



Estudio y análisis del uso de redes siamesas en estrategias de recomendación basadas en contenido y de filtrado colaborativo

Nicolás Serrano



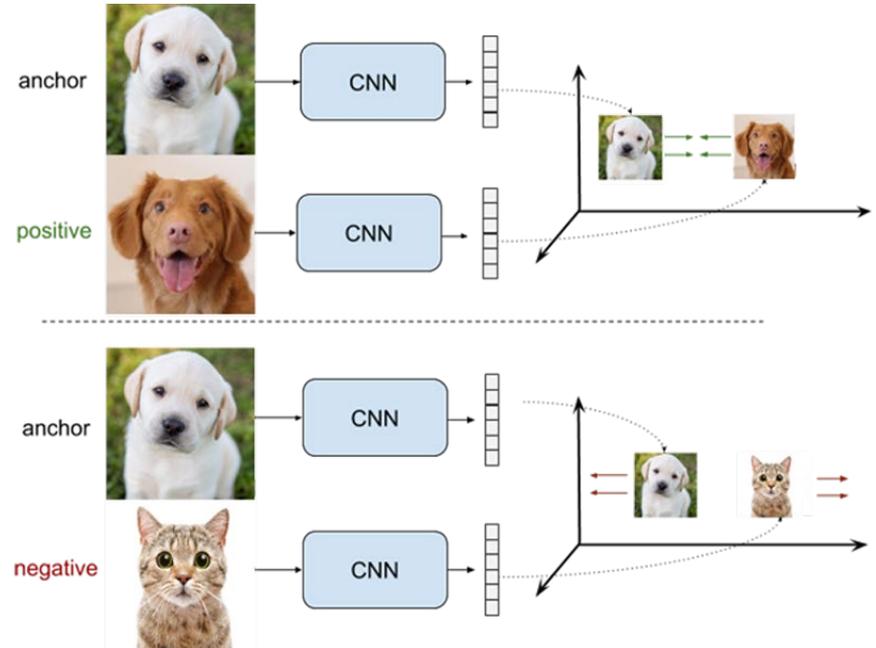
Índice

- Introducción
- Estado del arte
- Implementación
- Experimentos y resultados
- Conclusiones y trabajo futuro

Introducción

Motivación

- Las redes siamesas surgen para calcular la similitud entre dos elementos. Últimamente, se utilizan sobre todo en multimedia.
- La similitud es una pieza clave en los sistemas de recomendación.





Propuesta

1. Conocer el estado del arte de las redes siamesas para recomendación.
2. Plantear modelos de recomendación basados en redes siamesas.
 - Basado en contenido.
 - Filtrado colaborativo.
3. Evaluar los modelos estudiados.

Estado del arte

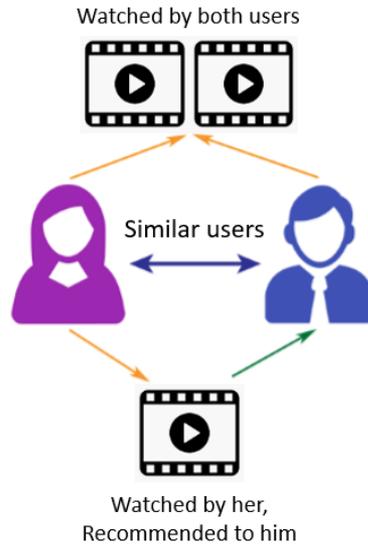


Sistemas de Recomendación

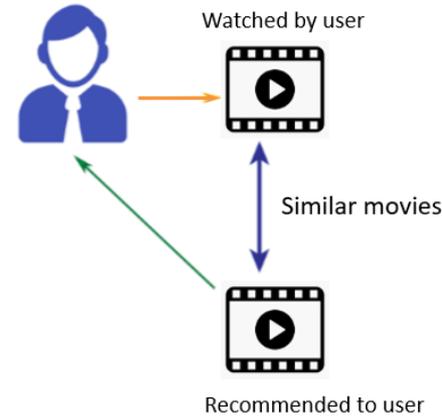
- Herramienta que proporciona una sugerencia de artículo a un usuario.
- Artículo / Ítem: Lo que es sugerido.
- Usuario: Sujeto de la recomendación.
- Tres tipos de puntuación: escalar (numérica y ordinal), binaria y unaria.
- Las recomendaciones se tienden a mostrar como un ranking de los artículos.

Sistemas de Recomendación

Collaborative Filtering



Content-Based Filtering





Basado en Contenido

- Aprende a recomendar artículos similares a los que al usuario le han gustado en un pasado.
- Las recomendaciones se crean considerando un perfil creado para el usuario, teniendo en cuenta las características de los artículos que le han gustado al mismo.

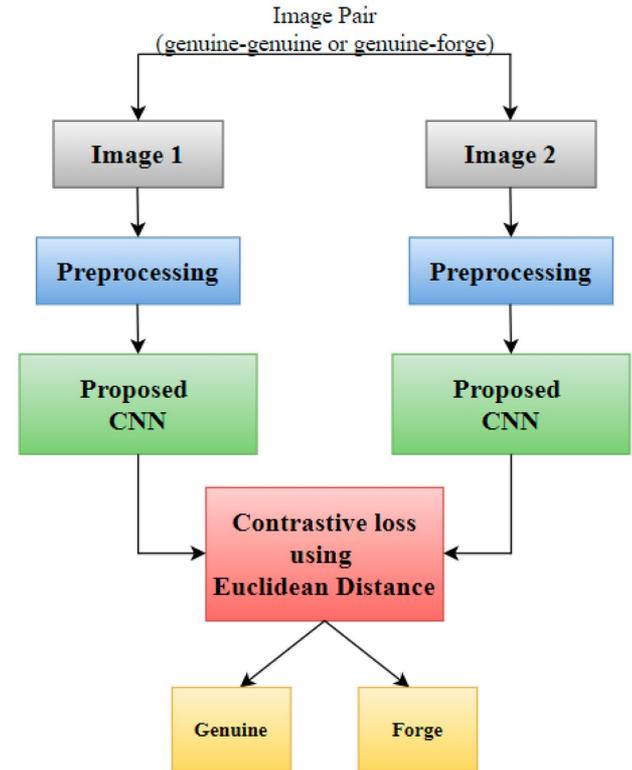


Filtrado Colaborativo

- Aprende a recomendar al usuario artículos en base a cómo se comportan el resto de usuarios en el sistema:
 - Buscando usuarios o artículos similares (vecindarios).
 - Construyendo modelos predictivos (SVD, redes neuronales, ...)

Redes Siamesas

- Surgen en 1993 para la verificación de firma manuscrita.
- Arquitectura de red neuronal compuesta por varias redes feedforward idénticas (arquitectura y pesos), unidas en la salida.
- Cada red procesa uno de los elementos y compara las salidas mediante una métrica de distancia, determinando su similitud.



