

Estudio del impacto de aplicar ensembles y ventanas temporales en la recomendación de POIs

Sergio Navarro Sánchez

Universidad Autónoma de Madrid

sergio.navarros@estudiante.uam.es

18 de septiembre de 2020



Contenido

- 1 Introducción
- 2 Estado del arte
- 3 Solución propuesta
- 4 Resultados
- 5 Trabajo futuro

Introducción



Introducción



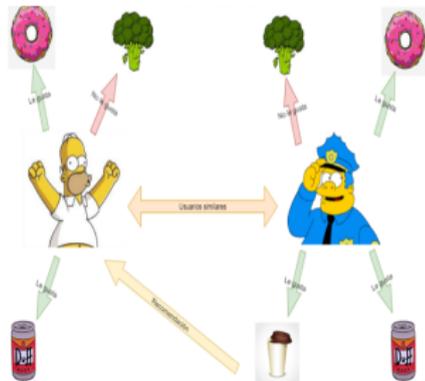
FOURSQUARE



Introducción



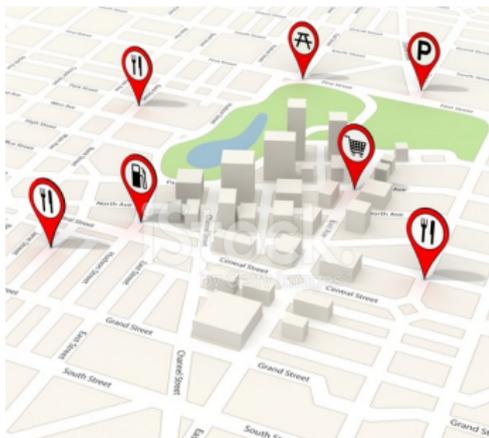
Sistemas de recomendación (SR)



Conjunto de algoritmos encargados de:

- Filtrar y analizar gran cantidad de datos.
- Realizar recomendaciones personalizadas, procesando los datos conocidos referentes a usuarios e ítems.

Puntos de interés (Point of interest)



- Comúnmente conocido como POI.
- Ítem = POI.
- Representa la localización de un lugar, por ejemplo, restaurantes, museos, playas, etc.
- En contexto de los SRs, debe ser útil o interesante para el usuario.

Problema a solucionar



- Poder generar recomendaciones satisfactorias en función de los datos conocidos sobre el propio usuario y similares a este.
- Intentar introducir técnicas novedosas y provechosas en el campo de la recomendación basada en el turismo.

Propuesta



FOURSQUARE



Gowalla



Redes sociales



Ventanas temporales

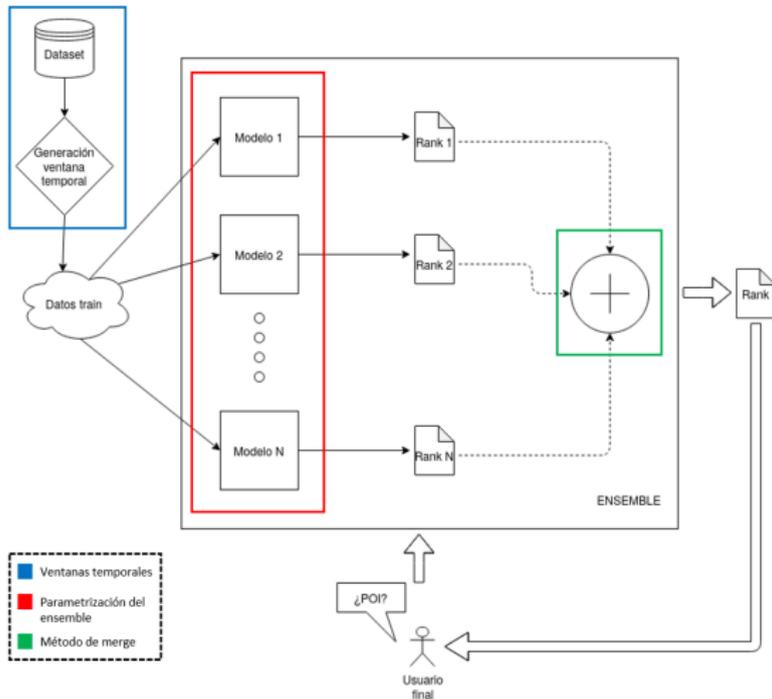


Ensembles



POI

Propuesta (diagrama alto nivel)



Estado del arte



Algoritmos de recomendación

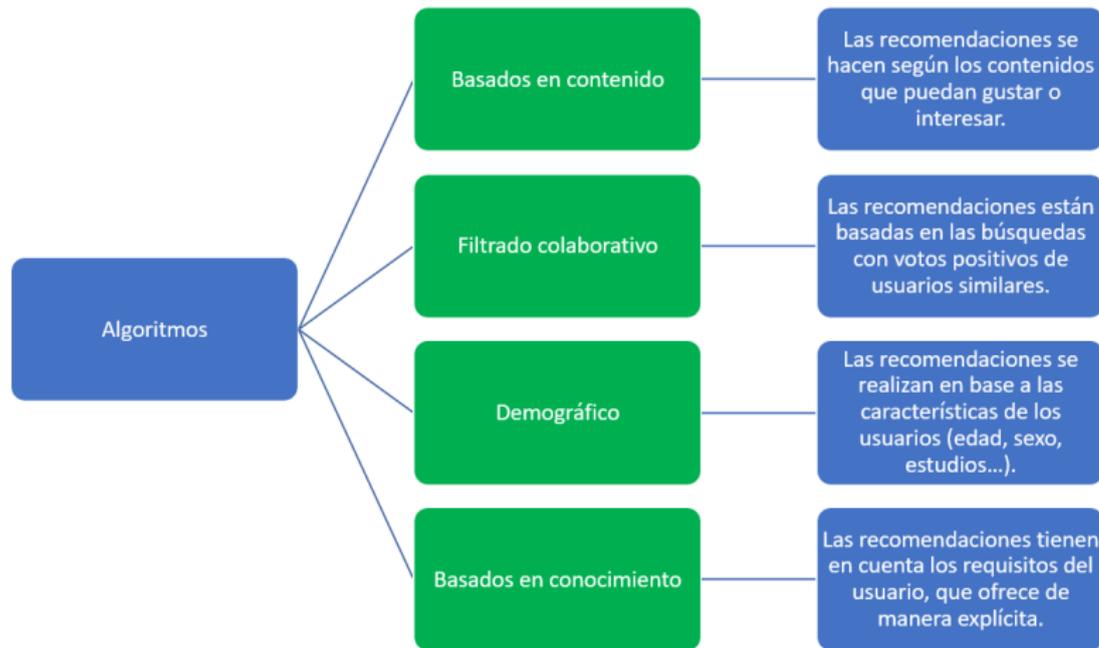


Figura: Tipos de algoritmos de recomendación más conocidos.

Algoritmos de recomendación empleados en el proyecto

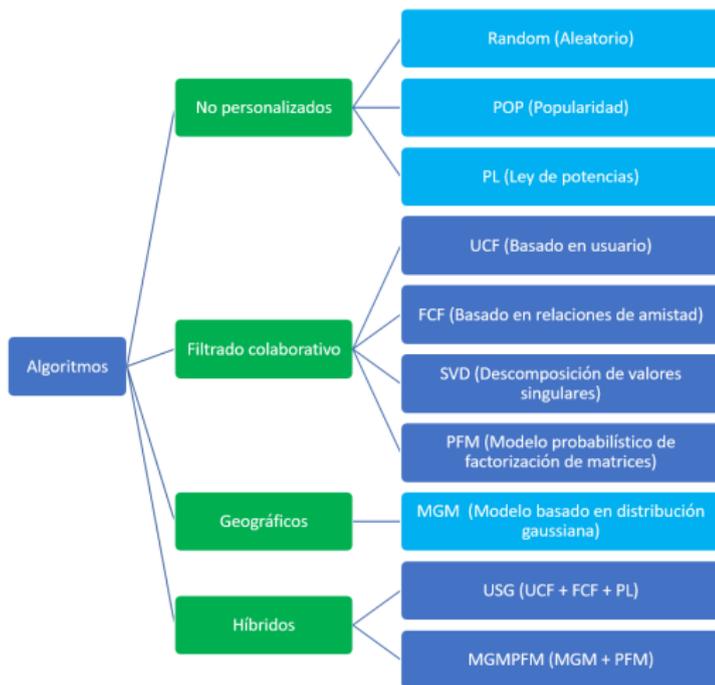


Figura: Algoritmos empleados.

Definición de ensemble

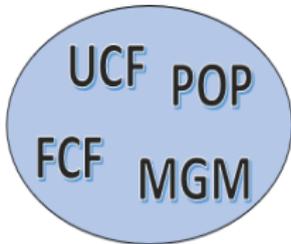


Figura: Ensemble

Ensemble

Se puede definir como un conjunto de modelos de machine learning donde cada modelo genera su propia predicción y cada una de éstas se combina para obtener una única predicción final. La principal ventaja que ofrece esta técnica es que la mayoría de las veces los errores individuales de los modelos tienden a compensarse, disminuyendo el error de generalización.

Tipos de ensemble

Tipo	¿Combinan modelos?	¿Emplean los mismos datos de entrenamiento?	Observación
Votación	✓	✓	La predicción final se forma a partir de las predicciones individuales de cada modelo.
Bagging	✗	✗	La predicción final se forma a partir de las predicciones individuales de cada modelo.
Boosting	✓	✗	Cada modelo intenta corregir el error de su antecesor dando mayor peso a las predicciones erradas.
Stacking	✓	✗	Se genera una pila de modelos, donde la salida de un modelo es la entrada de uno o más modelos.

Ensembles empleados en el proyecto

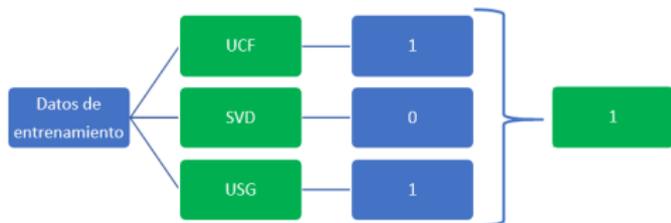


Figura: Ensemble votación.

