

PERSONALIZED ACTIVE LEARNING FOR COLLABORATIVE FILTERING (2008)

Harpale A. & Yang Y.

Nicolás Morales (nvmorale@uc.cl)

11 de Octubre de 2016

Active Learning busca entrenar clasificadores/modelos usando un mínimo de datos de entrenamiento etiquetados, dado que obtener datos etiquetados puede ser costoso o inviable.

Dentro del pool de datos no etiquetados se identifican aquellos que sean más beneficiosos para entrenar el modelo, esto se logra con criterios como:

- Máxima reducción de incerteza/entropía
- Máxima reducción en error de predicción
- Máximo desacuerdo en un conjunto de clasificadores

A la fecha de publicación del artículo, Active Learning era utilizado principalmente en problemas de clasificación, es decir etiquetar instancias de acuerdo a la pertenencia a una clase.

El concepto de Active Learning para Collaborative Filtering sería relativamente nuevo a esa fecha.

Objetivo de Active Learning para Collaborative Filtering:

Minimizar el número de items de los que se solicita rating al usuario, para aprender el patrón de preferencias del usuario

Es relevante por que el sistema recomendador sabe poco de los usuarios nuevos y no se desea molestar al usuario con demasiadas preguntas.

Trabajo previo en Active Learning para Collaborative Filtering asume que los usuarios entregarán ratings para cualquier item que les pida el sistema.

Es un supuesto poco realista por que ello implica consumir el item (ver película por ej.), puede ser frustrante para el usuario que se le requiera evaluar items que no consumiría.

Ello lleva a desear personalizar el Active Learning de modo que se le soliciten ratings al usuario de items que si consumiría.

TRABAJO RELACIONADO

ASPECT MODEL

Modelo probabilístico de semántica latente donde los usuarios son considerados una mezcla de múltiples intereses o aspectos.

Cada usuario $u \in U$ tiene una probabilidad de pertenecer a un aspecto $z \in Z$, donde usuarios del mismo grupo tienen los mismos patrones de preferencias para evaluar los items $m \in M$, entonces los ratings se pueden calcular como:

$$P(r|u, m) = \sum_{z \in Z} p(r|m, z)P(z|u) \quad (1)$$

Notamos que $p(r|m, z)$ no depende del usuario, sino que modela las preferencias del grupo, mientras que los $P(z|u)$ caracterizan al usuario en un modelo de usuario $\Theta_u = \{\Theta_{u_z} : \Theta_{u_z} = P(u|z), \forall z \in Z\}$.

FLEXIBLE MIXTURE MODEL

Extensión del Aspect Model con dos capas de aspectos latentes, una que agrupa usuarios de intereses similares (z_u) y otra de items con patrones similares (z_m), con ello las probabilidades de una tupla (r, u, m) son calculadas como:

$$P(r, u, m) = \sum_{z_u, z_m} P(z_u)P(z_m)P(u|z_u)P(m|z_m)P(r|z_u, z_m) \quad (2)$$

ACTIVE COLLABORATIVE FILTERING

Una de las técnicas usadas es solicitar rating de un ítem que minimiza la entropía esperada en el modelo de usuario, donde Θ_{u_z} representa las probabilidades del usuario de pertenecer a los grupos, mientras que $\Theta_{u_z|m,r}$ denota el modelo posterior después de re-entrenar basado en un rating nuevo r para el ítem m , es decir, los $P(z|u, m, r)$, el ítem a solicitar está dado por:

$$m_u^* = \operatorname{argmin}_{m \in M} - \left\langle \sum_{z \in Z} \Theta_{u_z|m,r} \log \Theta_{u_z|m,r} \right\rangle_{P(r|m,u)} \quad (3)$$

Se usan los $P(r|u, m)$ dado que el rating r es desconocido para estos ítems. En este caso minimizar la entropía tiende a generar usuarios con pertenencia a un solo grupo de interés, lo que es contraproducente.

ACTIVE COLLABORATIVE FILTERING

Una solución es el uso de Bayesian Selection (BS), donde el modelo actualizado de usuario $\Theta_{u_z|m,r}$ es cambiado por el verdadero modelo de usuario Θ_u^{true} , con ello la ecuación para m_u^* queda como:

$$m_u^* = \operatorname{argmax}_{m \in M} \left\langle \sum_{z \in Z} \Theta_u^{\text{true}} \log \frac{\Theta_{u_z|m,r}}{\Theta_u^{\text{true}}} \right\rangle_{P(r|m,u)} \quad (4)$$

Esta ecuación queda maximizada cuando la distribución estimada es igual a la distribución verdadera siendo modelada. Dado que el verdadero modelo de usuario es desconocido, se estima como el valor esperado sobre la distribución del modelo de usuario a posteriori.