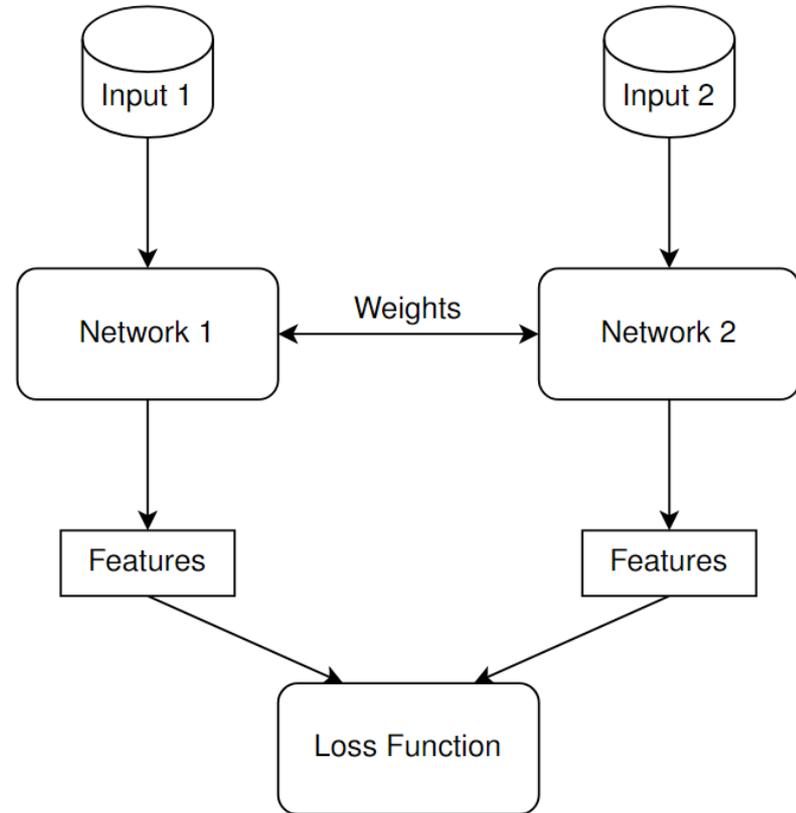


Parejas

- Son las primeras propuestas en 1993. También se las conoce como Twin Neural Network (gemelas).
- Se emparejan pares de elementos y se aprende su similitud mediante una función de pérdida.



Parejas



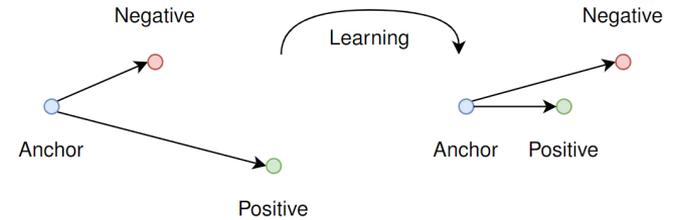


Parejas

- Entropía binaria cruzada (BCE) determina si dos elementos son de la misma clase o de distintas clases.
- Contrastive Loss, que debería adaptarse mejor a este problema, pues el objetivo es diferencias y no clasificar entre dos elementos.

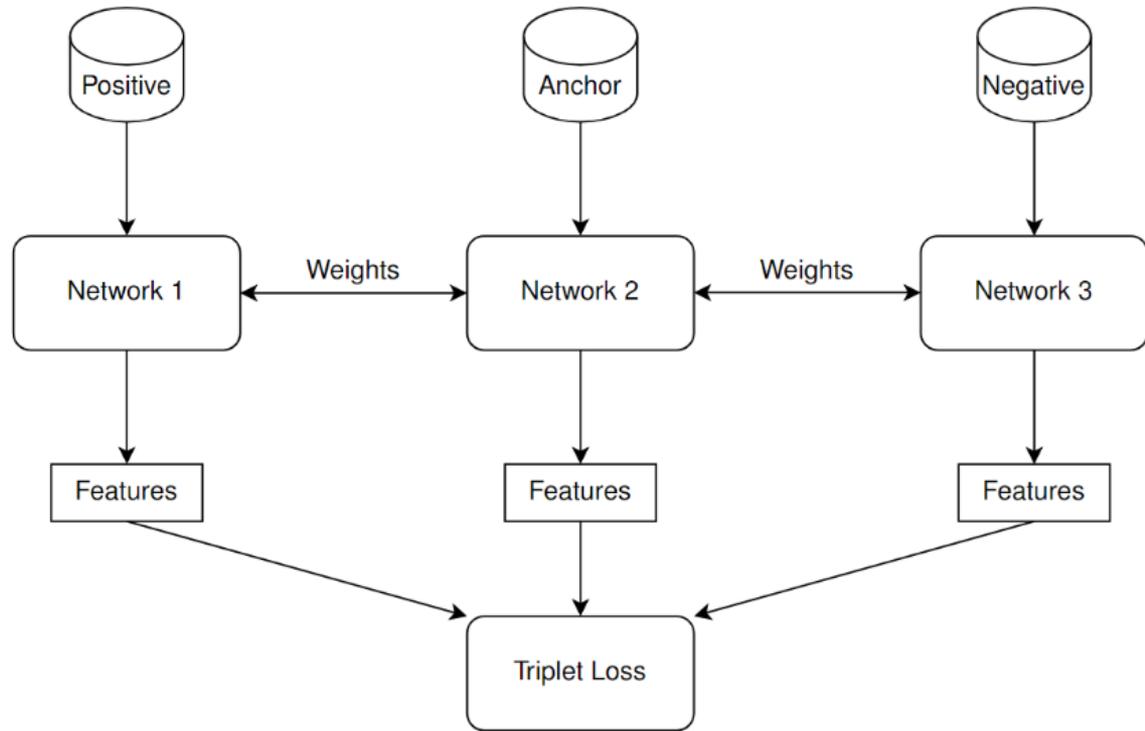


Tripletas



- Propuestas en 2015. También se las conoce como Triplet Networks.
- En vez de parejas, se tienen tres elementos (A, P, N).
 - Ancla (A): elemento a comparar o usuario.
 - Positivo (P): elemento de la misma clase que el ancla.
 - Negativo (N): elemento de una clase distinta al ancla.
- Función de pérdida: Triplet Loss.

Tripletas





Integración Recomendación + SNN

- Coexisten desde los 90, pero no existen integración hasta 2018.
- Diferentes aproximaciones para diferentes problemas.
- Análisis de la literatura para aprender y entender los métodos concretos.