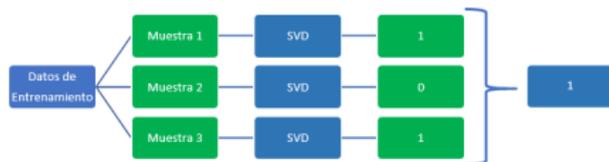


Figura: Ensemble bagging.

Trabajos actuales



- Recomendador musical.
- Recomendador de venta de productos online.
- Ventanas temporales.

Recomendador musical híbrido mediante el uso de ensembles



Figura: Sistema de recomendación musical

Ver: [Enlace 1](#)

- Se emplean ensembles de tipo bagging.
- El algoritmo empleado es filtrado colaborativo basado en ítem.
- Los resultados obtenidos son un 10 % peores que el algoritmo base.
- Los autores determinaron que *existe un grado de diversidad entre las recomendaciones sociales y las basada en contenido.*

El método de recomendación personalizada con combinación de conjuntos



Figura: Sistema de recomendación de venta online

Ver: [Enlace 2](#)

- Los conjuntos de datos pertenecen al ámbito de ventas online de productos.
- Emplean la técnica de ensemble votación.
- Los algoritmos empleados son: euclídeo, coseno y relación social, todos ellos pertenecientes a filtrado colaborativo.
- Los autores determinaron que *el rendimiento mejoró en torno a un 0.02 (precisión) y que la mejor implementación fue relación social.*

Predicción de la influencia social basada en el dominio consciente del tiempo



Figura: Red social
Twitter

Ver: [Enlace 3](#)

- Se emplean ventanas temporales y redes neuronales para determinar la fiabilidad de los usuarios de la red de Twitter y de la red social en conjunto.
- Las franjas temporales empleadas son semana, mes y año.
- Nos ha ofrecido un punto de partida para nuestra implementación de las ventanas temporales.

Conclusión



- Es un tema interesante.
- En general estas técnicas generan buenos resultados.
- No se han probado estas técnicas de manera conjunta en turismo.
- La idea es novedosa y tiene sentido realizarla.

Solución propuesta

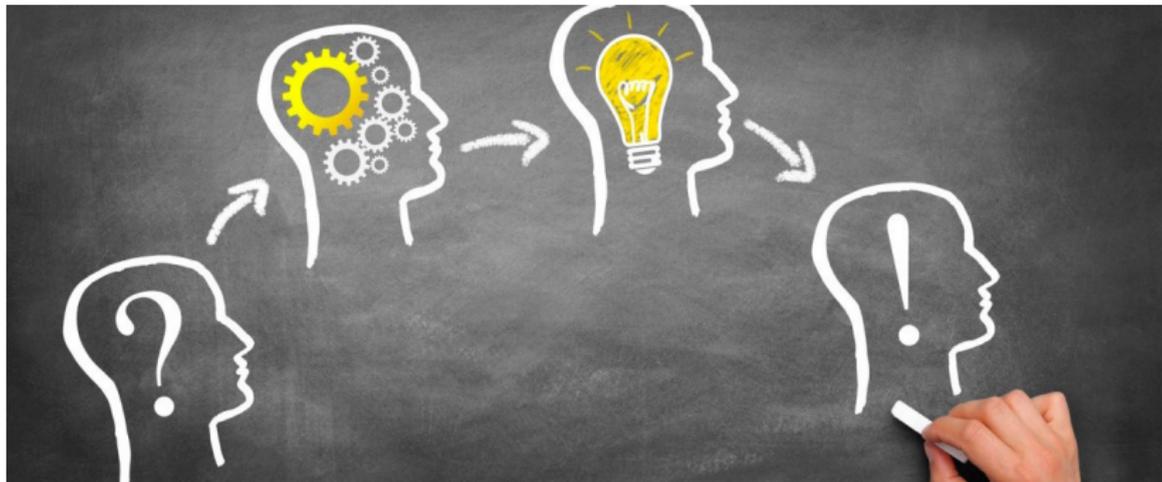
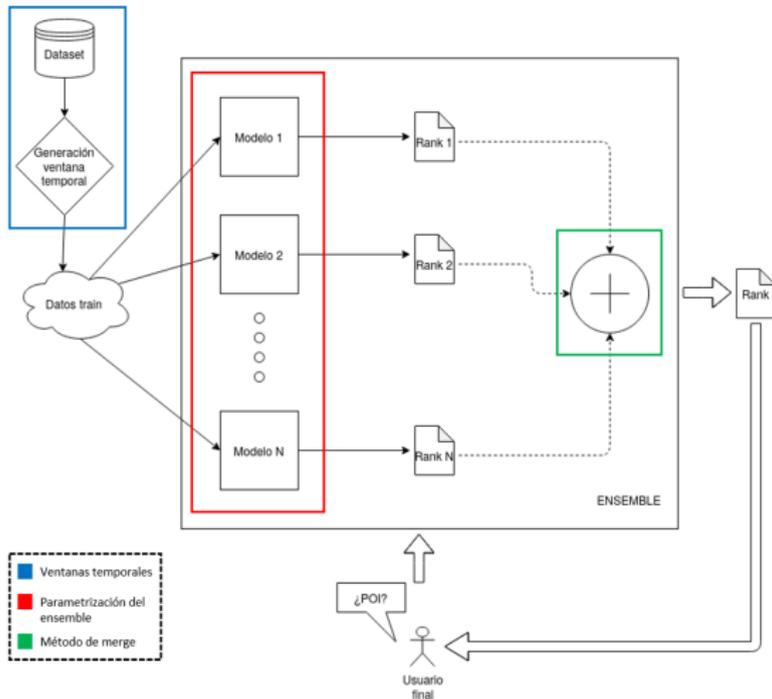


Diagrama de la solución propuesta



Definición de ventana temporal



Figura: Ventana temporal

Ventana temporal

Son subconjuntos de datos ordenados cronológicamente por fecha y hora de check-in definidos por una fecha de inicio y una de final.

Tipos de ventanas temporales empleadas

Estado nuevo

Los modelos se entrenan con el 30 % de los patrones de entrenamiento más actuales.

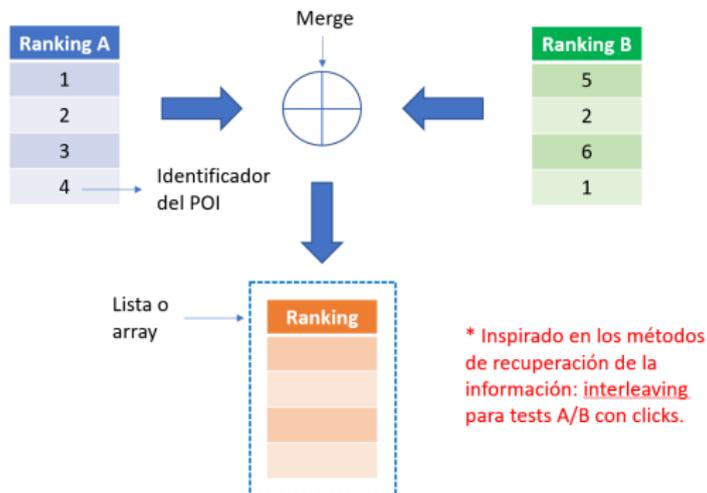
Estado avanzado

Los modelos se entrenan con el 60 % de los patrones de entrenamiento más actuales.

Estado final

Los modelos se entrenan con el 100 % de los patrones de entrenamiento más actuales.

Estrategias para combinar rankings



Estrategias para combinar rankings implementadas

- Aleatorio.
- Equilibrado.
- Ítems comunes.
- Popularidad.
- Por equipos.
- Por secuencia.

Aleatorio

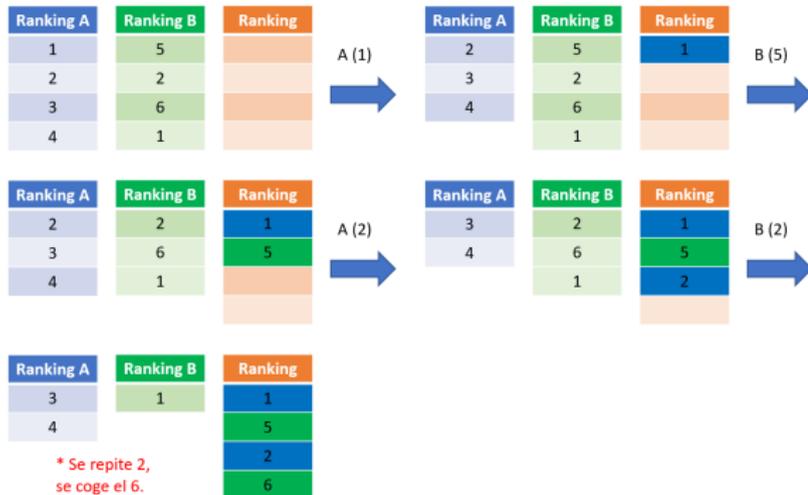


Aleatorio

Se genera un ranking aleatorio a partir de los rankings de entrada.

Equilibrado

Comienza: A



Equilibrado

Se retorna un ranking con el mismo número de POIs mejor posicionados de los rankings de entrada.

Ítems comunes



Ítems comunes

El ranking se genera en base a los ítems comunes de los rankings de entrada, en caso de empate se seleccionan de manera aleatoria.

Popularidad



Popularidad

El ranking se genera en base a los items más populares de los rankings de entrada, en caso de empate se seleccionan de manera aleatoria.

