

ADVERSARIAL PERSONALIZED RANKING FOR RECOMMENDATION

Thomas Muñoz

8 de noviembre de 2018

PERTURBACIONES EN SISTEMAS RECOMENDADORES

Lo robusto de un sistema recomendador es qué tanto aguanta inyecciones de usuarios que apuntan a manipular el modelo mismo.

PERTURBACIONES EN EL INPUT



Figure: Perturbaciones aleatorias y adversariales

LAS PERTURBACIONES SON EN LOS PARÁMETROS

El input inicial en general son **entidades** discretas, por lo que perturbaciones en ese dato produce un cambio de significado del dato

$$(u, i, j) \rightarrow (u', i, j)$$

CASO DE MÁQUINAS DE FACTORIZACIÓN

Los parámetros son los embeddings. Es decir, dados los usuarios \mathcal{U} y los items \mathcal{I} , los conjuntos

$$P = \{p_u\}_{u \in \mathcal{U}}, Q = \{q_i\}_{i \in \mathcal{I}}$$




Figure: Perturbaciones en MF

BPR: UN MÉTODO L2R DE A PARES

Asume que las interacciones observadas tienen que estar mejor rankeadas que las no observadas, y maximiza ese margen.

Es decir, para cada usuario, aprende un orden de items (función de dos variables).

Itera sobre los parámetros de cualquier modelo de recomendación y minimiza la función

$$L_{BPR}(\mathcal{D}|\Theta) = \sum_{(u, i, j) \in \mathcal{D}} -\ln \sigma(\hat{y}_{ui}(\Theta) - \hat{y}_{uj}(\Theta)) + \lambda_{\Theta} \|\Theta\|^2,$$

PERTURBACIONES ADVERSARIALES EN MF-BPR

Primero se entrena el sistema recomendador y luego se le entrena con perturbaciones.

Se define la perturbación en cada paso de BPR como:

$$\Delta_{adv} = \arg \max_{\Delta, \|\Delta\| \leq \epsilon} L_{BPR}(\mathcal{D} | \hat{\Theta} + \Delta)$$

MEDIANTE LINEALIZACIONES SE OBTIENE LA PERTURBACIÓN


En cada paso, es decir, dado $\hat{\Theta}$, se tiene que

$$\Delta_{adv} = \epsilon \frac{\Gamma}{\|\Gamma\|}$$


Donde

$$\Gamma = \frac{\partial L_{BPR}(\mathcal{D}|\hat{\Theta} + \Delta)}{\partial \Delta}$$

PERTURBACIONES ALEATORIAS VS ADVERSARIALES



(a) Testing NDCG vs. ϵ



(b) Training Accuracy vs. ϵ

Figure: Comparación en Pinterest

PERTURBACIONES ALEATORIAS VS ADVERSARIALES




Figure: Comparación en Gowalla

SE MINIMIZA TAMBIÉN LO PROVOCADO POR LA PERTURBACIÓN

Luego de entrenar MF con criterio BPR, se sigue entrenando con esta nueva función objetivo a minimizar:

$$L_{APR}(\mathcal{D}|\Theta) = L_{BPR}(\mathcal{D}|\Theta) + \lambda L_{BPR}(\mathcal{D}|\Theta + \Delta_{adv}),$$

where $\Delta_{adv} = \arg \max_{\Delta, \|\Delta\| \leq \epsilon} L_{BPR}(\mathcal{D}|\hat{\Theta} + \Delta),$

SE OPTIMIZAN LOS PARÁMETROS PASO A PASO

Se itera por turnos minimizando en Θ y maximizando en Δ .

Para Δ :

$$l_{adv}((u, i, j)|\Delta) = -\lambda \ln \sigma(\hat{y}_{ui}(\hat{\Theta} + \Delta) - \hat{y}_{uj}(\hat{\Theta} + \Delta)).$$

Y se obtiene

$$\Delta_{adv} = \epsilon \frac{\Gamma}{\|\Gamma\|} \quad \text{where} \quad \Gamma = \frac{\partial l_{adv}((u, i, j)|\Delta)}{\partial \Delta}.$$

$$l_{APR}((u, i, j)|\Theta) = -\ln \sigma(\hat{y}_{ui}(\Theta) - \hat{y}_{uj}(\Theta)) + \lambda_{\Theta} \|\Theta\|^2 \\ - \lambda \ln \sigma(\hat{y}_{ui}(\Theta + \Delta_{adv}) - \hat{y}_{uj}(\Theta + \Delta_{adv})).$$