Metodología

- Consultas generalistas en Web of Science y Scopus.
- 55 artículos → 24 artículos
- Eliminación de duplicados, consulta ambigua.
- Clasificación de la literatura (*survey*).
- Novedoso (enviado a revista).
 - Neural Computing and Applications

```
(  
TITLE-ABS-KEY("recommender systems") OR  
TITLE-ABS-KEY("recommendation system") OR  
TITLE-ABS-KEY("recommendation")  
)  
AND  
(  
TITLE-ABS-KEY("siamese network") OR  
TITLE-ABS-KEY("siamese neural network") OR  
TITLE-ABS-KEY("twin neural network")  
)
```



Tareas de recomendación

Dominio	Artículos	Texto	Audio	Imágenes	Vídeos
Búsqueda de Trabajo	[9, 14]	X			
Comercio Electrónico	[10, 15, 16]	X			
Moda	[7, 8, 17, 18]	X		X	
Música	[19, 20]		X		
Noticias	[11]	X			
Películas	[10, 21, 22]				
Turismo	[22, 23]				
Otros	[24–32]			X	X



Enfoque algorítmico

- Hemos dividido los artículos de la bibliografía en cuatro categorías.
 - Uso de la red en el problema.
 - N° de parámetros de entrada.
 - Función de pérdida.
 - Red feedforward utilizada en la red siamesa.



Uso de la red

	Extracción de características	Predicción
<i>Feedforward</i>	[14, 18, 22, 24, 26, 31, 32]	
Clusterización	[16, 20, 23, 27]	[8–11, 15, 19, 21, 28–30]
Aprendizaje de clasificación	[7, 17, 25]	



Parámetros de entrada

- Parejas (I_1, I_2).
- Tripletas (A, P, N).
- Otro (A, P, N_1, N_2, \dots, N_n).

¡HAY ARTÍCULOS QUE LLAMAN TRIPLETAS A PAREJAS ETIQUETADAS!



Función de pérdida

- Entropía Binaria Cruzada (3 artículos).
- Contrastive Loss (7 artículos).
- Triplet Loss (1 artículo).
- Personalizadas (3 artículos).
- Otras (4 artículos).
- Desconocida (6 artículos).



Red feedforward

<i>Red feedforward</i>	Artículos
Perceptrón multicapa	[21, 24, 25, 28, 29, 31]
Red convolucional	[7–9, 14, 16–20, 26, 27, 32]
Red recurrente	[10, 11, 14–16, 22, 23]
Transformer	[30]

Ajustes de evaluación

- Comparar diferentes aproximaciones detectando cuál es el mejor algoritmo.
- Técnicas Online.
- Técnicas Offline: Recall@K, Precision@K, AUC, F1, NDCG

Artículo	Métrica de evaluación
Año 2018	
[7]	AUC
[8]	Mean Recall@K
[9]	Accuracy, Precision, Recall, F1
[10]	Recall@K, MRR
[11]	HR@K, NDCG@K
Año 2019	
[17]	AUC
[18]	Lift@K
[21]	Precision, Recall, F1, BPREF, LTC, WLTC, TTC
[29]	AUC, ERR, RD, FPR, TPR, FNR
[32]	Recall, Betrayal Rate
Año 2020	
[14]	Accuracy
[19]	Precision, AUC
[22]	Precision
[23]	Accuracy@K, macro-F1
[25]	HR, NDCG
[26]	Precision, Recall, F1, ROC
[27]	Accuracy
Año 2021	
[15]	Precision, Recall, A/B Test
[16]	Accuracy, AUC
[20]	Accuracy, Satisfacción de Usuario
Año 2022	
[24]	AUC, NDCG, MMR, PR-AUC
[28]	Precision, Recall, HR and Average Reciprocal HR
[30]	Precision, Recall, F1, MRR, MAP
[31]	Accuracy@K, Precision@K, Recall@K, F1@K, ROC