Por equipos

Patrón: BA

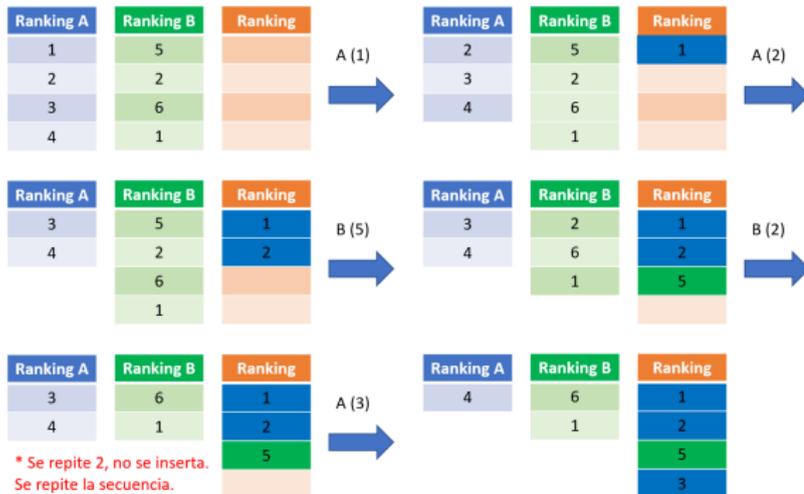


Por equipos

Se genera un patrón aleatorio con el id de los ranking de entrada y se van extrayendo POIs hasta que se alcance el tamaño del ranking de salida.

Por secuencia

Secuencia:
 AABB



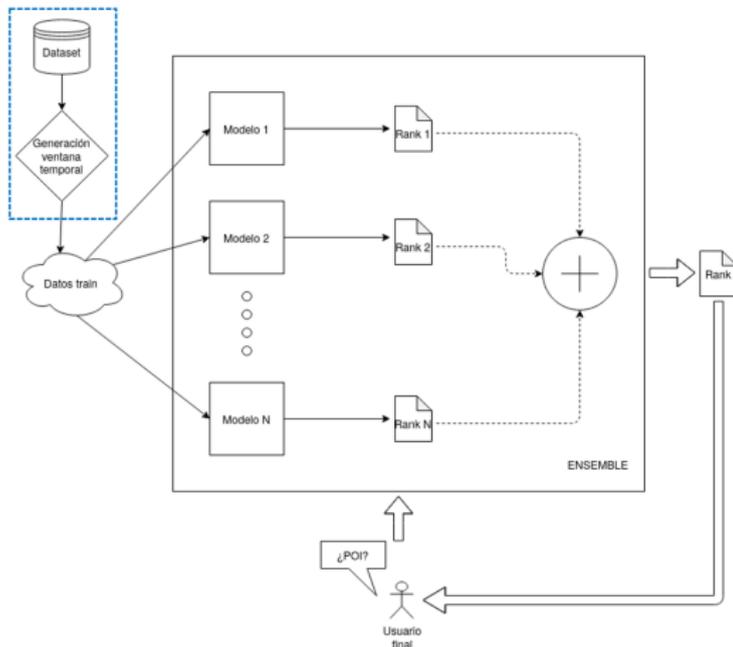
Por equipos

Se genera el ranking de salida en función al patrón de los ID de los rankings definido.

Funcionamiento conjunto



Diagrama de flujo I

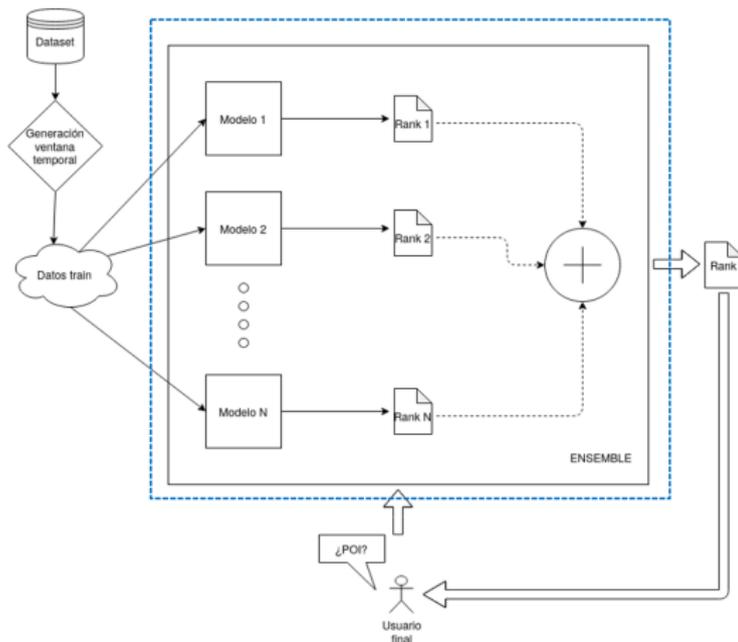


Fase 1:

Se genera la ventana temporal a partir de los datos de entrenamiento en función de la etapa que se quiera simular.

Figura: Diagrama de flujo, fase 1

Diagrama de flujo II



Fase 2:

Selección del tipo de ensemble a implementar.

Figura: Diagrama de flujo, fase 2

Diagrama de flujo III

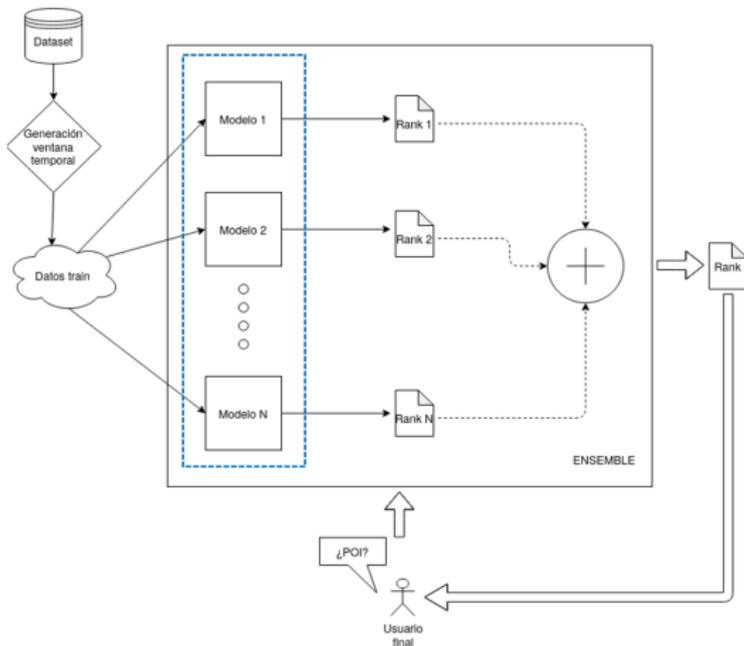


Figura: Diagrama de flujo, fase 3

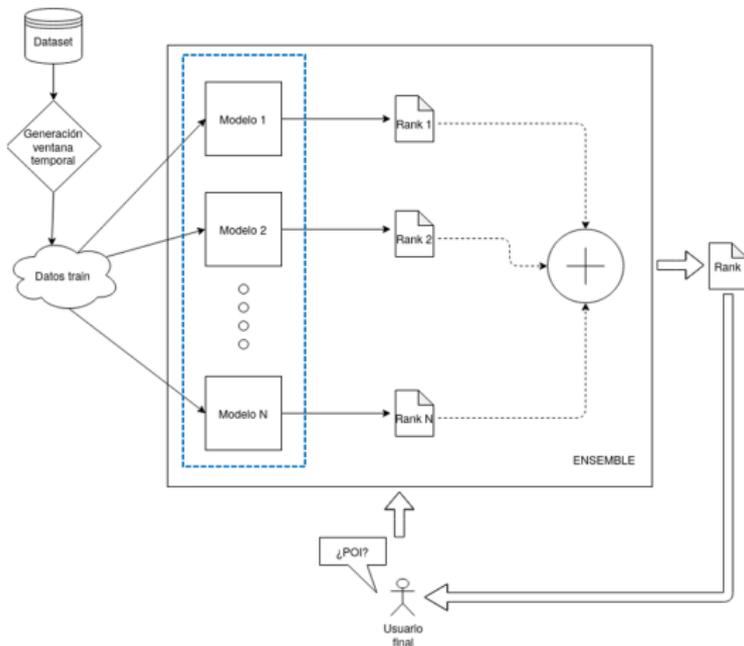
Fase 3.1:

Si empleamos ensemble votación, determinar el tamaño del ensemble y los modelos involucrados.

Fase 3.2:

Si utilizamos bagging, determinar el modelo involucrado y el número de particiones (se divide el conjunto de entrenamiento).

Diagrama de flujo IV

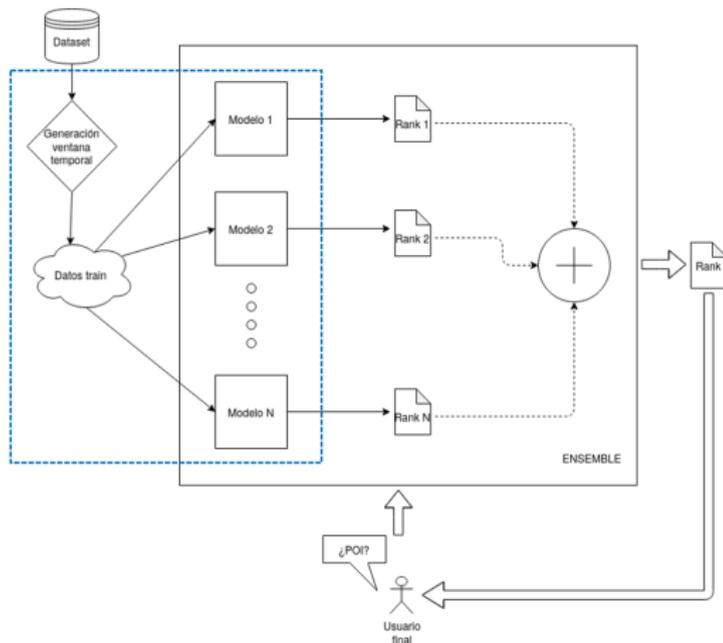


Fase 4:

Decidir el tamaño de las recomendaciones.