Y se obtiene

$$\frac{\partial l_{APR}((u, i, j)|\Theta)}{\partial \Theta} = - (1 - \sigma(\hat{y}_{uij}(\Theta))) \frac{\partial \hat{y}_{uij}(\Theta)}{\partial \Theta} + 2\lambda_{\Theta} \Theta \\ - \lambda (1 - \sigma(\hat{y}_{uij}(\Theta + \Delta_{adv}))) \frac{\partial \hat{y}_{uij}(\Theta + \Delta_{adv})}{\partial \Theta}.$$

Los sistemas recomendadores tienen como output una lista de recomendaciones *top – k* ($K=100$)

- **HR:** *hit ratio*, una métrica que se basa en el *recall*, si están o no los elementos relevantes.
- **NDCG:** *Normalized Discounted Cumulative Gain*, es sensible a la posición.

RESULTADOS




Figure: Entrenamiento en Yelp




Figure 4: Training curves of MF-BPR and AMF on Pinterest.




Figure: Entrenamiento en Pinterest y Gowalla

RESULTADOS




Figure: Efecto del tamaño del embedding

RESULTADOS

Ahora, después de entrenar, se ve el efecto de perturbaciones adversariales en los modelos.

| | $\epsilon = 0.5$ | | $\epsilon = 1.0$ | | $\epsilon = 2.0$ | |
|----------------|------------------|------------|------------------|------------|------------------|------------|
| Dataset | BPR | APR | BPR | APR | BPR | APR |
| Yelp | -22.1% | -4.7% | -42.7% | -12.5% | -63.8% | -31.0% |
| Pinterest | -9.5% | -2.6% | -25.1% | -7.2% | -55.7% | -23.4% |
| Gowalla | -26.3% | -2.9% | -53.0% | -13.2% | -78.0% | -29.2% |

Figure: NDCG: MF-APR vs MF-BPR

- **ItemPop:** más populares.
- **MF-BPR.** máquina de factorización con criterio BRP.
- **CDAE:** modelo que sirve para generalizar factores latentes.
- **NeuMF:** combina MF con perceptrones multicapa para aprender la función de interacción.
- **IRGAN:** discrimina si un dato es generado (perturbación) o es del *dataset*.

RESULTADOS

| | Yelp, HR | | Yelp, NDCG | | Pinterest, HR | | Pinterest, NDCG | | Gowalla, HR | | Gowalla, NDCG | |
|------------|----------------|----------------|----------------|----------------|----------------|----------------|-----------------|----------------|----------------|----------------|----------------|----------------|
| | K=50 | K=100 | K=50 | K=100 | K=50 | K=100 | K=50 | K=100 | K=50 | K=100 | K=50 | K=100 |
| ItemPop | 0.0405 | 0.0742 | 0.0114 | 0.0169 | 0.0294 | 0.0485 | 0.0085 | 0.0116 | 0.1183 | 0.1560 | 0.0367 | 0.0428 |
| MF-BPR | 0.1053 | 0.1721 | 0.0312 | 0.0420 | 0.2226 | 0.3403 | 0.0696 | 0.0886 | 0.4061 | 0.5072 | 0.1714 | 0.1878 |
| CDAE [35] | 0.1041 | 0.1733 | 0.0293 | 0.0405 | 0.2254 | 0.3495 | 0.0672 | 0.0873 | 0.4435 | 0.5483 | 0.1837 | 0.2007 |
| IRGAN [31] | 0.1119 | 0.1765 | 0.0361* | 0.0465* | 0.2254 | 0.3363 | 0.0724 | 0.0904 | 0.4157 | 0.518 | 0.1853 | 0.2019 |
| NeuMF [17] | 0.1135 | 0.1817 | 0.0335 | 0.0445 | 0.2342 | 0.3526 | 0.0734 | 0.0925 | 0.4558 | 0.5642 | 0.1962 | 0.2138 |
| AMF | 0.1176* | 0.1885* | 0.0350 | 0.0465* | 0.2375* | 0.3595* | 0.0741* | 0.0938* | 0.4693* | 0.5763* | 0.2039* | 0.2212* |

Figure: Comparación con distintos métodos

RESULTADOS




Figure: Efecto de ϵ

RESULTADOS




Figure: Efecto de λ

RESULTADOS




Figure: Efecto en la norma del embedding



He, X., He, Z., Du, X. & Chua, T. *Adversarial Personalized Ranking for Recommendation*, 2018.