

centrale_201606_sysrec

April 26, 2022

1 Recommandations sur le web

Quelques pistes sur le fonctionnement des moteurs de recommandations sur le web.

Related searches

- [Pandas PyData](#)
- [Pandas Dataframe](#)
- [Panda Python](#)
- [Pandas Documentation](#)
- [Python Data](#)
- [Install Pandas](#)
- [Data Frame Python](#)
- [Pandas](#)

Customers Who Bought This Item Also Bought



```
[1]: from jyquickhelper import add_notebook_menu
      add_notebook_menu()
```

```
[1]: <IPython.core.display.HTML object>
```

1.1 Formalisation d'un système de recommandation

			1			
	1			1		
	1				1	
		1				
		1		1		
1						
			1		1	
						1

1.1.1 Tenseur

- Tenseur = matrice multidimensionnelle
 - Utilisateur
 - Produit
 - Temps
 - Localisation
 - Contexte
- Quelle valeur pour les paires non observées ?
- Chaque dimension multiplie les possibilités sans multiplier les données.
- [Non-negative matrix factorization](#)

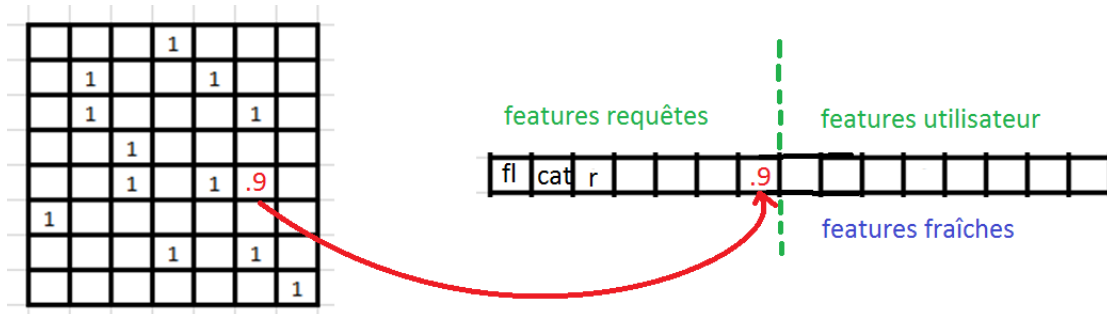
1.1.2 Système de recommandation, ranking

- Ranking similaire à un système de recommandation
 - Requête → résultats conseillés
 - Requête → requêtes associées (Related Searches)
- Recommandation pure
 - Le système n'utilise pas d'information sur le contenu
 - Uniquement basée sur l'évaluation implicite faite par l'utilisateur (le clic)

1.1.3 Recommandation en pratique

- Système de recommandation pure → une feature
- Features extraites à partir du contenu, du contexte, de l'utilisateur
- Utilisation de classifieurs intermédiaires (annotation manuelle, catégorisation)

- Apprendre le feedback des utilisateurs, généraliser là où il n'est pas



1.2 Offline / Online

Online

- Le service qui délivre les réponses à l'utilisateur.
- Quelques millisecondes

Offline

- Tout les traitements qui produisent les données que le service online utilisent.
- Data workflows
- Rafraîchissements fréquents et périodiques

1.2.1 Offline – cycle long – beaucoup de map reduce - machine learning

- Utilisation de logs d'événements (achats, clic)
- Génération de candidats : requête \rightarrow liste de résultats, système de recommandation
- Extraction de features (requête, résultat, paire requête résultats)
- Machine learning, targets construites à partir des clics

Construction d'une liste de recommandations à utiliser online $\sim O(100M)$.