Figura: Diagrama de flujo, fase 4

Diagrama de flujo V

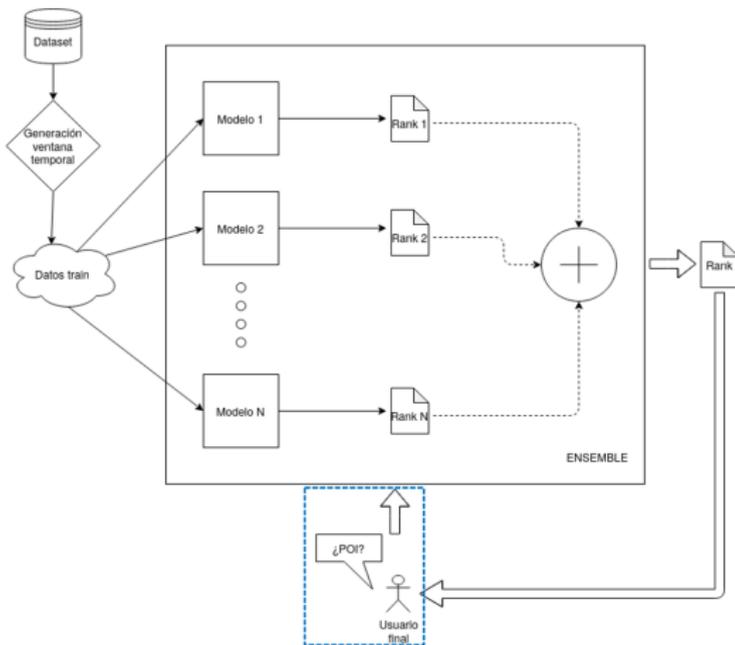


Fase 5:

Realizar el
entrenamiento de los
modelos.

Figura: Diagrama de flujo, fase 5

Diagrama de flujo VI

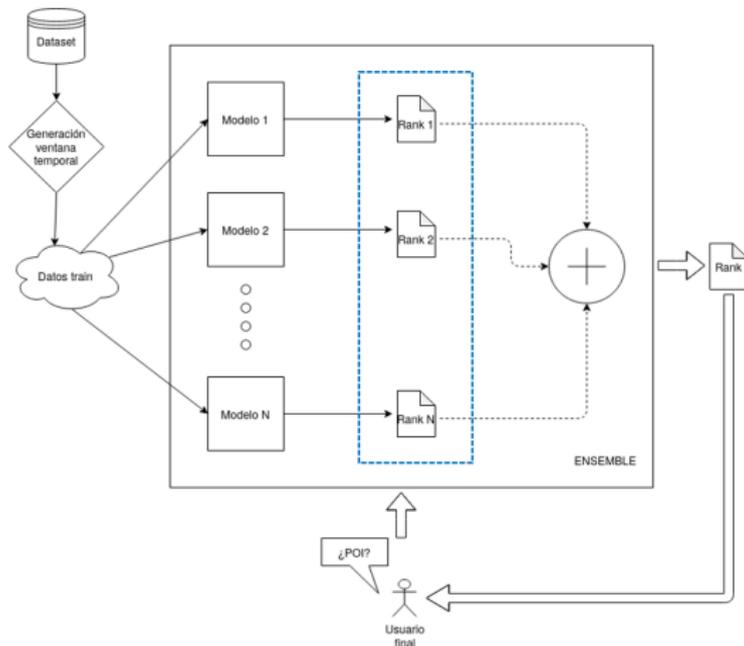


Fase 6:

Simulamos que un usuario realiza una solicitud.

Figura: Diagrama de flujo, fase 6

Diagrama de flujo VII

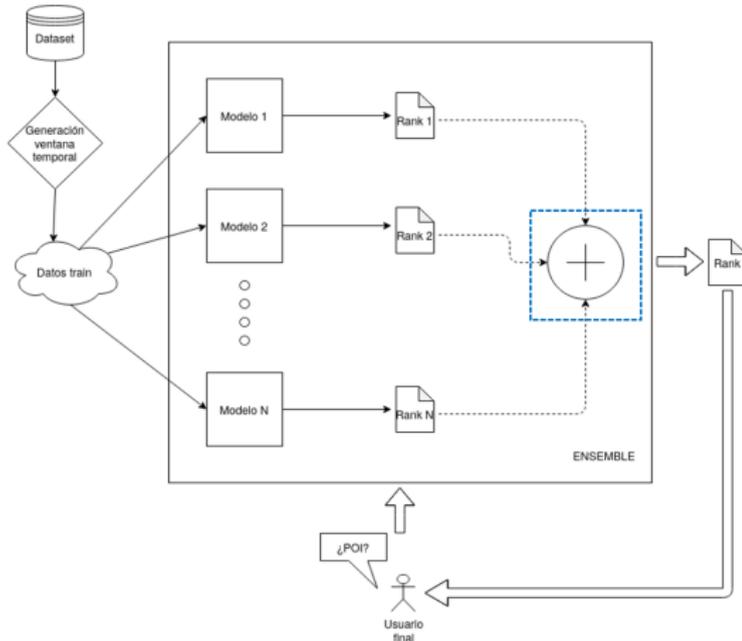


Fase 7:

Se generan los rankings individuales en función de la localización actual del usuario.

Figura: Diagrama de flujo, fase 7

Diagrama de flujo VIII

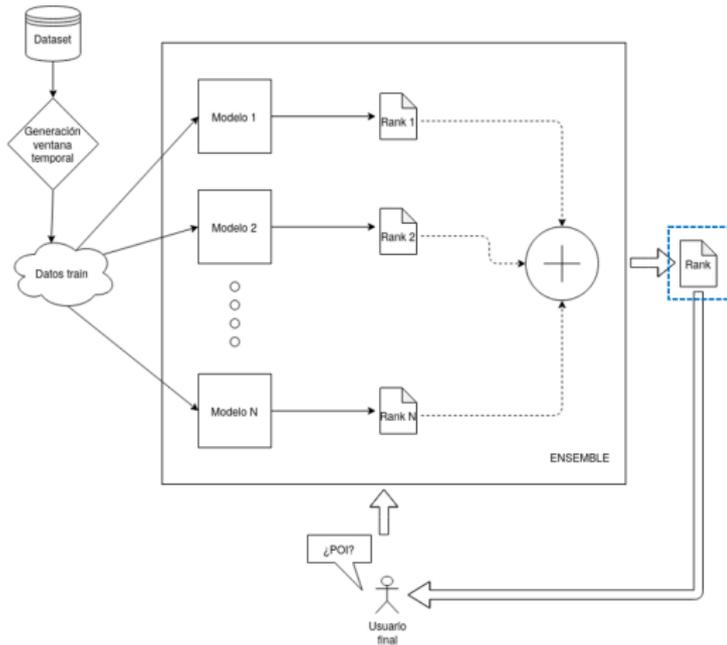


Fase 8:

Selección del método de merge.

Figura: Diagrama de flujo, fase 8

Diagrama de flujo IX

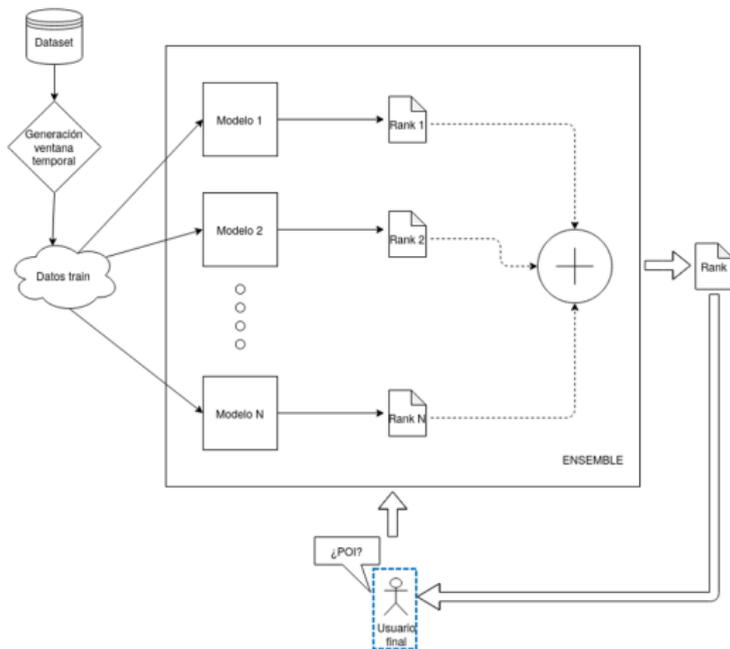


Fase 9:

Generación del ranking final.

Figura: Diagrama de flujo, fase 9

Diagrama de flujo X



Fase 10:

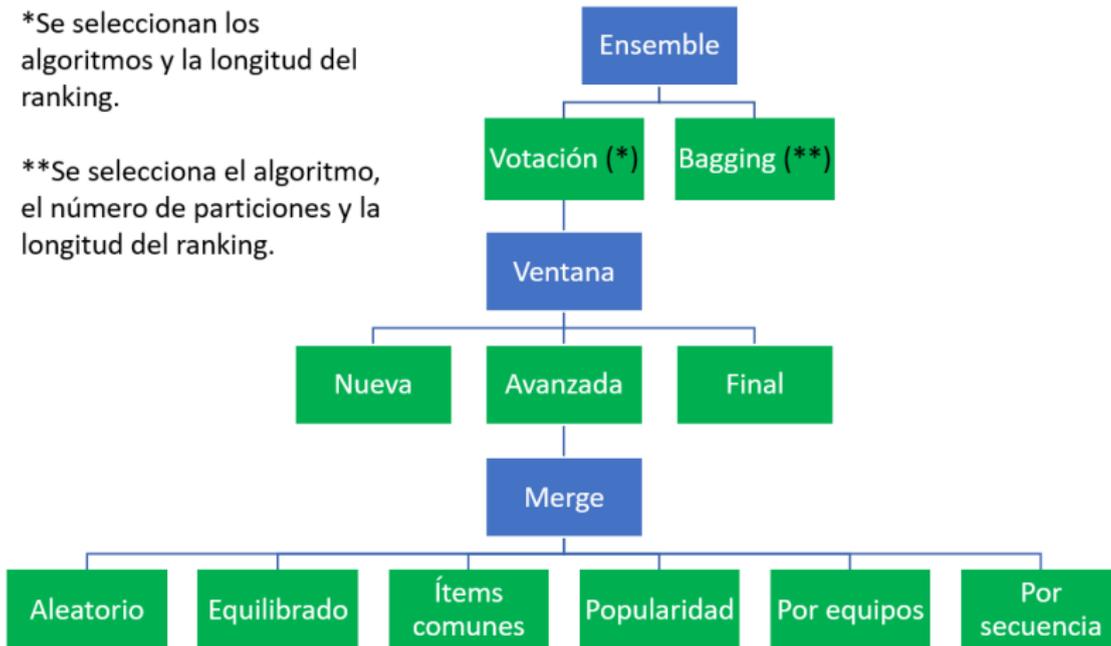
Evaluación del ranking, simulando que es un usuario.

