

Filtrado Colaborativo Interactivo (ICF)

XIAOXUE ZHAO, WEINAN ZHANG , JUN WAN.



Introducción

Modelo

Resultados y
conclusiones



Introducción

Modelo

Resultados y
conclusiones

Alza de Sistemas Recomendadores (2006)


Alza de Sistemas Recomendadores (2006)

35% de las ventas de Amazon provienen de sus sistemas recomendadores.

Alza de Sistemas Recomendadores (2006)

Noticias de google aumentaron su trafico un 38% producto de sus sistemas recomendadores.

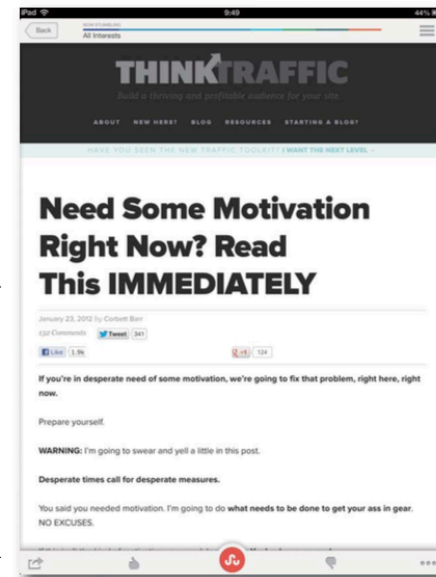
Nacen los sistemas recomendadores
interactivos



Pandora Radio Service
on iPhone


← Item
Delivery
Panel →

← User
Feedback
Panel →



StumbleUpon Web Engine
on iPad

(a) Two examples of Interactive Recommender Systems.



(b) Non-stop Recommendation-feedback loop.

¿cómo aprender rápidamente los intereses del usuario, sin comprometer su experiencia de recomendaciones ?

Soluciones existentes

Proceso de dos etapas:

1. Entrevista sobre los intereses.
2. Recomendaciones basadas en entrevista.

Un buen algoritmo no debiera distinguir entre estas dos fases.

Exploración v/s Explotación

- Recomendar para obtener mas conocimiento sobre el usuario (exploración)
- Recomendar basado en el conocimiento actual (explotación)

Objetivos

1. Modelar la interacción solo en base a ratings.
2. Maximizar la satisfacción total del usuario luego de todas las recomendaciones.



Función objetivo

Sea $r_{u,i(t)}$ el rating o recompensa recolectado por el usuario u , para el ítem $i(t)$ en el tiempo t .

$$\mathcal{H}(t) = \{i(1), r_{u,i(1)}, \dots, i(t-1), r_{u,i(t-1)}\} .$$

Ítem se selecciona según la información hasta el momento:

$$i(t) \equiv \pi(\mathcal{H}(t)) .$$

Función objetivo

$$\mathbf{i}^*(\cdot) = \arg \max_{\mathbf{i}(\cdot)} \sum_{t=1}^T \mathbb{E}[r_{u, \mathbf{i}(t)}],$$

Función objetivo

Ocupando el modelo de factores latentes:

$$r_{u,i} = \mathbf{p}'_u \mathbf{q}_i + \eta,$$

Función objetivo:

$$\begin{aligned} \mathbf{i}^*(\cdot) &= \arg \max_{\mathbf{i}(\cdot)} \sum_{t=1}^T \mathbb{E}[r_{u,i(t)} | t] \\ &= \arg \max_{\mathbf{i}(\cdot)} \sum_{t=1}^T \mathbb{E}_{\mathbf{p}_u, \mathbf{q}_{i(t)}} [\mathbf{p}'_u \mathbf{q}_{i(t)} | t] . \end{aligned}$$

¿ Como optimizar la función objetivo ?

