alex Smola

読む人：藤巻@NEC

大体の流れ的な感じ

- 推薦系のシステムでは、「嫌いなもの」よりも「好きなもの」を当てるのが大事
- ランキングに適したスコア(ロス)を使おう
- 非凸だから凸に緩和(**Convex Upper Bound**)
- 問題は**MMMF**に定式化する
- 最適化は**Bundle Method**を適用

Convex Upper Bounds


Maximum Margin Matrix Factorization

Bundle Method

とかの技を知れてちょっとお得

Collaborative Rating

- Ranking
- Regression
- Matrix Factorization
 - Nonnegative Matrix Factorization 低ランク+非負制約を利用
 - Maximum Margin Matrix Factorization トレースノルム(or maxノルム)を利用



■に合うようにMとUを推定して全体を復元する

推薦系システムではユーザーの嗜好上位のものを当てる事が大事

(Normalized) Discounted Cumulative Gain

$y \in \{1, \dots, r\}^n$ アイテムのレートベクトル(降順)
 π 1~nの順列
 π_i i番目のアイテムのランク
 $k \in \mathbb{N}$ 適当な閾値(上位幾つ推薦するか)

$$\text{DCG}@k(\pi, y) = \sum_{i=1}^k \frac{(2^{y_i} - 1)}{\log(\pi_i + 1)}$$

$$\text{NDCG}@k(\pi, y) = \frac{\text{DCG}@k(\pi, y)}{\text{DCG}@k(\text{argsort}(y), y)}$$

y が π によって降順にソートされる場合にDCGは最大
(上位のものほどスコアが大きくなる)

$$R(\mathcal{X}, F, Y) := \sum_{i \in \mathcal{X}} \text{NDCG}(\Pi^i, Y^i)$$

Rを最大化するようなFを推定する → Rは非凸で扱いにくい

Hop-Step-Jump : Non-Convex \rightarrow Convex

Hop : Rを各ユーザーに分解し, -NDCGを最小化

$$\Delta(\pi, y) := \text{NDCG}(1_\pi, y) - \text{NDCG}(\pi, y) \quad (\pi = 1_\pi \text{で最小})$$

Step : 推定されたfと π によってソートしたfの差を考える

Polya-Littlewood-Hardy Inequality : $\langle a, b \rangle \leq \langle \text{sort}(a), \text{sort}(b) \rangle$

$$\psi(\pi, f) := \langle c, f_\pi \rangle \quad c_i = (i + 1)^{-0.25}$$

任意の降順ベクトル fを π で並べ替えたベクトル

Jump : 非凸な Δ の変わりに凸なUpper Boundを考える

$$l(f, y) \geq \Delta(y, \pi^*)$$

$$l(f, y) := \max_{\pi} \left[\Delta(\pi, y) + \langle c, f_\pi - f \rangle \right]$$

Maximum Margin Matrix Factorization

$$\text{Loss : } L(\mathcal{X}, F, Y) := \sum_{i \in \mathcal{X}} l(F^i \circ \Pi^i, \text{sort}(Y^i))$$

where $\Pi^i = \text{argsort}(Y^i)$

$$\text{Regularize : } \Omega[F] := \frac{1}{2} \min_{M, U} [\text{tr } MM^\top + \text{tr } UU^\top]$$

subject to $MU = F$

結局...

$$\underset{M, U}{\text{minimize}} L(\mathcal{X}_{\text{train}}, MU, Y) + \frac{\lambda}{2} [\text{tr } MM^\top + \text{tr } UU^\top]$$

repeat

For fixed M minimize (8) with respect to U .


For fixed U minimize (8) with respect to M .

until No more progress is made or a maximum iteration

Bundle Methods

イメージ的には、凸損失のlower boundを線形近似で抑えておいてlower boundの最大値を凸損失の代わりに使って近似を繰り返す

$$g(w) \geq \max_{\bar{w} \in W} [g(\bar{w}) + \langle w - \bar{w}, \partial_w g(\bar{w}) \rangle]$$



Algorithm 1 Bundle Method

Initialize $i = 1$, $w_0 = 0$, and $W = \{w_0\}$.

repeat

 Compute gradient a_i and offset b_i .

 Find minimizer $w_i := \operatorname{argmin}_w J_i(w)$

 Update $W \leftarrow W \cup \{w_i\}$ and $i \leftarrow i + 1$.

until converged

ちゃんと最適値に収束する

Optimization using Bundle Methods

Algorithm 1 Bundle Method(ϵ)

Initialize $t = 0, W_0 = 0, b_0 = 0$ and $H = \infty$

repeat

Find minimizer M_t and value L of the optimization problem

$$\underset{U}{\text{minimize}} \quad \max_{0 \leq j \leq t} [\text{tr } W_j^\top U + b_j] + \frac{\lambda}{2} \text{tr } U^\top U.$$

Compute $W_{t+1} = \partial_U L(\mathcal{X}_{\text{train}}, M_t U, Y)$

Compute $b_{t+1} = L(\mathcal{X}_{\text{train}}, M_t U, Y) - \text{tr } M_t W_{t+1}$

if $H' := \text{tr } W_{t+1}^\top M_t + b_{t+1} + \frac{\lambda}{2} \text{tr } U U^\top \leq H$ **then**

Update $H \leftarrow H'$

end if

until $H - L \leq \epsilon$

Computing the loss

理由が謎の式変形...

$$\Delta(\pi, y) := \text{NDCG}(1_\pi, y) - \text{NDCG}(\pi, y)$$

$$l(f, y) := \max_{\pi} \left[\Delta(\pi, y) + \langle c, f_\pi - f \rangle \right]$$

$$\text{const.} - \sum_{i=1}^n a_{\pi_i} b(y)_i = \text{const.} - \langle a_\pi, b(y) \rangle$$

$$a_i = \frac{1}{\log(i+1)} \quad b(y)_i = \frac{2^{y_i} - 1}{\text{DCG}@k(1_\pi, y)}$$

$$l(f, y) = \text{const.} + \max_{\pi} \left[\langle f_\pi, c \rangle - \langle a_\pi, b(y) \rangle \right]$$

Hungarian Marrigae algorithmで解ける
(π がpermutationだから整数計画になってるのが難しい)

Experiments

Dataset	Users	Movies	Ratings
EachMovie	61265	1623	2811717
MovieLens	983	1682	100000
Netflix	480189	17770	100480507