Figura: Diagrama de flujo, fase 10

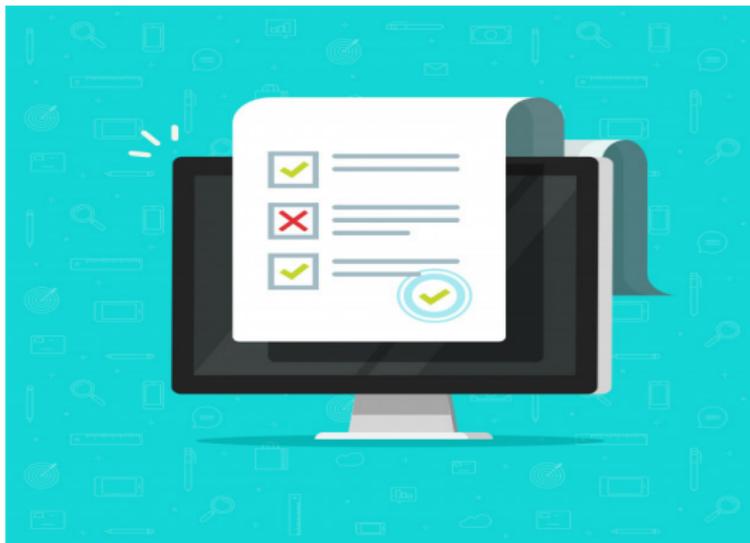
Resumen

*Se seleccionan los algoritmos y la longitud del ranking.

**Se selecciona el algoritmo, el número de particiones y la longitud del ranking.



Resultados



Descripción de los datasets

Plataforma	Usuarios	POIs	Check-ins	Relaciones sociales
Foursquare	24,941	28,593	1,196,248	50,429
Gowalla	25,379	32,623	1,395,856	118,717
Yelp	30,887	18,995	860,888	78,634

Cuadro: Tabla descripción de los conjuntos de datos.

Evaluación del rendimiento



Métricas de evaluación I

Precision@k

Precision

$$Precision@k = \frac{1}{|U|} \sum_{u \in U} \frac{|Rel_u@k|}{k} \quad (1)$$

Recall@k

Recall

$$Recall@k = \frac{1}{|U|} \sum_{u \in U} \frac{|Rel_u@k|}{|Rel_u|} \quad (2)$$

Métricas de evaluación II

mAP@k

Mean average precision

$$mAP@k = \frac{1}{|U|} \sum_u \frac{1}{|Rel_u|} \sum_{i \in Rel_u} P@rank(u, i) \quad (3)$$

nDCG

Normalized discounted cumulative gain

$$nDCG@k = \frac{DCG@k}{iDCG@k} \quad (4)$$

Baselines



Rendimiento individual de los algoritmos con el dataset de Foursquare

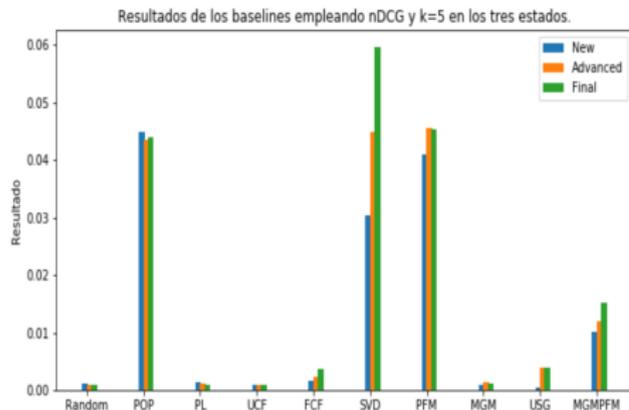


Figura: Comparación de los algoritmos.

Tras realizar la comparativa empleando nDCG como métrica y un recomendación de 5 POIs, se puede destacar:

- Los mejores algoritmos son SVD, PFM y POP en todas las ventanas.
- En promedio los mejores resultados se generan en la ventana final.
- El mejor rendimiento ha sido SVD en la ventana final con un 0.06 de rendimiento.

Rendimiento individual de los algoritmos con el dataset de Gowalla

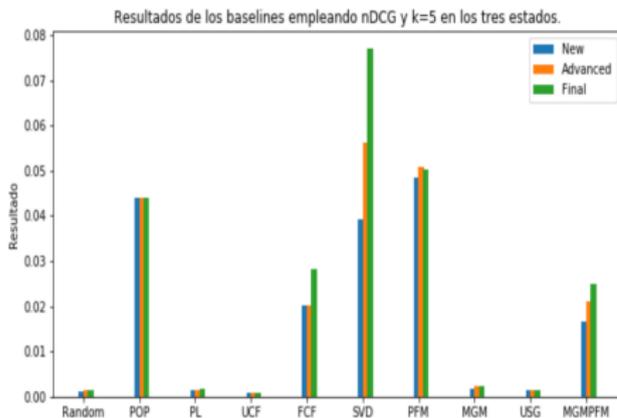


Figura: Comparación de los algoritmos.

Tras realizar la comparativa empleando nDCG como métrica y un recomendación de 5 POIs, se puede destacar:

- Los mejores algoritmos son SVD, PFM, POP, FCF y MGMPFM en todas las ventanas.
- En promedio los mejores resultados se generan en la ventana final.
- El mejor rendimiento ha sido SVD en la ventana final con un 0.08 de rendimiento.

Rendimiento individual de los algoritmos con el dataset de Yelp

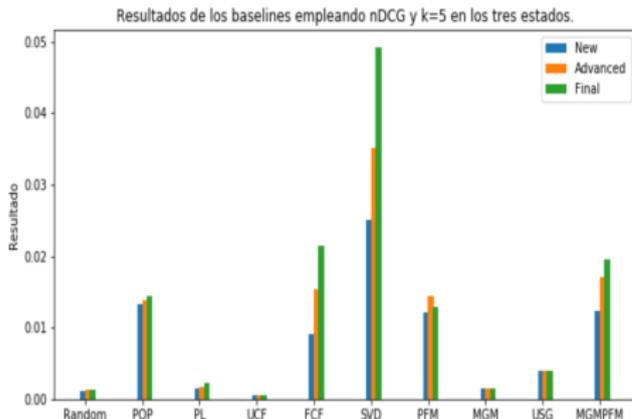
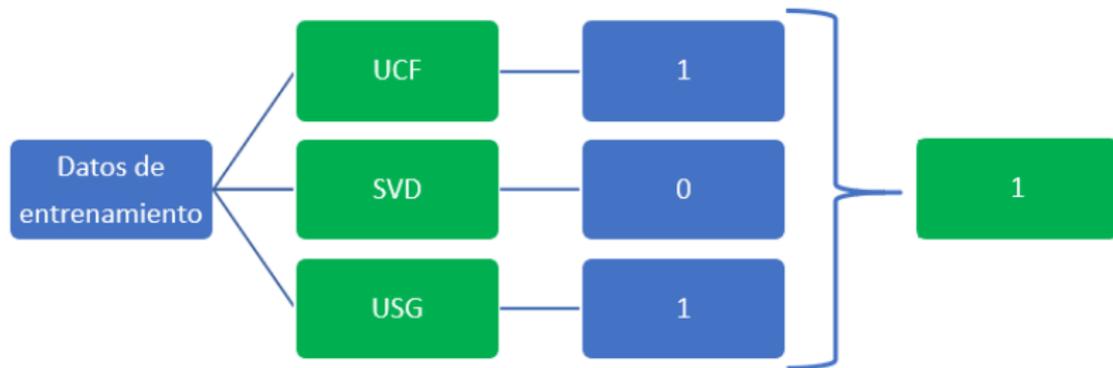


Figura: Comparación de los algoritmos.

Tras realizar la comparativa empleando nDCG como métrica y un recomendación de 5 POIs, se puede destacar:

- Los mejores algoritmos son SVD, FCF, MGMPFM, POP y PFM en todas las ventanas.
- En promedio los mejores resultados se generan en la ventana final.
- El mejor rendimiento ha sido SVD en la ventana final con un 0.05 de rendimiento.

Resultados de los ensembles tipo votación



Dataset de Foursquare (ventana nueva)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(POP, FCF)	5	Ítems comunes	0.0426	0.0265	0.0232	0.0450
(POP, MGMPFM)	5	Ítems comunes	0.0426	0.0265	0.0232	0.0450
(POP, MGMPFM, FCF)	5	Ítems comunes	0.0426	0.0265	0.0232	0.0450
POP (Baseline)	5	-	0.0426	0.0265	0.0232	0.0450
PFM (Baseline)	5	-	0.0434	0.0272	0.0207	0.0410
POP (Baseline)	10	-	0.0339	0.0426	0.0182	0.0384

- Las mejores combinaciones han obtenido los mismos resultados que el algoritmo POP.
- En esta ventana temporal no ha habido ninguna mejora.
- La estrategia de merge con mejores resultados ha sido la de ítems comunes.
- El tamaño de recomendación óptimo es 5.