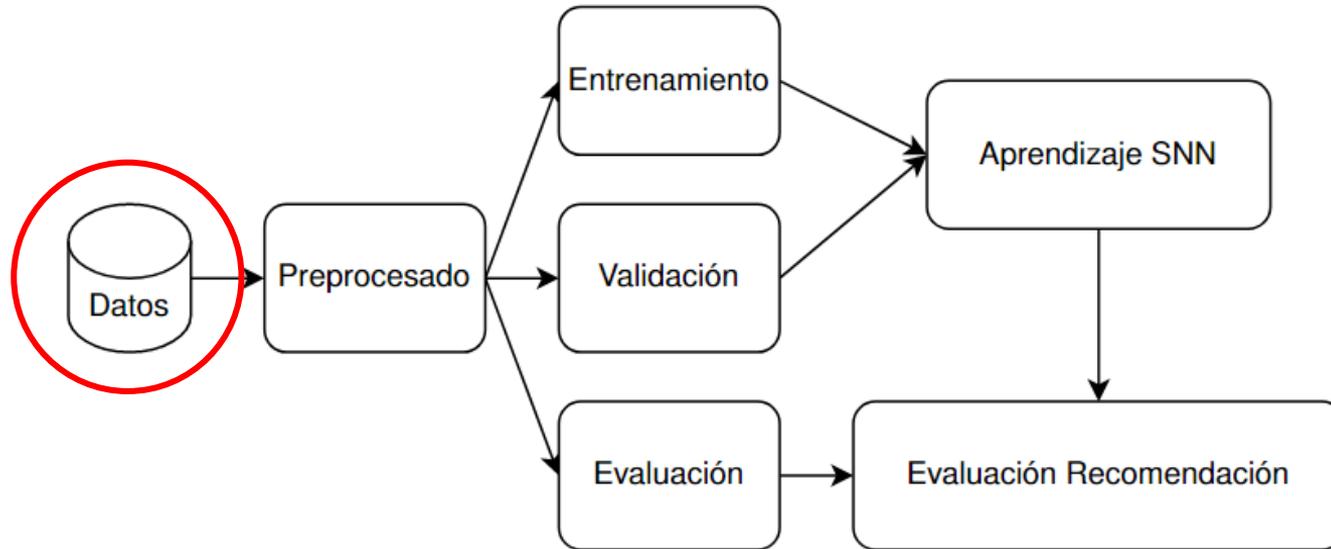
Implementación de los modelos



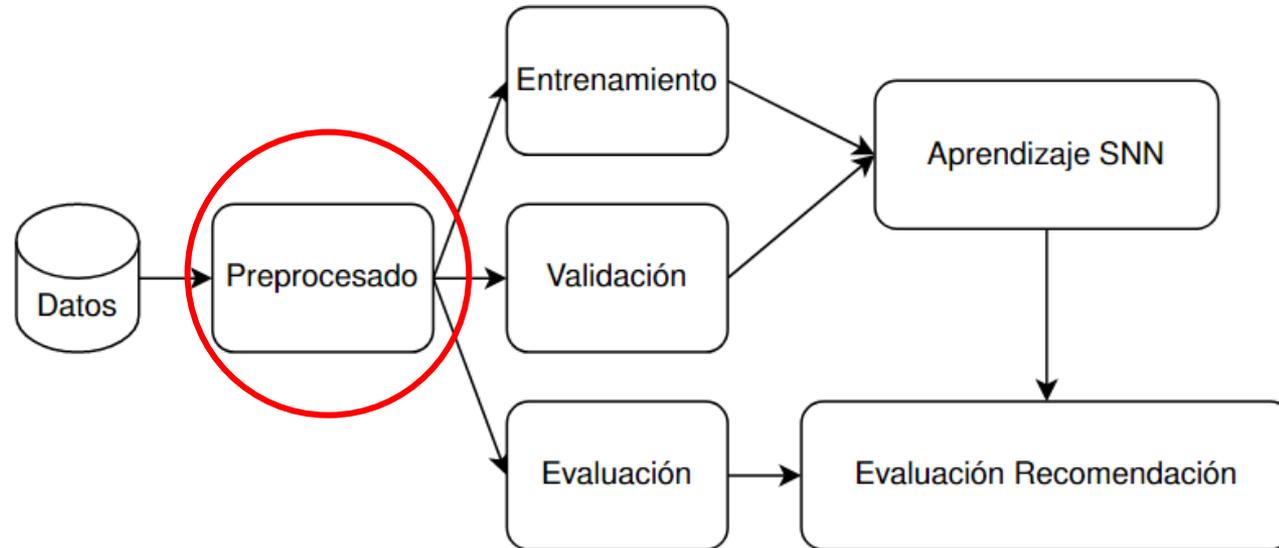
Artículos con código

Artículo	Año	Librerías	Link
[10]	2018	TensorFlow	https://github.com/PreferredAI/cbs
[11]	2018	Keras	https://github.com/dhruvkhattar/RARE
[16]	2021	TensorFlow, Keras	https://github.com/marinaangelovska/complementary_products_suggestions
[20]	2021	TensorFlow, Keras	https://github.com/michaelpulis/SnnForCbColdStartMusicRecommendation
[30]	2022	PyTorch	https://github.com/malteos/aspect-document-embeddings