1. Selección de ítems mediante muestreo.

Se obtienen p_u y q_i de la muestra, y se maximiza:

$$i^*(t)_{ts} = \arg \max_i \mathbb{E}(r_{ui} | \tilde{\mathbf{p}}_u, \tilde{\mathbf{q}}_i),$$

Usando probabilistic matrix factorization (PMF)

La distribución de probabilidad condicional del rating dado el usuario y el ítem sigue una distribución gaussiana:

$$p(r_{ui}|\mathbf{p}'_u\mathbf{q}_i, \sigma^2) = \mathcal{N}(r_{ui}|\mathbf{p}'_u\mathbf{q}_i, \sigma^2) .$$

Usando probabilistic matrix factorization (PMF)

Implementando Markov chain Monte Carlo and Gibbs Sampling (MCMC-Gibbs):

$$p(\mathbf{p}_u | R, Q, \sigma^2, \sigma_p^2, \sigma_q^2) = \mathcal{N}(\mathbf{p}_u | \boldsymbol{\mu}_u, \Sigma_u),$$

$$\boldsymbol{\mu}_u = (D_u' D_u + \lambda_p I)^{-1} D_u' \mathbf{r}_u,$$

$$\Sigma_u = (D_u' D_u + \lambda_p I)^{-1} \sigma^2.$$

$$\lambda_p = \sigma^2 / \sigma_p^2.$$

Con D_u matriz cuyas filas son los vectores de características de los ítems que el usuario a dado rating.

Usando probabilistic matrix factorization (PMF)

Para los ítems:

$$p(\mathbf{q}_i | R, P, \sigma^2, \sigma_p^2, \sigma_q^2) = \mathcal{N}(\mathbf{q}_i | \boldsymbol{\nu}_i, \Psi_i),$$

$$\boldsymbol{\nu}_i = (B_i' B_i + \lambda_q I)^{-1} B_i' \mathbf{r}_i,$$

$$\Psi_i = (B_i' B_i + \lambda_q I)^{-1} \sigma^2,$$

Con B_i matriz cuyas filas son los vectores de características de los usuarios que han dado rating al ítem.

Combinando PMF con Thompson Sampling

No es necesario actualizar los ítems después de cada feedback.

Para los usuarios estiman:

$$\tilde{\mathbf{p}}_{u,t} \sim \mathcal{N}(\mathbf{p}_{u,t} | \boldsymbol{\mu}_{u,t}, \Sigma_{u,t}),$$

$$\boldsymbol{\mu}_{u,t} = (D'_{u,t} D_{u,t} + \lambda_p I)^{-1} D'_{u,t} \mathbf{r}_{u,t},$$

$$\Sigma_{u,t} = (D'_{u,t} D_{u,t} + \lambda_p I)^{-1} \sigma^2.$$

Finalmente usando Thompson Sampling y PMF la selección del ítem en un tiempo t es:

$$i^*(t)_{ts} = \arg \max_i \tilde{\mathbf{p}}'_{u,t} \tilde{\mathbf{q}}_i,$$

2. Selección de ítems vía límites de confianza

Estos algoritmos consideran los vectores de características de los ítems como fijos y conocidos utilizando la estimación MAP v_i .

Linear Upper Confidence Bound

La recompensa esperada se encuentra dentro del intervalo:

$$\Theta_{i,t} = [\boldsymbol{\mu}'_{u,t}\boldsymbol{\nu}_i - \alpha\|\boldsymbol{\nu}_i\|_{2,\Sigma_{u,t}}, \boldsymbol{\mu}'_{u,t}\boldsymbol{\nu}_i + \alpha\|\boldsymbol{\nu}_i\|_{2,\Sigma_{u,t}}] \quad (25)$$

$$\|\boldsymbol{\nu}_i\|_{2,\Sigma_{u,t}} \equiv \sqrt{\boldsymbol{\nu}_i' \Sigma_{u,t} \boldsymbol{\nu}_i} .$$

Por lo tanto se elije el ítem:

$$i^*(t)_l = \arg \max_i (\boldsymbol{\mu}'_{u,t}\boldsymbol{\nu}_i + \alpha\|\boldsymbol{\nu}_i\|_{2,\Sigma_{u,t}}) .$$