Dataset de Gowalla (ventana avanzada)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(SVD, PFM, POP)	5	Por equipos	0.0433	0.0203	0.0260	0.0599
(SVD, PFM, POP)	5	Equilibrado	0.0428	0.0199	0.0250	0.0592
(SVD, PFM)	5	Por equipos	0.0546	0.0258	0.0293	0.0589
(SVD, PFM)	5	Equilibrado	0.0545	0.0255	0.0291	0.0589
(SVD, POP)	5	Equilibrado	0.0526	0.0247	0.0299	0.0586
SVD (Baseline)	5	-	0.0551	0.0279	0.0315	0.0563
PFM (Baseline)	5	-	0.0486	0.0199	0.0262	0.0508
POP (Baseline)	5	-	0.0425	0.0173	0.0257	0.0441

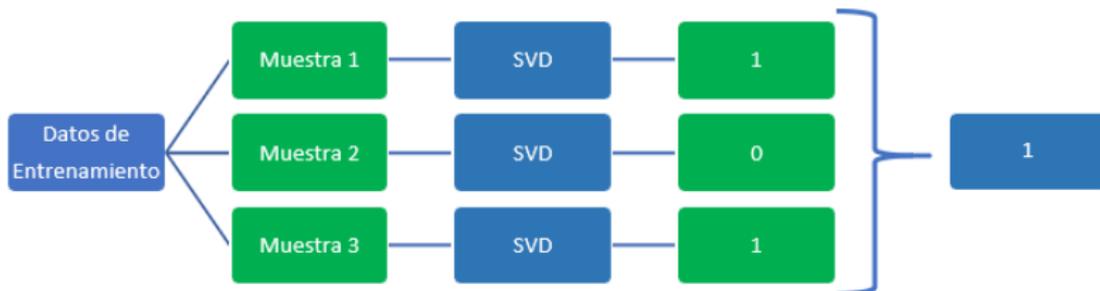
- Las mejor combinación ha sido (SVD, PFM, POP) con dos técnicas de merge distintas.
- No ha habido ninguna mejora aparente.
- Las estrategias de merge con mejores resultados han sido equilibrada y por equipos.
- El tamaño de recomendación óptimo es 5.

Dataset de Yelp (ventana final)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(SVD, PFM, MGMPFM)	5	Ítems comunes	0.0497	0.0258	0.0262	0.0526
(SVD, POP, FCF)	5	Ítems comunes	0.0510	0.0235	0.0271	0.0513
(SVD, FCF)	5	Ítems comunes	0.0482	0.0210	0.0260	0.0492
SVD (Baseline)	5	-	0.0482	0.0210	0.0260	0.0492
FCF (Baseline)	5	-	0.0213	0.0092	0.0121	0.0215
MGMPFM (Baseline)	5	-	0.0194	0.0096	0.0101	0.0196

- Las mejor combinación ha sido (SVD, PFM, MGMPFM).
- En esta ventana temporal no ha habido ninguna mejora aparente.
- La estrategia de merge con mejor resultado ha sido la de ítems comunes.
- El tamaño de recomendación óptimo es 5.

Resultados de los ensembles tipo bagging



Dataset de Foursquare (ventana nueva)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
SVD	4	5	Por equipos	0.0116	0.0052	0.0027	0.0123
FCF	4	5	Por equipos	0.0132	0.0102	0.0012	0.0107
POP	4	5	Ítems comunes	0.0072	0.0084	0.0007	0.0073
POP (Baseline)	-	5	-	0.0426	0.0265	0.0232	0.0450
PFM (Baseline)	-	5	-	0.0434	0.0272	0.0207	0.0411
POP (Baseline)	-	10	-	0.0339	0.0426	0.0182	0.0384

- El algoritmo con mejores resultados ha sido SVD.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline POP.
- Las estrategias de merge con mejores resultados han sido por equipos e ítems comunes.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Dataset de Gowalla (ventana avanzada)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
SVD	4	5	Equilibrado	0.0157	0.0148	0.0112	0.0179
PFM	4	5	Por equipos	0.0148	0.0138	0.0109	0.0166
POP	4	5	Equilibrado	0.0105	0.0087	0.0098	0.0130
SVD (Baseline)	-	5	-	0.0551	0.0279	0.0314	0.0563
PFM (Baseline)	-	5	-	0.0486	0.0198	0.0262	0.0508
POP (Baseline)	-	5	-	0.0425	0.0173	0.0257	0.0441

- El algoritmo con mejores resultados ha sido SVD.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline SVD.
- Las estrategias de merge con mejores resultados han sido equilibrado y por equipos.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Dataset de Yelp (ventana final)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
SVD	4	5	Ítems comunes	0.0289	0.0139	0.0140	0.0295
FCF	4	5	Ítems comunes	0.0169	0.0081	0.0089	0.0179
POP	4	5	Ítems comunes	0.0149	0.0073	0.0073	0.0146
SVD (Baseline)	-	5	-	0.0482	0.0210	0.0259	0.0491
FCF (Baseline)	-	5	-	0.0213	0.0092	0.0121	0.0214
MGMPFM (Baseline)	-	5	-	0.0194	0.0095	0.0101	0.0196

- El algoritmo con mejores resultados ha sido SVD.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline SVD.
- La estrategia de merge con mejores resultados ha sido ítems comunes.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Conclusión y discusión de los resultados

- El ensemble tipo votación es el que mejores resultados ha generado.
- Los algoritmos de filtrado colaborativo son los que mejor se adaptan a las técnicas de ensembles.
- Los mejores algoritmos en rendimiento general han sido SVD, PFM y POP.
- Las mejores técnicas de merge han sido por equipos, ítems comunes y equilibrada.
- La longitud óptima de recomendación es 5.
- Los datos con mayor calidad han sido los pertenecientes a Foursquare y Yelp.

Trabajo futuro



Trabajo futuro

- Repetir los experimentos de bagging empleando ventanas temporales para las particiones.
- Realizar los experimentos empleando ensembles de tipo boosting y stacking.
- Repetir los experimentos empleando algoritmos basados en redes neuronales.
- Emplear otro tipo de implementación para las ventanas temporales basadas en semanas, meses, etc.
- Transformar los datos a una secuencia temporal.
- Emplear datos procedentes de otros ámbitos.

GRACIAS!



Tipos de ensemble I

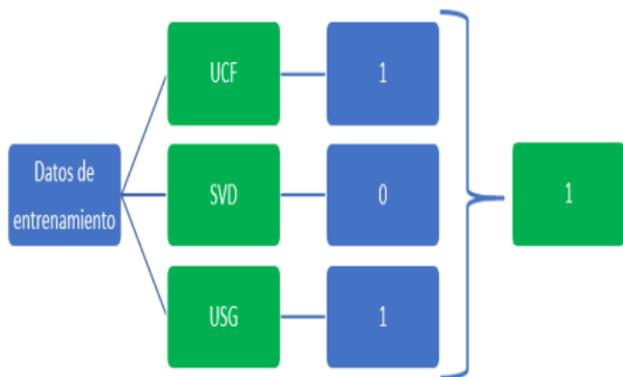


Figura: Ensemble votación.

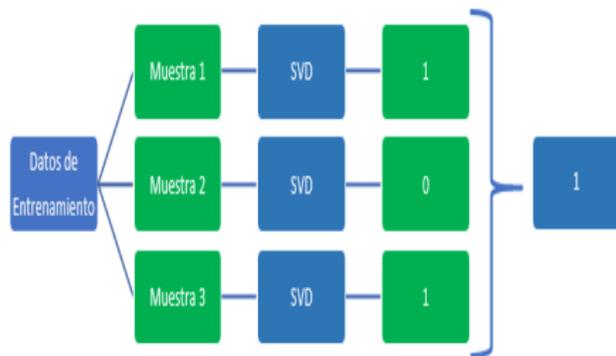


Figura: Ensemble bagging.

Tipos de ensemble II

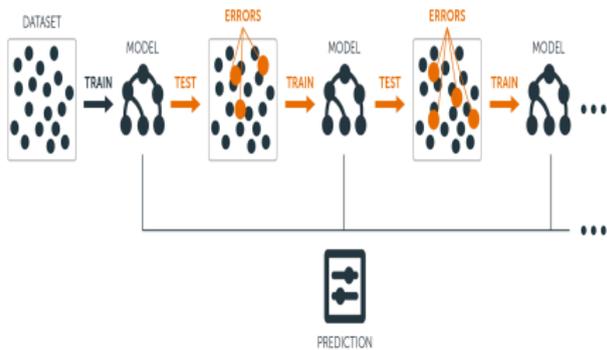


Figura: Ensemble boosting.

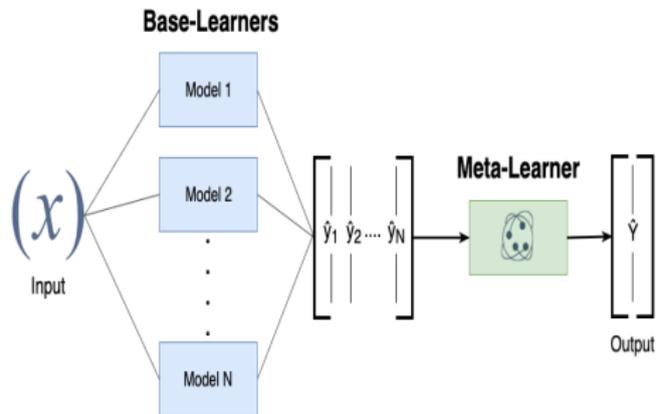


Figura: Ensemble stacking.

Baselines con el dataset de Foursquare

Algoritmo	Ventana	Tam. ranking	nDCG
POP	Nueva	5	0.0450
PFM	Nueva	5	0.0411
POP	Nueva	10	0.0384
PFM	Avanzada	5	0.0456
SVD	Avanzada	5	0.0449
POP	Avanzada	5	0.0436
SVD	Final	5	0.0596
PFM	Final	5	0.0453
POP	Final	5	0.0441

Cuadro: Resultados por ventanas de los mejores baselines

- Los mejores algoritmos son SVD, PFM y POP en todas las ventanas.
- Las ventanas nueva y avanzada han generado un rendimiento similar.
- El tamaño de recomendación óptimo es 5.
- El algoritmo SVD a medida que entrena con más datos genera mejores resultados.