PERSONALIZED ACTIVE LEARNING

INCORPORANDO PERSONALIZACIÓN

Los items obtenidos por Bayesian Selection permitirán converger al modelo verdadero de usuario solo si el usuario entrega ratings para todos estos items, lo que no ocurre en la práctica.

Por ello se busca considerar también la probabilidad de que el usuario u evalúe un item m , es decir $P(m|u)$, con esto la ecuación queda como:

$$m_u^* = \operatorname{argmax}_{m \in M} \left(\left\langle \sum_{z \in Z} \Theta_u^{\text{true}} \log \frac{\Theta_{u_z|m,r}}{\Theta_u^{\text{true}}} \right\rangle_{P(r|m,u)} \right) P(m|u) \quad (5)$$

Esta ecuación es maximizada cuando ambos factores se maximizan.

La probabilidad $P(m|u)$ es estimada como:

$$P(m|u) = \sum_{z \in Z} P(m|z)P(z|u) \quad (6)$$

Donde $P(m|z)$ se obtiene con:

$$P(m|z) = \frac{\sum_{u \in U} P(z|u)I(u, m)}{\sum_{u \in U} \sum_{m' \in M} P(z|u)I(u, m')} \quad (7)$$

Donde $I(u, m)$ vale 1 si el usuario u evaluó el ítem m y vale 0 en otro caso.

EXPERIMENTOS

SETUP EXPERIMENTAL

Se usaron datasets de MovieRating y MovieLens:

| | MovieRating | MovieLens |
|-------------------------------------|-------------|-----------|
| Number of users | 500 | 943 |
| Number of movies | 1000 | 1682 |
| Average number of rated movies/user | 87.7 | 106.5 |
| Rating Scale | 1-5 | 1-5 |

SETUP EXPERIMENTAL

Estos datasets son divididos en training y testing aleatoriamente:

| | MovieRating | MovieLens |
|--|--------------------|------------------|
| Number of Training-set users | 200 | 343 |
| Number of Test-set users | 300 | 600 |
| Number of Initial ratings per test user | 3 | 3 |
| Number of Preserved ratings (evaluation) per test user | 20 | 20 |
| Total number of Preserved ratings (evaluation) over all test users | 6000 | 12000 |
| Number of Active Selection Candidates per test user | 977 | 1659 |
| Number of user-classes | 5 | 10 |

SETUP EXPERIMENTAL

- El Aspect Model es obtenido desde el dataset de training, generando el modelo global $p(r|m, z)$.
- El testing set entrega los usuarios nuevos a los que se les pedirán ratings, con estos se obtiene el modelo de usuario Θ_u considerando 3 ratings para simular que es un usuario nuevo. El resto de los items de estos usuarios se dividen en un conjunto de selección activa y uno de evaluación, este conjunto de selección activa corresponde a todos los items que no están ni en los items iniciales ni en el conjunto de evaluación.

Performance de CF

Para cada usuario del dataset de testing se calcula MAE y MSE individualmente:

$$\text{MAE}_u = \frac{1}{n(M_{ue})} \sum_{m \in M_{ue}} \left| r_m^{\text{true}} - r_m^{\text{predicted}} \right| \quad (8)$$

$$\text{MSE}_u = \frac{1}{n(M_{ue})} \sum_{m \in M_{ue}} \left(r_m^{\text{true}} - r_m^{\text{predicted}} \right)^2 \quad (9)$$

Se reporta el promedio de los usuarios del conjunto de testing U_t :

$$\text{MAE} = \frac{1}{n(U_t)} \sum_{u \in U_t} \text{MAE}_u \quad (10)$$

Failures

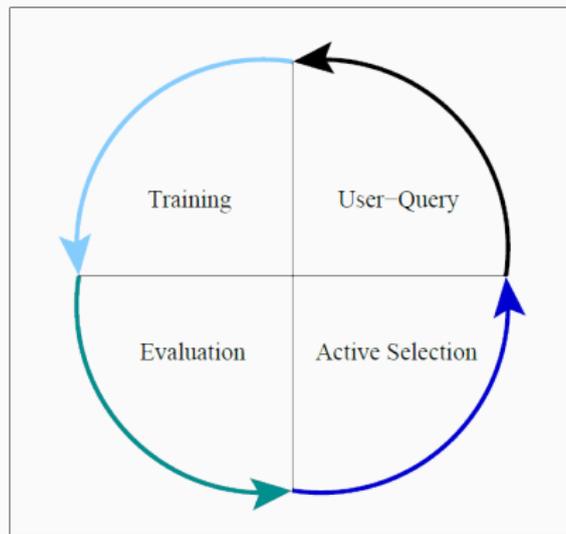
Los fallos (failures), son cuando el sistema solicita un rating al usuario y este no puede entregarlo.