Linear UCB generalizado

Se asume que la recompensa distribuye lineal:

$$r_{u,i(t)} = \rho(\mathbf{p}'_u \mathbf{q}_{i(t)}) + \eta(t),$$

Se ocupa una función mono-tónicamente creciente.

$$\rho(\mathbf{p}'_u \mathbf{q}_i) = \frac{1}{1 + e^{-\mathbf{p}'_u \mathbf{q}_i}}. \quad \text{o} \quad \rho(\mathbf{p}'_u \mathbf{q}_i) = \mathbf{p}'_u \mathbf{q}_i + \eta,$$

Se estima p_u de:

$$\sum_{\tau=1}^{t-1} (r_{u,i(\tau)} - \rho(\hat{\mathbf{p}}'_{u,t} \boldsymbol{\nu}_{i(\tau)})) \boldsymbol{\nu}_{i(\tau)} = 0.$$

Linear UCB generalizado

Se asume que la recompensa distribuye lineal:

$$i^*(t)_{gl} = \arg \max_i \left(\rho(\hat{\mathbf{p}}'_{u,t} \boldsymbol{\nu}_i) + c \sqrt{\log t} \|\boldsymbol{\nu}_i\|_{2, \Sigma_{u,t}} \right).$$

Linear ϵ -greedy

Escoge la estrategia greedy con probabilidad $1 - \epsilon$, o explorar con probabilidad ϵ

$$i^*(t)_g = \arg \max_i \boldsymbol{\mu}'_{u,t} \boldsymbol{\nu}_i.$$



Algoritmos a comparar

- Random.
- Popularity based.
- Greedy SVD.
- Active Learning.
- Interview Process.
- Thompson Sampling.
- Linear UCB.
- Linear UCB generalizado con función sigmoidea.
- Linear UCB generalizado con función lineal.
- Linear epsilon-greedy.

Métricas

- Cumulative Precision@T.

$$\text{precision@}T = \frac{1}{\#\text{users}} \sum_{\text{users}} \sum_{t=1}^T \theta_{\text{hit}} .$$

- Cumulative Recall@T.

$$\text{recall@}T = \frac{1}{\#\text{users}} \sum_{\text{users}} \sum_{t=1}^T \frac{\theta_{\text{hit}}}{\#\text{preferences}} .$$

- Cumulative nDCG@n.

$$\text{nDCG@}n = \frac{1}{\mathcal{Z}} \sum_{j=1}^n \frac{2^{r_j} - 1}{\log_2(j + 1)} ,$$

Resultados arranque en frío.

Table 2: Cold-start performance on MovieLens, EachMovie, and Netflix dataset.