Baselines con el dataset de Gowalla

Algoritmo	Ventana	Tam. ranking	nDCG
SVD	Nueva	5	0.0596
PFM	Nueva	5	0.0451
POP	Nueva	5	0.0410
SVD	Avanzada	5	0.0563
PFM	Avanzada	5	0.0508
POP	Avanzada	5	0.0441
SVD	Final	5	0.0770
PFM	Final	5	0.0503
POP	Final	5	0.0441

Cuadro: Resultados por ventanas de los baselines

- Los mejores algoritmos son SVD, PFM y POP en todas las ventanas.
- Las ventanas nueva y avanzada han generado un rendimiento similar.
- Los algoritmos PFM y POP en las ventanas avanzada y final tienen el mismo rendimiento.
- El tamaño de recomendación óptimo es 5.
- El algoritmo SVD en la ventana final ha tenido una mejora considerable.

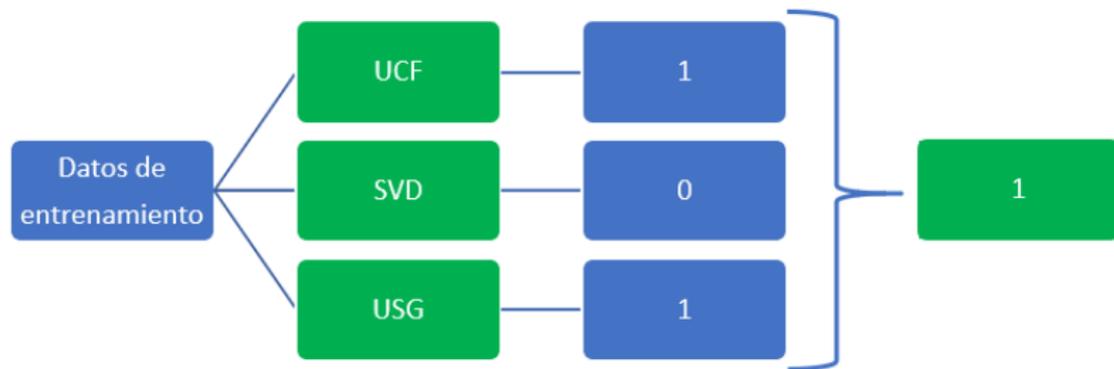
Baselines con el dataset de Yelp

Algoritmo	Ventana	Tam. ranking	nDCG
SVD	Nueva	5	0.0251
POP	Nueva	5	0.0133
MGMPFM	Nueva	5	0.0123
SVD	Avanzada	5	0.0351
MGMPFM	Avanzada	5	0.0171
FCF	Avanzada	5	0.0154
SVD	Final	5	0.0492
FCF	Final	5	0.0215
MGMPFM	Final	5	0.0196

Cuadro: Resultados por ventanas de los baselines

- Los mejores algoritmos son SVD, MGMPFM y FCF en todas las ventanas.
- Las ventanas nueva y avanzada han generado un rendimiento similar.
- El tamaño de recomendación óptimo es 5.
- El rendimiento del algoritmo SVD en la ventana final es el doble respecto a MGMPFM y FCF.

Resultados de los ensembles tipo votación



Dataset de Foursquare (ventana nueva)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(POP, FCF)	5	Ítems comunes	0.0426	0.0265	0.0232	0.0450
(POP, MGMPFM)	5	Ítems comunes	0.0426	0.0265	0.0232	0.0450
(POP, MGMPFM, FCF)	5	Ítems comunes	0.0426	0.0265	0.0232	0.0450
POP (Baseline)	5	-	0.0426	0.0265	0.0232	0.0450
PFM (Baseline)	5	-	0.0434	0.0272	0.0207	0.0410
POP (Baseline)	10	-	0.0339	0.0426	0.0182	0.0384

- Las mejores combinaciones han obtenido los mismos resultados que el algoritmo POP.
- En esta ventana temporal no ha habido ninguna mejora.
- La estrategia de merge con mejores resultados ha sido la de ítems comunes.
- El tamaño de recomendación óptimo es 5.

Dataset de Foursquare (ventana avanzada)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(SVD, POP)	5	Equilibrado	0.0509	0.0331	0.0281	0.0528
(SVD, POP)	5	Por equipos	0.0497	0.0326	0.0273	0.0522
(SVD, PFM, POP)	5	Por equipos	0.0484	0.0321	0.0253	0.0509
(SVD, PFM, POP)	5	Equilibrado	0.0480	0.0319	0.0259	0.0505
(SVD, PFM)	5	Equilibrado	0.0451	0.0306	0.0246	0.0485
PFM (Baseline)	5	-	0.0463	0.0297	0.0231	0.0456
SVD (Baseline)	5	-	0.0431	0.0295	0.0256	0.0449
POP (Baseline)	5	-	0.0419	0.0261	0.0238	0.0436

- Las mejores combinaciones que contienen a los algoritmos SVD y POP han obtenido los mejores resultados.
- El tamaño de recomendación óptimo es 5.
- La mejora generada por los conjuntos respecto a los baselines no ha sido aparente.
- Las estrategias de merge con mejores resultados han sido equilibrada y por equipos.

Dataset de Foursquare (ventana final)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(SVD, POP)	5	Equilibrado	0.0581	0.0382	0.0330	0.0615
(SVD, POP)	5	Por equipos	0.0578	0.0381	0.0330	0.0612
(SVD, PFM, POP, MGMPFM)	5	Ítems comunes	0.0587	0.0392	0.0360	0.0611
(SVD, PFM, POP, FCF)	5	Ítems comunes	0.0573	0.0398	0.0352	0.0606
SVD (Baseline)	5	-	0.0573	0.0398	0.0352	0.0596
PFM (Baseline)	5	-	0.0469	0.0300	0.0232	0.0453
POP (Baseline)	5	-	0.0426	0.0265	0.0240	0.0441

- Las mejor combinación ha sido (SVD, POP) con dos técnicas de merge distintas.
- En esta ventana temporal no ha habido ninguna mejora aparente.
- Las estrategias de merge con mejores resultados han sido la de equilibrada, por equipos e ítems comunes.
- El tamaño de recomendación óptimo es 5.

Dataset de Gowalla (ventana nueva)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(PFM, POP)	5	Equilibrado	0.0355	0.0147	0.0217	0.0518
(PFM, POP)	5	Por equipos	0.0357	0.0147	0.0222	0.0505
(SVD, PFM, POP)	5	Por equipos	0.0416	0.0184	0.0240	0.0499
(SVD, POP)	5	Equilibrado	0.0457	0.0203	0.0254	0.0488
SVD (Baseline)	5	-	0.0573	0.0398	0.0352	0.0596
PFM (Baseline)	5	-	0.0434	0.0272	0.0207	0.0451
POP (Baseline)	5	-	0.0426	0.0265	0.0232	0.0410

- Las mejor combinación ha sido (PFM, POP) con dos técnicas de merge distintas.
- En esta ventana temporal no ha habido ninguna mejora aparente.
- Las estrategias de merge con mejores resultados han sido la de equilibrada y por equipos.
- El tamaño de recomendación óptimo es 5.

Dataset de Gowalla (ventana avanzada)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(SVD, PFM, POP)	5	Por equipos	0.0433	0.0203	0.0260	0.0599
(SVD, PFM, POP)	5	Equilibrado	0.0428	0.0199	0.0250	0.0592
(SVD, PFM)	5	Por equipos	0.0546	0.0258	0.0293	0.0589
(SVD, PFM)	5	Equilibrado	0.0545	0.0255	0.0291	0.0589
(SVD, POP)	5	Equilibrado	0.0526	0.0247	0.0299	0.0586
SVD (Baseline)	5	-	0.0551	0.0279	0.0315	0.0563
PFM (Baseline)	5	-	0.0486	0.0199	0.0262	0.0508
POP (Baseline)	5	-	0.0425	0.0173	0.0257	0.0441

- Las mejor combinación ha sido (SVD, PFM, POP) con dos técnicas de merge distintas.
- En esta ventana temporal no ha habido ninguna mejora aparente.
- Las estrategias de merge con mejores resultados han sido equilibrada y por equipos.
- El tamaño de recomendación óptimo es 5.

Dataset de Gowalla (ventana final)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(PFM, POP)	5	Equilibrado	0.0355	0.0147	0.0217	0.0518
(SVD, PFM, POP)	5	Por equipos	0.0416	0.0184	0.0240	0.0499
(SVD, POP)	5	Equilibrado	0.0457	0.0203	0.0254	0.0488
SVD (Baseline)	5	-	0.0749	0.0376	0.0453	0.0770
PFM (Baseline)	5	-	0.0485	0.0202	0.0291	0.0503
POP (Baseline)	5	-	0.0425	0.0173	0.0257	0.0441

- Las mejor combinación ha sido (PFM, POP).
- En esta ventana temporal no ha habido ninguna mejora aparente.
- Las estrategias de merge con mejores resultados han sido la de equilibrada y por equipos.
- El tamaño de recomendación óptimo es 5.

Dataset de Yelp (ventana nueva)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(SVD, PFM, POP, FCF)	5	Ítems comunes	0.0289	0.0129	0.0210	0.0295
(SVD, MGMPFM, FCF)	5	Ítems comunes	0.0275	0.0119	0.0142	0.0284
(SVD, PFM, POP)	5	Ítems comunes	0.0269	0.0112	0.0139	0.0269
SVD (Baseline)	5	-	0.0247	0.0108	0.0122	0.0251
POP (Baseline)	5	-	0.0124	0.0054	0.0058	0.0133
MGMPFM (Baseline)	5	-	0.0126	0.0069	0.0065	0.0123

- La mejor combinación ha sido (SVD, PFM, POP, FCF) con dos técnicas de merge distintas.
- En esta ventana temporal no ha habido ninguna mejora aparente.
- La estrategia de merge con mejor resultado ha sido la de ítems comunes.
- El tamaño de recomendación óptimo es 5.