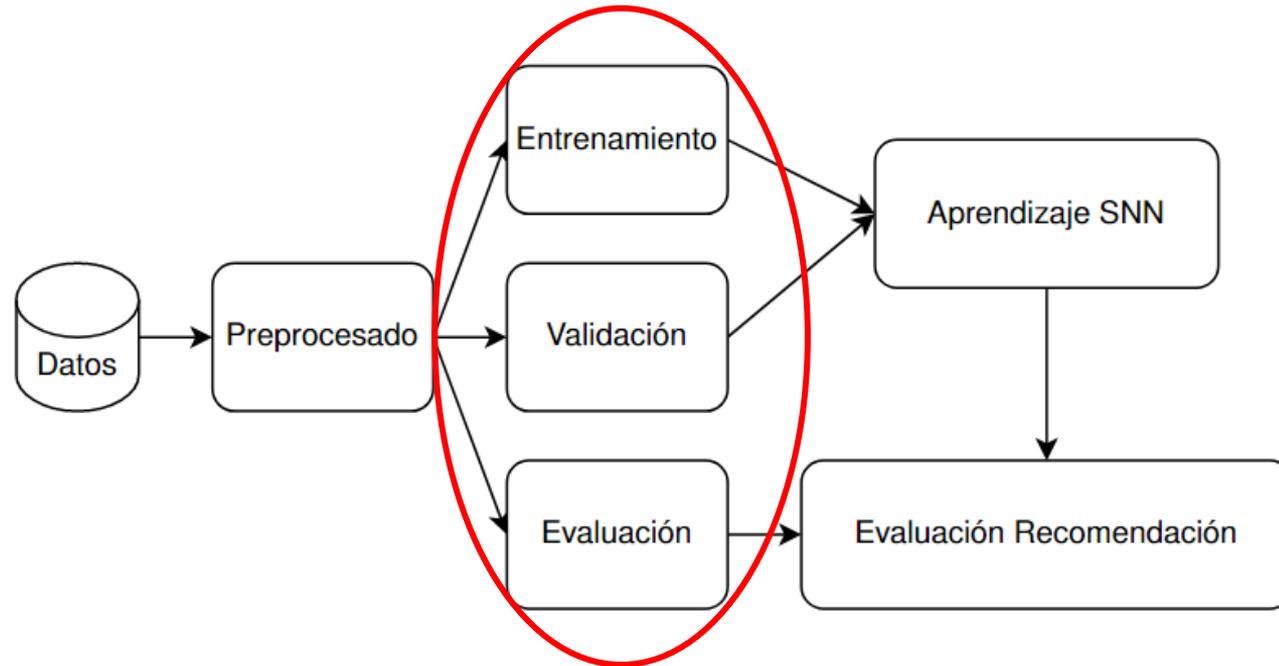
Arquitectura del problema



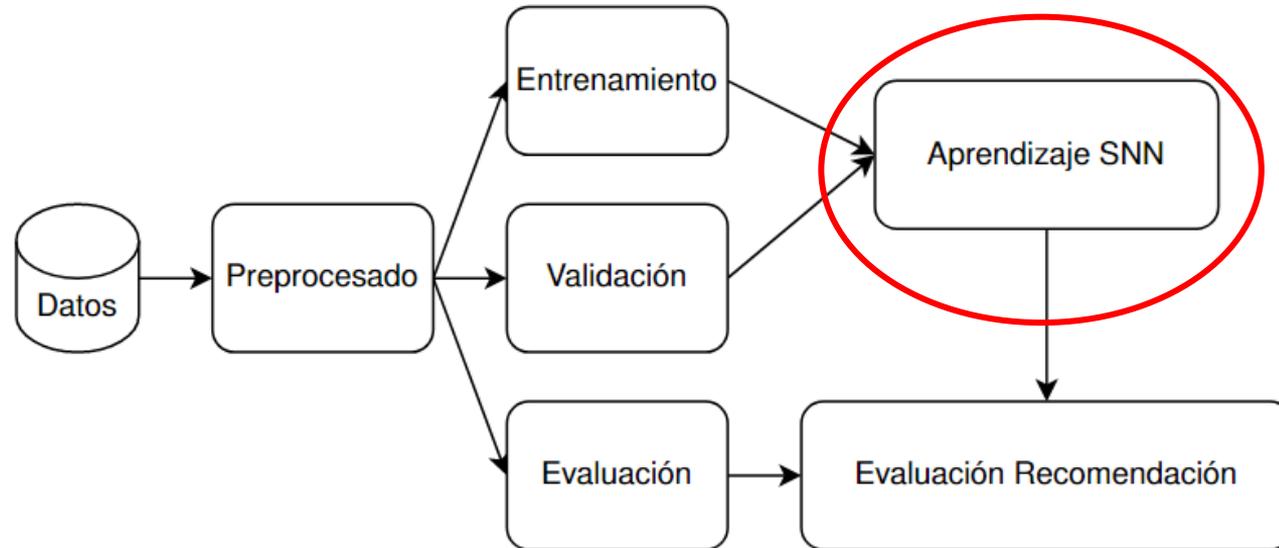
Arquitectura del problema



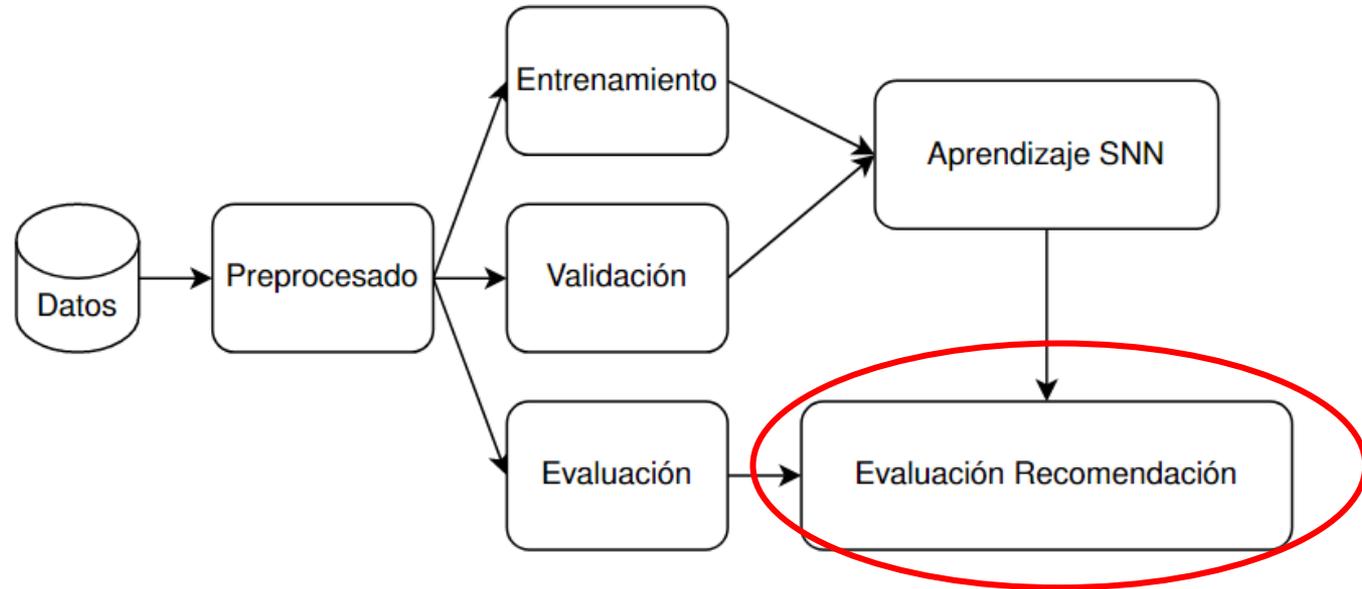
Arquitectura del problema



Arquitectura del problema



Arquitectura del problema

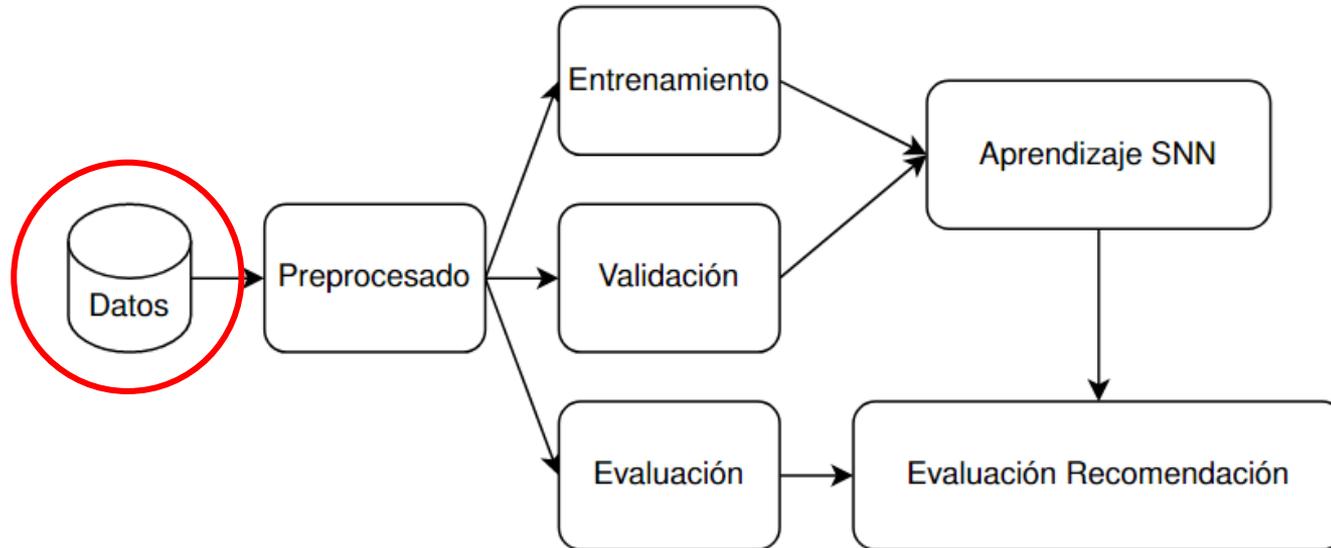




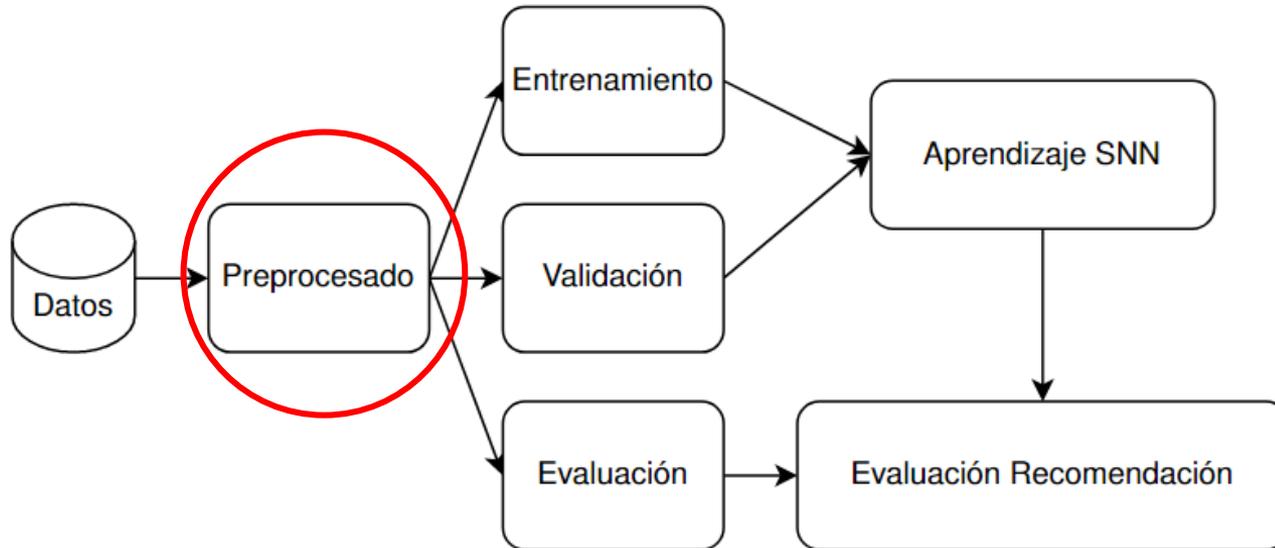
Experimentos Basados en Contenido

- 2 experimentos, Imágenes y Audios.
- Comparar diferentes redes feedforward y distintas funciones de pérdida.
- Enfoque algorítmico:
 - Uso de la red: Predicción.
 - Parámetros de entrada: Pareja.
 - Función de pérdida: BCE y Contrastive Loss.
 - Red feedforward: Red convolucional.