Dataset	MovieLens (100k)				EachMovie				Netflix			
Measure	Cumulative Precision				Cumulative Precision				Cumulative Precision			
T	10	20	40	120	10	20	40	120	10	20	40	120
Random	0.690	1.390	2.925	8.420	0.545	1.125	2.245	6.285	0.245	0.455	0.88	2.395
Pop	5.060	9.500	15.710	42.170	3.200	6.72	11.200	24.675	4.700	9.335	17.760	45.370
SVD	6.360	11.035	19.390	43.155	4.095	7.590	13.295	31.435	5.675	10.410	18.975	48.900
AL	6.850	11.095	18.905	41.785	3.180	6.865	13.270	29.965	7.060	12.595	18.695	21.780
Interview	6.800	11.885	20.495	45.745	3.180	6.865	13.270	30.660	3.825	9.165	18.720	52.310
TS	6.465	11.31	19.565	43.745	4.605	8.270	14.025	31.395	6.160	11.420	20.585	52.300
ϵ -greedy	6.375	11.060	19.440	43.180	4.660	8.430	14.315	32.270	5.725	10.545	19.205	49.780
LinUCB	6.850	11.835	20.820	46.455	4.610	8.175	14.280	33.590	7.060	12.735	22.855	56.490
GLM-Lin	6.850	11.835	20.820	46.470	5.105	9.030	15.170	35.045	7.060	12.835	22.830	55.620
GLM-Sig	6.850	11.830	20.825	46.445	4.765	8.435	14.305	32.605	7.060	12.710	22.780	56.275
Improvement	7.7%*	7.2%*	7.4%*	7.7%*	24.7%*	19.0%*	14.1%*	11.5%*	24.4%*	23.3%*	20.5%*	13.7%
Measure	Cumulative Recall				Cumulative Recall				Cumulative Recall			
T	10	20	40	120	10	20	40	120	10	20	40	120
Random	0.006	0.012	0.024	0.076	0.004	0.009	0.016	0.047	0.001	0.001	0.002	0.007
Pop	0.047	0.088	0.144	0.376	0.025	0.053	0.087	0.194	0.015	0.029	0.055	0.139
SVD	0.058	0.099	0.171	0.369	0.037	0.066	0.111	0.246	0.018	0.033	0.059	0.149
AL	0.064	0.102	0.170	0.369	0.027	0.059	0.099	0.232	0.022	0.04	0.06	0.071
Interview	0.063	0.108	0.182	0.395	0.025	0.054	0.102	0.231	0.022	0.04	0.071	0.175
TS	0.060	0.104	0.175	0.380	0.037	0.066	0.109	0.240	0.020	0.036	0.064	0.160
ϵ -greedy	0.0578	0.100	0.172	0.372	0.040	0.071	0.118	0.261	0.020	0.037	0.067	0.173
LinUCB	0.064	0.109	0.187	0.409	0.038	0.068	0.115	0.251	0.022	0.04	0.072	0.173
GLM-Lin	0.064	0.109	0.187	0.409	0.042	0.072	0.121	0.272	0.022	0.041	0.071	0.171
GLM-Sig	0.064	0.109	0.187	0.409	0.038	0.067	0.113	0.252	0.022	0.04	0.071	0.173
Improvement	9.4%*	10.1%*	9.4%*	10.8%*	13.5%*	9.1%*	9.1%*	10.6%*	22.2%*	24.2%*	22.0%*	16.1%

Resultados arranque normal.

Table 3: Performance on Warm-start Users with Taste Drift on MovieLens and EachMovie.

Dataset	MovieLens (100k)				EachMovie			
Measure	Cumulative Precision				Cumulative Precision			
T	60	80	100	120	60	80	100	120
Random	2.420	3.100	3.730	4.435	3.532	4.400	5.363	6.279
Pop	16.025	18.420	20.490	22.775	19.526	20.437	21.416	22.447
SVD	18.620	21.290	24.060	25.980	19.447	22.453	25.458	28.353
TS	19.095	21.780	24.620	26.515	20.047	22.879	25.832	28.968
ϵ -greedy	18.995	21.72	24.535	26.480	19.984	22.904	25.974	28.805
LinUCB	20.005	22.875	25.775	27.780	20.205	23.137	26.221	29.247
GLM-Lin	19.895	22.905	25.665	27.775	22.853	25.916	28.863	31.711
GLM-Sig	20.000	22.835	25.760	27.790	20.437	23.358	26.279	29.284
Improvement	7.4%	7.6%*	7.1%	7.0%	17.5%*	15.4%*	13.4%*	11.8%*
Measure	Cumulative Recall				Cumulative Recall			
T	60	80	100	120	60	80	100	120
Random	0.038	0.050	0.063	0.074	0.038	0.050	0.063	0.074
Pop	0.245	0.286	0.321	0.358	0.126	0.148	0.169	0.189
SVD	0.267	0.311	0.351	0.379	0.126	0.148	0.169	0.189
TS	0.272	0.314	0.360	0.388	0.129	0.149	0.170	0.192
ϵ -greedy	0.273	0.317	0.363	0.391	0.13	0.15	0.172	0.191
LinUCB	0.291	0.341	0.389	0.422	0.132	0.155	0.178	0.199
GLM-Lin	0.291	0.342	0.388	0.424	0.156	0.180	0.204	0.223
GLM-Sig	0.291	0.341	0.388	0.421	0.138	0.161	0.182	0.201
Improvement	9.0%	10.0%*	10.8%	11.9%	23.8%*	21.6%*	20.7%*	18.0%*

Resultados ranking.