Esto permite comparar el enfoque personalizado con los otros enfoques de Active Learning.

Para el experimento se consideró como failure cuando el sistema pide un rating que no se encuentra en el dataset. Con ello el sistema no puede ser re-entrenado y pierde un ciclo de Active Learning teniendo que pasar a la siguiente iteración.

- Se aprende modelo global a partir de usuarios del training set.
- El sistema aprende el modelo de usuario para un usuario del testing set, basado en sus ratings iniciales o el conjunto etiquetado y se predicen ratings para el set de evaluación.
- El sistema elige un item para ser evaluado del set de selección activa.
- Si el usuario entrega rating para ese item, este par item-rating es incorporado al conjunto etiquetado y se re-entrena el modelo. En caso contrario se registra como failure.

CICLO DE ACTIVE CF



Proceso de Active Learning

IMPLEMENTACIÓN ASPECT MODEL

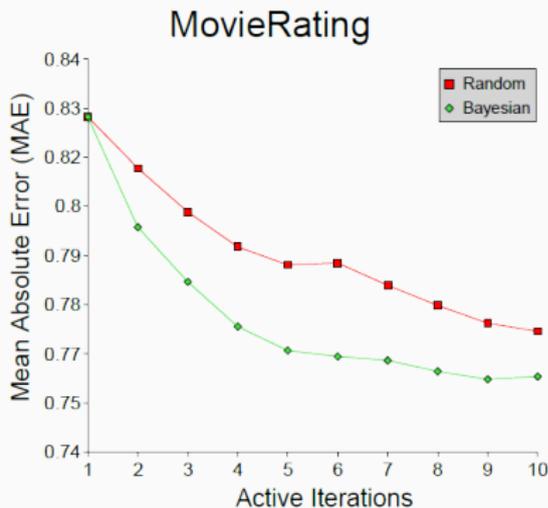
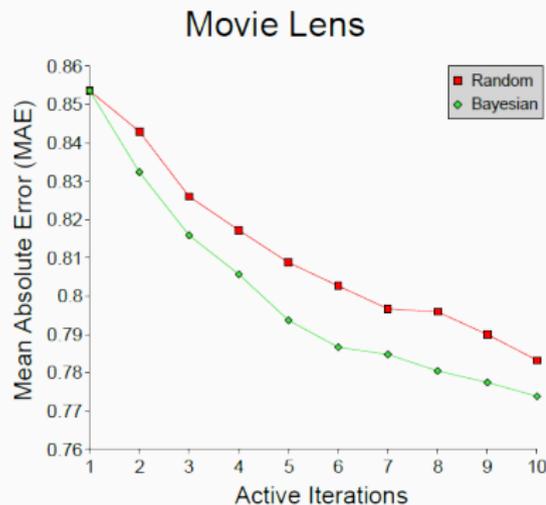
- $P(r|m, z)$ es modelado con una distribución gaussiana $N(r; \mu_{m,z}, \sigma_{m,z})$
- Para las proporciones de usuarios en cada grupo $P(z|u)$ se utiliza un modelo multinomial.
- Los ratings son normalizados por usuario, para tener media cero y varianza unitaria, esto se hace considerando los ratings disponibles en ese momento para cada usuario.

Se compara contra dos implementaciones para la selección de items para Active Learning:

- Aleatorio
- Bayesian Selection (BS)

Para la replicación de resultados se definió primero un setup *constrained*, que consiste en que la selección activa se realiza solo en el subconjunto de items con ratings disponibles, para satisfacer el supuesto de que el usuario puede evaluar cualquier item que se le pida.

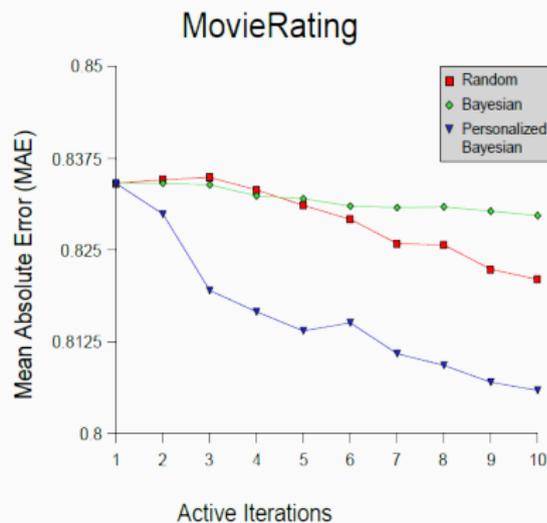
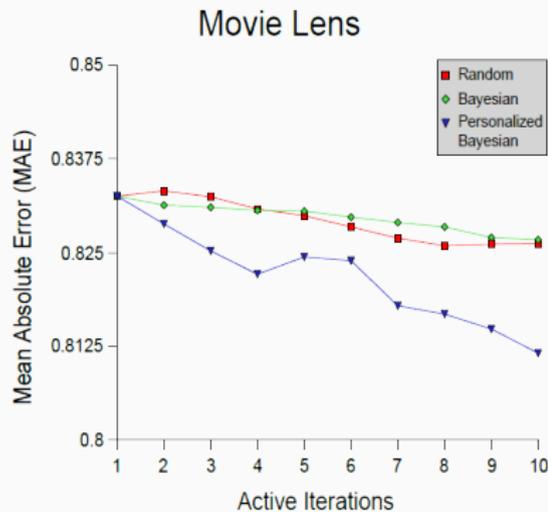
BASELINES DE COMPARACIÓN