Experimentos Basados en Contenido



Experimentos Basados en Contenido





Experimentos Basados en Contenido

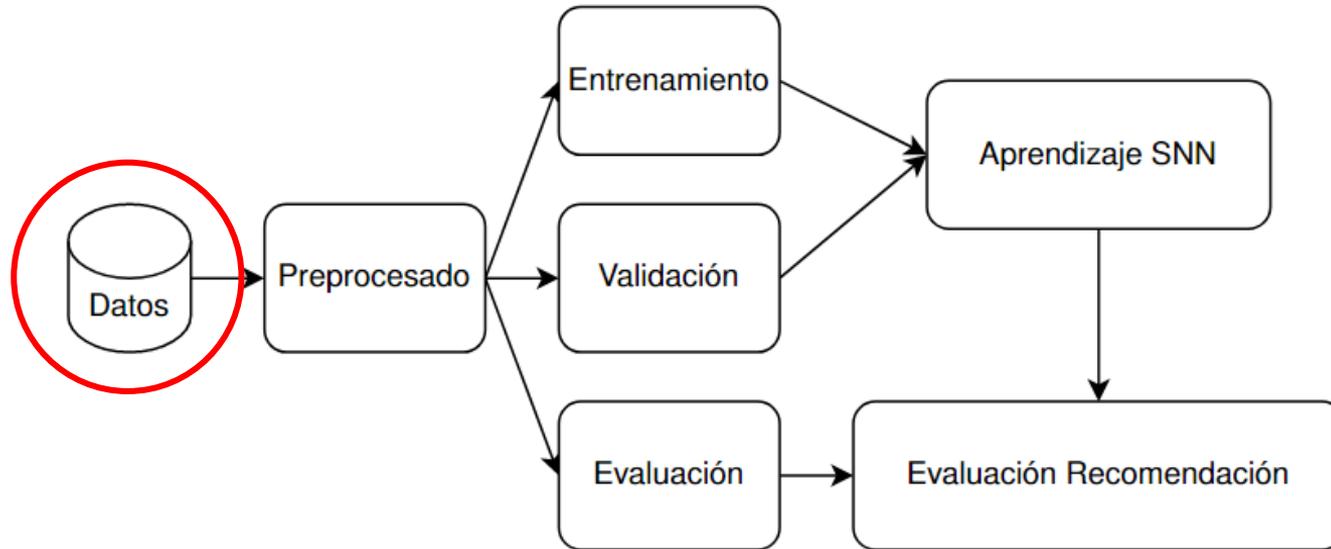
- Modelos de red Feedforward:
 - Custom CNN for MNIST
 - VGG-19 (Imagenet)
 - Inception-ResNet v2 (Imagenet)
- Funciones de pérdida:
 - BCE
 - Contrastive Loss



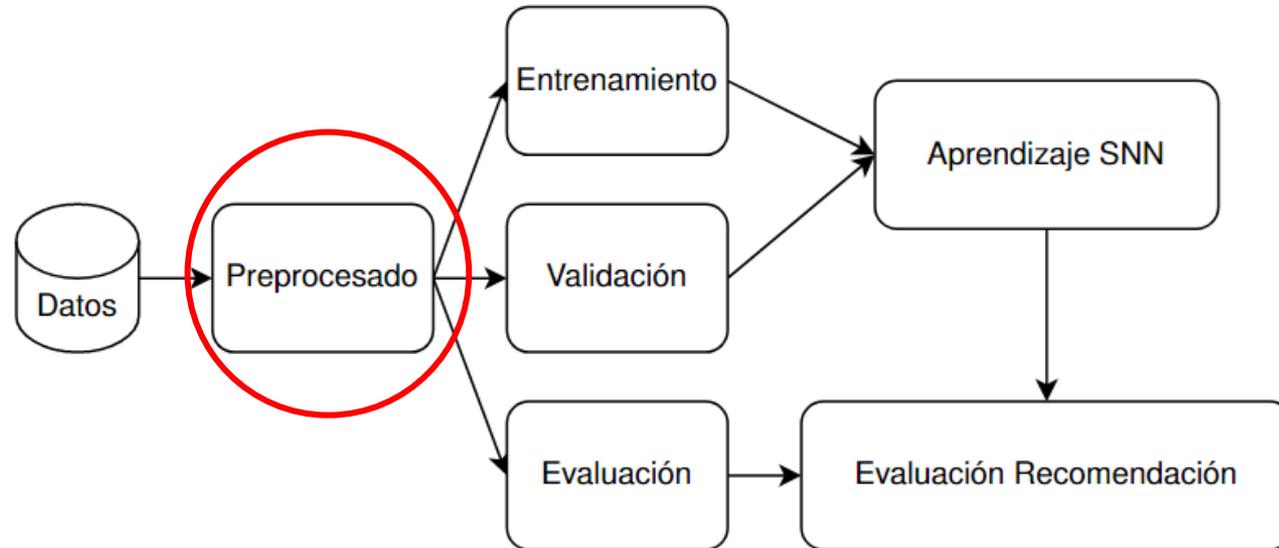
Experimentos Filtrado Colaborativo

- Comparar efecto del tamaño de recomendación en Precision y Recall.
- Comparar el sistema frente a un modelo de referencia.
- Enfoque algorítmico:
 - Uso de la red: Predicción.
 - Parámetros de entrada: Tripleta.
 - Función de pérdida: Triplet Loss .
 - Red feedforward: Perceptrón Multicapa.