Table 4: Performance for Multiple-item Recommendations by Cumulative nDCG.

Dataset	MovieLens				EachMovie				Netflix			
Measure	nDCG@3		nDCG@5		nDCG@3		nDCG@5		nDCG@3		nDCG@5	
T	20	40	10	20	20	40	10	20	20	40	10	20
Random	0.750	1.563	0.369	0.701	0.619	1.280	0.290	0.586	0.263	0.46	0.145	0.255
Pop	4.876	8.669	2.666	4.633	3.864	5.588	1.752	2.913	5.29	9.165	2.687	4.693
SVD	6.099	9.832	3.361	5.345	5.043	8.083	2.651	4.379	7.465	12.733	3.983	6.837
TS	6.195	9.912	3.393	5.452	5.167	8.320	2.678	4.431	7.962	13.887	4.237	7.363
ϵ -greedy	6.080	9.845	3.352	5.333	5.181	8.482	2.689	4.509	7.591	13.009	4.006	6.87
LinUCB	6.391	10.250	3.419	5.519	4.996	8.381	2.689	4.466	8.113	14.085	4.221	7.376
GLM-Lin	6.369	10.253	3.427	5.472	5.367	8.862	2.815	4.719	7.834	13.569	4.145	7.265
GLM-Sig	6.363	10.236	3.424	5.432	5.156	8.375	2.718	4.494	8.081	14.094	4.199	7.353
Improvement	4.8%	4.3%	2.0%*	3.3%*	6.4%	9.6%	6.2%*	7.7%*	8.7%*	10.7%*	6.4%*	7.9%*

Casos de estudio.

Table 5: A case study of cold-start user #454 on Movielens. User feedback R: L-Like, D-Dislike, U-Unknown. Movie Genre Abbreviation: Ac-Action, Ad-Adventure, An-Animation, C-Comedy, CC-Children’s Comedy, D-Drama, R-Romance, S-Scientific Fiction, T-Thriller, W-War.

T	R	Movies recommended by SVD	Genres	R	Movies recommended by LinUCB	Genres
1	L	Star Wars (1977)	Ac,Ad,R,S,W	L	Star Wars (1977)	Ac,Ad,R,S,W
2	L	Raiders of the Lost Ark (1981)	Ac,Ad	L	Raiders of the Lost Ark (1981)	Ac,Ad
3	L	Fargo (1996)	C,D,T	U	The Godfather (1972)	Ac,C,D
4	D	The Silence of the Lambs (1991)	D,T	D	The Silence of the Lambs (1991)	D,T
5	D	Dante’s Peak (1997)	Ac,T	D	Return of the Jedi (1983)	Ac,Ad,R,S,W
6	U	Kika (1993)	D	D	The Empire Strikes Back (1980)	Ac,Ad,D,R,S,W
7	U	A Very Brady Sequel (1996)	C	L	Air Force One (1997)	Ac,T
8	U	Boomerang (1992)	C,R	U	Liar Liar (1997)	C
9	U	Black Sheep (1996)	C	U	Twelve Monkeys (1995)	D,S
10	L	The Saint (1997)	Ac,R,T	L	Contact (1997)	D,S
11	U	Kiss the Girls (1997)	C,D,T	D	Toy Story (1995)	An,CC
12	U	Batman (1989)	Ac,Ad,C,D	L	Braveheart (1995)	Ac,D,W
13	U	Matilda (1996)	CC	L	Titanic (1997)	Ac,D,R
14	D	Rock, The (1996)	Ac,Ad,T	L	Schindler’s List (1993)	D,W
15	D	The Usual Suspects (1995)	C,T	L	The Shawshank Redemption (1994)	D




Figure 3: A case study on handling taste drift.