Resultados en la implementación del baseline en setup constrained

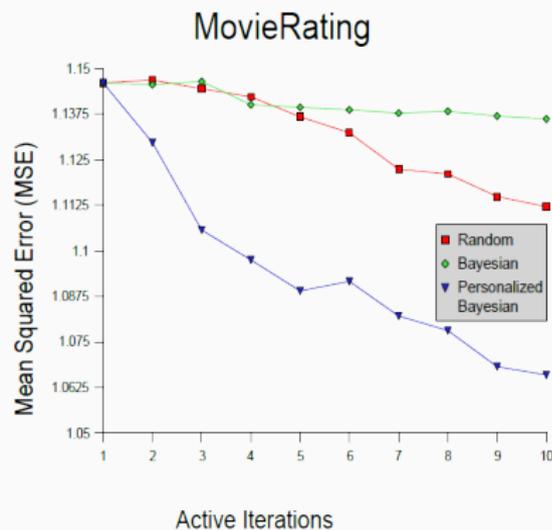
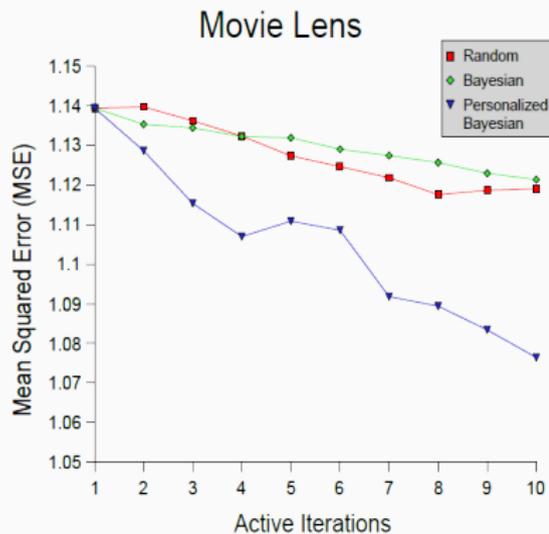
A este enfoque se le denomina Personalized Bayesian Selection (PBS) y para ser comparado con las implementaciones del baseline se define un setup *unconstrained*, que consiste en usar todos los items del dataset para solicitar ratings al usuario, de modo que también se puedan registrar los failures.

RESULTADOS



Resultados de MAE en la implementación del setup unconstrained

RESULTADOS



Resultados de MSE en la implementación del setup unconstrained

Numero medio de failures tras 10 iteraciones del ciclo de Active Learning:

| | MovieRating | MovieLens |
|-----|-------------|-----------|
| RS | 9.0728 | 9.3268 |
| BS | 9.8398 | 9.8366 |
| PBS | 5.995 | 5.1267 |

El término de personalización $P(m|u)$ incluido en el modelo se compone de dos elementos: el $P(z|u)$ que indica la pertenencia de usuarios a los grupos y el $P(m|z)$, que indica la probabilidad de obtener un rating del item en cierto grupo.

Si observamos los items con mayor $P(m|z)$ en cada grupo se pueden obtener clusters que reflejan intereses de ciertos grupos de usuarios, por ejemplo en el cluster A se tienen thrillers y en el cluster B se tienen principalmente películas de ciencia ficción.

ANALIZANDO PERSONALIZACIÓN

Cluster A

Dante's Peak

Contact

Scream

Air Force One

Murder at 1600

The Game

Conspiracy Theory

Titanic

I know what you did last summer

The Devil's own

Cluster B

Star Trek: First Contact

Return of Jedi

Scream

Courage under Fire

Contact

Mission Impossible

The Godfather

Star Trek: The wrath of Khan

The fifth element

Star Trek: Generations

CONCLUSIONES Y TRABAJO FUTURO

- Incorporación de Implicit Feedback, de forma que en caso de fallar obtener un rating, esto se pueda utilizar como información adicional para actualizar $P(z|u)$.
- Análisis de escalabilidad de técnicas de Active Learning para Collaborative Filtering, incluyendo el enfoque personalizado propuesto.

¿PREGUNTAS?