Experimentos Filtrado Colaborativo



Experimentos Filtrado Colaborativo





Experimentos Filtrado Colaborativo

- Modelo de referencia:
 - Recomendación de vecindarios basado en usuario.
 - Similitud coseno.
 - Mejora de mínimo solapamiento.
 - Se debe estudiar el tamaño de vecindario.

Experimentos y Resultados



Código y entorno de ejecución

- Repositorio de GitHub:
<https://github.com/masternico97/Siamese-Recommender-Systems>

Recursos	Características
CPU	Intel(R) Xeon(R)
Frecuencia CPU	2.20GHz
Nº de núcleos CPU	2
Tamaño de disco	80GB
GPU	Nvidia Tesla T4
Memoria GPU	16GB
RAM	12.6 GB

Tabla 4.1: Especificaciones Hardware del entorno utilizado en Google Colab.



Basado en Contenido: Imágenes

- Dataset: V. Luhaniwal, “E-commerce product images,” 2021.
 - Dominio: moda.
 - Imágenes de ropa para hombres y mujeres.
 - Nos quedamos con calzado para hombre.

Total number of products : 811

Total Subcategories for men footwear: ['Shoes' 'Flip Flops' 'Sandal']

Total Product Types for men footwear: ['Casual Shoes' 'Flip Flops' 'Sandals' 'Formal Shoes' 'Sports Shoes' 'Sports Sandals']

Total Colours for men footwear: ['Black' 'White' 'Purple' 'Red' 'Khaki' 'Silver' 'Blue' 'Grey' 'Brown' 'Beige' 'Tan' 'Olive' 'Navy Blue' 'Maroon' 'Yellow' 'Charcoal' 'Turquoise Blue' 'Green' 'Orange' 'Multi' 'Mushroom Brown']

Basado en Contenido: Imágenes

1/1 [=====] - 0s 24ms/step
Similarity: 0.57



Similarity: 0.82



Similarity: 0.79



1/1 [=====] - 0s 26ms/step
Similarity: 0.78



Similarity: 0.78



Similarity: 0.77



1/1 [=====] - 0s 22ms/step
Similarity: 0.39



Similarity: 0.78



Similarity: 0.76





Basado en Contenido: Imágenes

	Entropía Binaria Cruzada	Contrastive loss
MNIST CNN	0.0114	0.0247
VGG-19	<u>0.0551</u>	0.0200
Inception-ResNet v2	0.0114	0.0230

Tabla 4.2: Resultados de Recall@10 para el experimento 1.

Basado en Contenido: Imágenes



	Entropía Binaria Cruzada	Contrastive loss
MNIST CNN	0.0114	0.0247
VGG-19	<u>0.0551</u>	0.0200
Inception-ResNet v2	0.0114	0.0230

Tabla 4.2: Resultados de Recall@10 para el experimento 1.



Basado en Contenido: Imágenes

	Entropía Binaria Cruzada	Contrastive loss
MNIST CNN	0.3025	0.3850
VGG-19	<u>0.8100</u> >	0.2925
Inception-ResNet v2	0.1725	0.4050

Tabla 4.3: Resultados de Precision@10 para el experimento 1.



Basado en Contenido: Audio

- Dataset: FMA.
 - Dominio: música.
 - 16 géneros.
 - Transformar audios en imágenes de su espectrograma de Mel.
 - Se establece similitud si algún género coincide.



Basado en Contenido: Audio

	Entropía Binaria Cruzada	Contrastive loss
MNIST CNN	<u>0.0764</u> >	0.0552
VGG-19	0.0130	0.0244
Inception-ResNet v2	0.0268	0.0269

Tabla 4.4: Resultados de Recall@10 para el experimento 2.



Basado en Contenido: Audio

	Entropía Binaria Cruzada	Contrastive loss
MNIST CNN	0.2607	<u>0.3000</u>
VGG-19	0.1107	0.1893
Inception-ResNet v2	0.2071	0.1429

Tabla 4.5: Resultados de Precision@10 para el experimento 2.



Filtrado Colaborativo

- Dataset: MovieLens Small.
 - Dominio: películas.
 - Películas con al menos 50 ratings.
 - Positivo si puntuación $> 3,5$.
- Modelo de referencia: Vecindario de tamaño 5 tras hacer pruebas.



Filtrado Colaborativo

K	Recall@K	Precision@K
1	0.0307	0.2065
2	0.0571	<u>0.2083</u>
3	0.0849	<u>0.2083</u>
4	0.1097	0.1993
5	0.1265	0.1860
6	0.1414	0.1765
7	0.1631	0.1713
8	0.1829	0.1685
9	0.2002	0.1612
10	<u>0.2190</u>	0.1587

Tabla 4.6: Resultados de Recall@K y Precision@K en el experimento 3 para el sistema de recomendación con la integración de la red siamesa, diferentes valores de K.

K	Recall@K	Precision@K
1	0.0139	0.0735
2	0.0273	0.0726
3	0.0483	0.0783
4	0.0645	<u>0.0802</u>
5	0.0762	0.0785
6	0.0893	0.0797
7	0.1033	0.0776
8	0.1128	0.0775
9	0.1234	0.0767
10	<u>0.1309</u>	0.0749

Tabla 4.8: Resultados de Recall@K y Precision@K en el experimento 3 para el sistema de recomendación de vecindarios basado en usuario, con un tamaño de vecindario 5.

Conclusiones del proyecto



Conclusiones

- Se han catalogado y agrupado artículos del estado del arte.
- Se han clarificado términos.
- Se han creado experimentos reproducibles en diseño y con acceso a código.
- Se ha observado que no siempre la Contrastive Loss es mejor que BCE.



Trabajo futuro

- Referencia de integración de SNN y sistemas de recomendación.
- Plantilla de diseño o código para futuras aproximaciones.
- Modelo de referencia de otro modelo.
- Investigación a expandir cuando el número de artículos en el área sea mayor.



Fin



¡Gracias por vuestra atención!