Dataset de Yelp (ventana avanzada)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(SVD, PFM, MGMPFM)	5	Ítems comunes	0.0395	0.0198	0.0202	0.0401
(SVD, PFM, POP)	5	Ítems comunes	0.0377	0.0176	0.0190	0.0380
(SVD, FCF)	5	Ítems comunes	0.0357	0.0171	0.0196	0.0363
SVD (Baseline)	5	-	0.0345	0.0155	0.0174	0.0351
MGMPFM (Baseline)	5	-	0.0169	0.0089	0.0086	0.0171
FCF (Baseline)	5	-	0.0150	0.0060	0.0079	0.0154

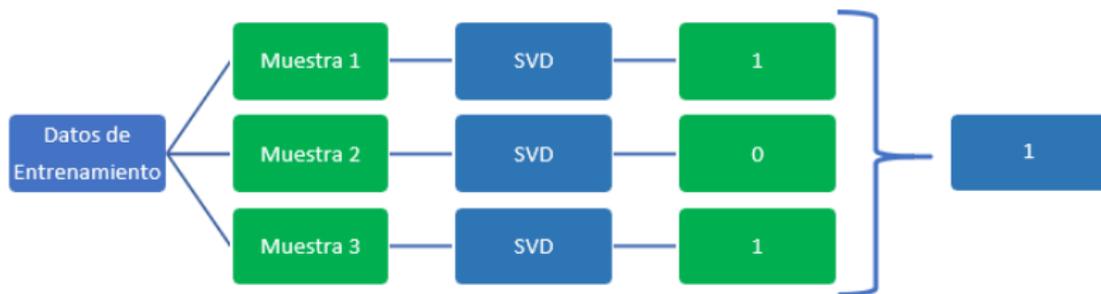
- Las mejor combinación ha sido (SVD,PFM, MGMPFM).
- En esta ventana temporal no ha habido ninguna mejora aparente.
- La estrategia de merge con mejor resultado ha sido la de ítems comunes.
- El tamaño de recomendación óptimo es 5.

Dataset de Yelp (ventana final)

Combinación	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
(SVD, PFM, MGMPFM)	5	Ítems comunes	0.0497	0.0258	0.0262	0.0526
(SVD, POP, FCF)	5	Ítems comunes	0.0510	0.0235	0.0271	0.0513
(SVD, FCF)	5	Ítems comunes	0.0482	0.0210	0.0260	0.0492
SVD (Baseline)	5	-	0.0482	0.0210	0.0260	0.0492
FCF (Baseline)	5	-	0.0213	0.0092	0.0121	0.0215
MGMPFM (Baseline)	5	-	0.0194	0.0096	0.0101	0.0196

- Las mejor combinación ha sido (SVD, PFM, MGMPFM).
- En esta ventana temporal no ha habido ninguna mejora aparente.
- La estrategia de merge con mejor resultado ha sido la de ítems comunes.
- El tamaño de recomendación óptimo es 5.

Resultados de los ensembles tipo bagging



Dataset de Foursquare (ventana nueva)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
SVD	4	5	Por equipos	0.0116	0.0052	0.0027	0.0123
FCF	4	5	Por equipos	0.0132	0.0102	0.0012	0.0107
POP	4	5	Ítems comunes	0.0072	0.0084	0.0007	0.0073
POP (Baseline)	-	5	-	0.0426	0.0265	0.0232	0.0450
PFM (Baseline)	-	5	-	0.0434	0.0272	0.0207	0.0411
POP (Baseline)	-	10	-	0.0339	0.0426	0.0182	0.0384

- El algoritmo con mejores resultados ha sido SVD.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline POP.
- Las estrategias de merge con mejores resultados han sido por equipos e ítems comunes.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Dataset de Foursquare (ventana avanzada)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
SVD	4	5	Por equipos	0.0123	0.0065	0.0030	0.0156
PFM	4	5	Por equipos	0.0238	0.0116	0.0026	0.0125
POP	4	5	Ítems comunes	0.0087	0.0097	0.0009	0.0074
PFM (Baseline)	-	5	-	0.0462	0.0297	0.0231	0.0456
SVD (Baseline)	-	5	-	0.0430	0.0294	0.0256	0.0449
POP (Baseline)	-	5	-	0.0418	0.0261	0.0238	0.0436

- El algoritmo con mejores resultados ha sido SVD.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline PFM.
- Las estrategias de merge con mejores resultados han sido por equipos e ítems comunes.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Dataset de Foursquare (ventana final)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
SVD	4	5	Por equipos	0.0281	0.0182	0.0129	0.0378
PFM	4	5	Por equipos	0.0237	0.0115	0.0125	0.0319
POP	4	5	Ítems comunes	0.0215	0.0097	0.0087	0.0307
SVD (Baseline)	-	5	-	0.0573	0.0397	0.0352	0.0596
PFM (Baseline)	-	5	-	0.0468	0.0300	0.0232	0.0453
POP (Baseline)	-	5	-	0.0425	0.0264	0.0240	0.0440

- El algoritmo con mejores resultados ha sido SVD.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline SVD.
- Las estrategias de merge con mejores resultados han sido por equipos e ítems comunes.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Dataset de Gowalla (ventana nueva)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
PFM	4	5	Equilibrado	0.0138	0.0119	0.0101	0.0130
POP	4	5	Por equipos	0.0104	0.0115	0.0094	0.0104
SVD	4	5	Equilibrado	0.0078	0.0049	0.0057	0.0085
SVD (Baseline)	-	5	-	0.0573	0.0397	0.0352	0.0596
PFM (Baseline)	-	5	-	0.0434	0.0272	0.0207	0.0450
POP (Baseline)	-	5	-	0.0425	0.0264	0.0232	0.0410

- El algoritmo con mejores resultados ha sido PFM.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline SVD.
- Las estrategias de merge con mejores resultados han sido equilibrado y por equipos.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Dataset de Gowalla (ventana avanzada)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
SVD	4	5	Equilibrado	0.0157	0.0148	0.0112	0.0179
PFM	4	5	Por equipos	0.0148	0.0138	0.0109	0.0166
POP	4	5	Equilibrado	0.0105	0.0087	0.0098	0.0130
SVD (Baseline)	-	5	-	0.0551	0.0279	0.0314	0.0563
PFM (Baseline)	-	5	-	0.0486	0.0198	0.0262	0.0508
POP (Baseline)	-	5	-	0.0425	0.0173	0.0257	0.0441

- El algoritmo con mejores resultados ha sido SVD.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline SVD.
- Las estrategias de merge con mejores resultados han sido equilibrado y por equipos.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Dataset de Gowalla (ventana final)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
SVD	4	5	Equilibrado	0.0265	0.0183	0.0133	0.0279
PFM	4	5	Por equipos	0.0239	0.0163	0.0124	0.0226
POP	4	5	Equilibrado	0.0163	0.0126	0.0106	0.0178
SVD (Baseline)	-	5	-	0.0749	0.0375	0.0452	0.0769
PFM (Baseline)	-	5	-	0.0484	0.0201	0.0291	0.0502
POP (Baseline)	-	5	-	0.0425	0.0173	0.0257	0.0441

- El algoritmo con mejores resultados ha sido SVD.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline SVD.
- Las estrategias de merge con mejores resultados han sido equilibrado y por equipos.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Dataset de Yelp (ventana nueva)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
POP	4	5	Ítems comunes	0.0088	0.0070	0.0064	0.0096
FCF	4	5	Ítems comunes	0.0075	0.0065	0.0062	0.0086
SVD	4	5	Ítems comunes	0.0072	0.0062	0.0059	0.0083
SVD (Baseline)	-	5	-	0.0247	0.0108	0.0121	0.0251
POP (Baseline)	-	5	-	0.0124	0.0054	0.0057	0.0132
MGMPFM (Baseline)	-	5	-	0.0126	0.0068	0.0064	0.0123

- El algoritmo con mejores resultados ha sido POP.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline SVD.
- La estrategia de merge con mejores resultados ha sido ítems comunes.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Dataset de Yelp (ventana avanzada)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
SVD	4	5	Ítems comunes	0.0175	0.0128	0.0114	0.0187
FCF	4	5	Ítems comunes	0.0128	0.0106	0.0099	0.0139
POP	4	5	Ítems comunes	0.0100	0.0106	0.0086	0.0117
SVD (Baseline)	-	5	-	0.0345	0.0154	0.0174	0.0351
MGMPFM (Baseline)	-	5	-	0.0169	0.0088	0.0086	0.0170
FCF (Baseline)	-	5	-	0.0150	0.0060	0.0078	0.0153

- El algoritmo con mejores resultados ha sido SVD.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline SVD.
- La estrategia de merge con mejores resultados ha sido ítems comunes.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.

Dataset de Yelp (ventana final)

Combinación	Particiones	Tam. ranking	Tipo de merge	Precision	Recall	mAP	nDCG
SVD	4	5	Ítems comunes	0.0289	0.0139	0.0140	0.0295
FCF	4	5	Ítems comunes	0.0169	0.0081	0.0089	0.0179
POP	4	5	Ítems comunes	0.0149	0.0073	0.0073	0.0146
SVD (Baseline)	-	5	-	0.0482	0.0210	0.0259	0.0491
FCF (Baseline)	-	5	-	0.0213	0.0092	0.0121	0.0214
MGMPFM (Baseline)	-	5	-	0.0194	0.0095	0.0101	0.0196

- El algoritmo con mejores resultados ha sido SVD.
- En esta ventana temporal el resultado ha sido peor en comparación con el baseline SVD.
- La estrategia de merge con mejores resultados ha sido ítems comunes.
- El tamaño de recomendación óptimo es 5 y el de particiones 4.