1.2.2 Online – cycle très court

- Ranking online \rightarrow doit être rapide
- Personnalisation ?
- Compromis performance / pertinence

1.2.3 Systèmes de contrôle

- Black lists / while lists
- Possibilité de revenir à une version antérieure

1.2.4 Usure régulière

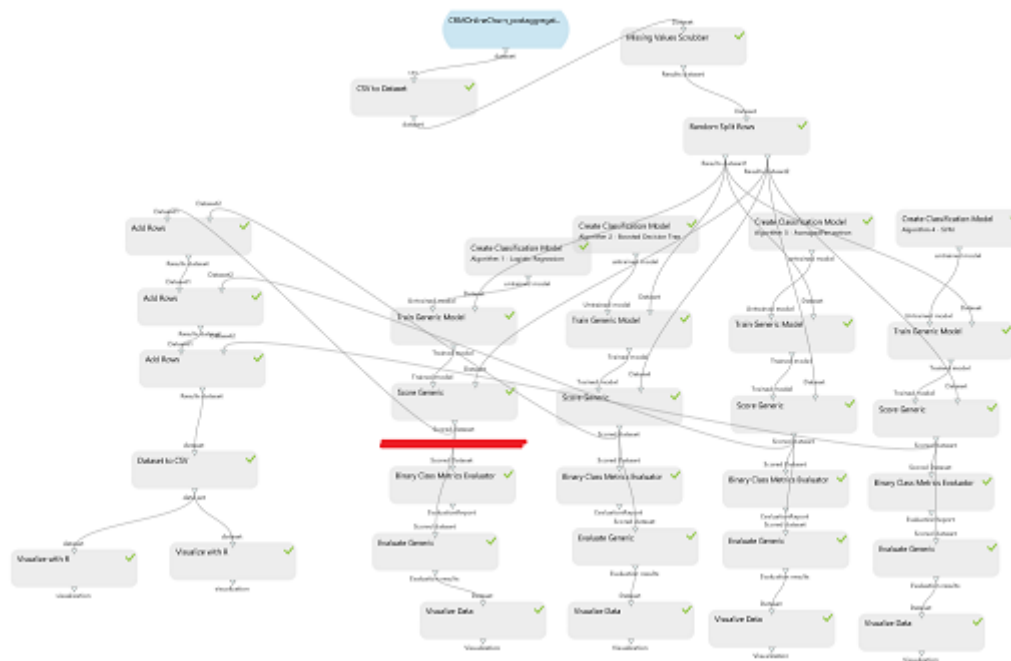
- Sans réapprentissage : dégradation des performances du ranker
- Croissance régulière des jeux de données
- Croissance des temps de traitements
- Nouvelles requêtes, livres, comment gérer ?

1.3 Kaggle VS machine learning en continu

- Kaggle = une compétition d'un jour
 - Ingénierie << recherche
- Production = réapprentissage en continu
 - Ingénierie > recherche

1.3.1 Workflow, pipeline ML

Always growing.



1.3.2 Questions difficiles

- Mesurer l'impact d'une modification ?
 - Au début du pipeline ?
 - A la fin du pipeline ?
- Corrélation entre
 - La performance offline du pipeline
 - Les préférences des utilisateurs (test A/B)
- Impact d'une modification sur les données d'apprentissages futures ?

1.3.3 Vécu

- Documentation manquante ou orale (black list, seuils...)
- On préfère ajouter un patches que de modifier un code existant.
- Implémentation pas forcément conçue pour tout volume de données.
- Difficulté de changer de technos ou d'algorithmes
- Agilité contre robuste
- Tests unitaires sur des clusters : pas de solutions miracles

1.4 Quelques paris sur l'avenir

Métrique

- Rôle d'une suggestion dans le parcours utilisateur ?
- Clic sur une suggestion : est-elle drôle ou pertinente ?
- Appauvrissement des données dû aux suggestions

Personnalisation renforcée

- Un utilisateur voit différentes suggestions même s'il fait la même requête
- Prise en compte de l'heure, de la météo...

Apprentissage par renforcement

- Randomisation des algorithmes
- Utiliser l'utilisateur pour faire converger le système
- [MWT](#)