Apéndices



Consultas

```
(  
  TI="recommender systems" OR TS="recommender systems" OR  
  AB="recommender systems" OR AK="recommender systems" OR  
  TI="recommendation system" OR TS="recommendation system" OR  
  AB="recommendation system" OR AK="recommendation system" OR  
  TI="recommendation" OR TS="recommendation" OR AB="recommendation" OR  
  AK="recommendation"  
)  
AND  
(  
  TI="siamese network" OR TS="siamese network" OR AB="siamese network" OR  
  AK="siamese network" OR  
  TI="siamese neural network" OR TS="siamese neural network" OR AB="siamese  
  neural network" OR AK="siamese neural network" OR  
  TI="twin neural network" OR TS="twin neural network" OR AB="twin neural net-  
  work" OR AK="twin neural network"  
)
```

Cuadro A.1: Consulta en la base de datos de artículos Web of Science



Consultas

```
(  
  TITLE-ABS-KEY("recommender systems") OR  
  TITLE-ABS-KEY("recommendation system") OR  
  TITLE-ABS-KEY("recommendation")  
)  
AND  
(  
  TITLE-ABS-KEY("siamese network") OR  
  TITLE-ABS-KEY("siamese neural network") OR  
  TITLE-ABS-KEY("twin neural network")  
)
```

Cuadro A.2: Consulta en la base de datos de artículos Scopus

Busqueda Bibliográfica

Título	Apto	Año de publica	¿Accesible?	Propone datz	Origen dataset	Dataset P
A contextual-bandit approach for multifaceted reciprocal recommendations in online dating	Si	2022	Si	Si	Speed Dating Experiment	Público
CNGAN: Generative adversarial networks for cross-network user preference generation for non-overlapped users	?	2020	Si	Si	Dice como lo han hecho	
Deep Learning-based Online Alternative Product Recommendations at Scale	Si	2021	Si	Si	Dice como lo han hecho	
Fashion clothes matching scheme based on Siamese Network and AutoEncoder	Si	2019	Si	Si	MbFashion (FashionVC + MicroBlog)	
From Recommendation to Generation: A Novel Fashion Clothing Advising Framework	Si	2018	Si	Si	Amazon Fashion, Amazon Men's and Amazon Women's	Público
ImRec: Learning Reciprocal Preferences Using Images	Si	2020	Si	Si	Pairs (Asian dating app)	Privado
Learning Fashion Compatibility Across Apparel Categories for Outfit Recommendation	Si	2019	Si	Si	Polyvore	Público
Matching Recommendations based on Siamese Network and Metric Learning	Si	2018	Si	?		
Matching Recruiters and Jobseekers on Twitter	Si	2020	Si	Si	Dice como lo ha hecho (Twitter Search API con keywords)	
Matching Resumes to Jobs via Deep Siamese Network	Si	2018	Si	?	Dice como lo ha hecho (IBM Research Labs Intern Applications and Indian Job Descriptions)	
Mitigating long tail effect in recommendations using few shot learning technique	Si	2019	Si	Si	MovieLens1M, Netflix	Público, ?
Modeling contemporaneous basket sequences with twin networks for next-item recommendation	Si	2018	Si	Si	Alibaba, MovieLens	Público, P
MOOCs Recommender System with Siamese Neural Network	Si	2022	Si	Si	Logs from XuetangX	?
NZone: Identifying coreference object among user generated content with siamese network	Si	2020	Si	Si	Yelp, IMDB	Público, P
Rare: A recurrent attentive recommendation engine for news aggregators	Si	2018	Si	Si	CLEF NewsREEL, Other two news aggregation website	Público, Pr
Siamese neural networks for detecting complementary products	Si	2021	Si	Si	-	Privado
Siamese neural networks for content-based cold-start music recommendation	Si	2021	Si	Si	Free Music Archive	Público
TDFI: Two-stage Deep Learning Framework for Friendship Inference via Multi-source Information	Si	2019	Si	Si	Instagram (2016, NYC, LA, London)	Inaccessible
Convolutional networks for appearance-based recommendation and visualisation of mascara products	Si	2020	Si	Si	Dice como lo han hecho	
FoodNet: Simplifying Online Food Ordering with Contextual Food Combs	Si	2022	Si	Si	Dice como lo han hecho	
Learning audio embeddings with user listening data for content-based music recommendation	Si	2020	Si	Si?		
Semi-Siamese Network for Content-based Video Relevance Prediction	?	2019	Si	Si	Content-Based Video Relevance Prediction Datasets (HULU)	
Specialized document embeddings for aspect-based similarity of research papers	?	2022	Si	Si	Hecho por ellos	Público
TULSN: Siamese Network for Trajectory-user Linking	Si	2020	Si	Si	Gowalla, Brightkite (Referencia a un paper donde dice como lo hicieron)	



Horarios

Fecha	Motivo	Tarea	Horas
14/06/2022	1º Reunión Alejandro	Reunión	1
15/06/2022	Mirar cosas	Estado del arte	2,5
16/06/2022	Toqueteo		3
19/07/2022	Reanudar con cosas		1,25
20/07/2022	Busqueda bibliográfica	Estado del arte	1,5
05/09/2022	Comprobar referencias	Estado del arte	0,75
05/09/2022	Catalogar validos con Abstract	Estado del arte	0,5
06/09/2022	Catalogar validos con Abstract	Estado del arte	1,5
08/09/2022	Revisar catalogo	Estado del arte	1,5
11/09/2022	Leer papers morados	Estado del arte	3,5
12/09/2022	Leer papers naranjas	Estado del arte	3
13/09/2022	Leer papers azules + 1 amarillo	Estado del arte	3
14/09/2022	Leer papers + reunion	Estado del arte	3,5
15/09/2022	Terminar papers amarillos	Estado del arte	1
20/09/2022	Lectura 3 papers	Estado del arte	1,5
22/09/2022	Leer papers	Estado del arte	1
25/09/2022	Acabar lectura	Estado del arte	2,5
26/09/2022	Acabar repaso	Estado del arte	1
28/09/2022	Reunión	Reunión	1,5
04/10/2022	Configurar entorno		1,5
05/10/2022	Descargar datos del primer test	Estado del arte	0,5
07/10/2022	Entender y probar código cbs	Estado del arte	4
10/10/2022	Seguir cbs y rare	Estado del arte	2
11/10/2022	Detecting complementary products	Estado del arte	3
17/10/2022	Últimos dos papers	Estado del arte	4
25/10/2022	Mirando redes siamesas	Estado del arte	2,5
27/10/2022	Probando modelos		6
28/10/2022	VGC19, MLP, LSTM		10
02/11/2022	Reunión Bellogin	Reunión	2
02/11/2022	Presentación proyecto	Gestion	1
14/11/2022	Escribir Paper	TFM	2,5
16/11/2022	Encontrar dataset moda	Desarrollo fashion	1,5
21/11/2022	Contrative loose y visualize	Desarrollo BC?	8,5