



Avancement de travail

Présenté par:

Takwa Ben Smida

Proposé par:

Pr. Engelbert Mephu Nguifo

Dr. Sabeur Aridhi

Plan

1

Motivations

2

La plateforme Spark

4

Graphx

5

objectifs

Motivations

MapReduce:

- Plateforme pour le traitement massive des données
- N'en fournit pas pour accéder à la mémoire partagée.
- S'appuie sur le partage de données et il ne fournit pas l'abstraction pour une réutilisation des données.

 Inefficace pour une importante classe d'applications:

- Apprentissage automatique (Clustering);
- Algorithmes de graphe (PageRank);
- Algorithmes d'extraction de données interactives ...

Plan



Motivations



La plateforme Spark



Graphx



objectifs

Spark



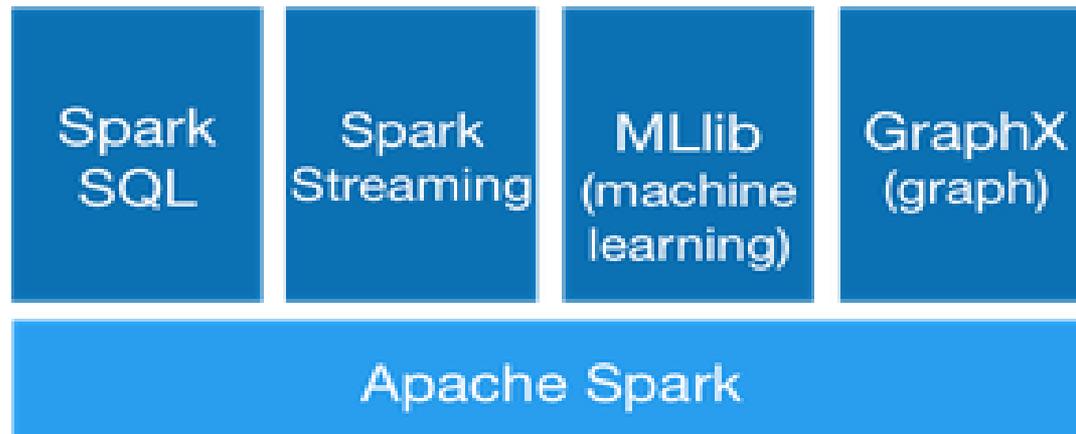
- ✚ Un modèle de programmation adapté au traitement de données à grande échelle;
- ✚ Open source , développé par la Fondation Apache;
- ✚ Une alternative *in-memory* plus rapide que le traditionnel MapReduce de Hadoop;
 - *fonctionne jusqu'à 10x sur disque et jusqu'à 100x en mémoire.*
- ✚ Divers langages de programmation : *Java, Scala ou Python.*

Spark



Utilisé pour une grande variété d'usages:

- capable de se connecter à des bases SQL: *Spark SQL*
- une analyse permanente des données en temps réel: *Spark Streaming*
- les calculs en profondeur impliquant l'apprentissage automatique: *Mlib*
- Traitement des graphes: *Graphx*



RDD: Resilient Distributed Datasets

- ✚ une collection partitionnée d'enregistrements en lecture seule;
- ✚ Réutilise efficacement les données dans une large gamme d'applications;


RDD: Resilient Distributed Datasets

- ✚ Tolérant à la panne;
 - ✚ Si une partition de RDD est perdue:
 - ❖ le RDD dispose d'informations sur la manière dont il a été produit pour recalculer la partition manquante.
 - ❖ les données perdues peuvent être récupérées rapidement sans avoir à recourir aux mécanismes de réplication.

Plan



Motivations



La plateforme Spark



Graphx



objectifs

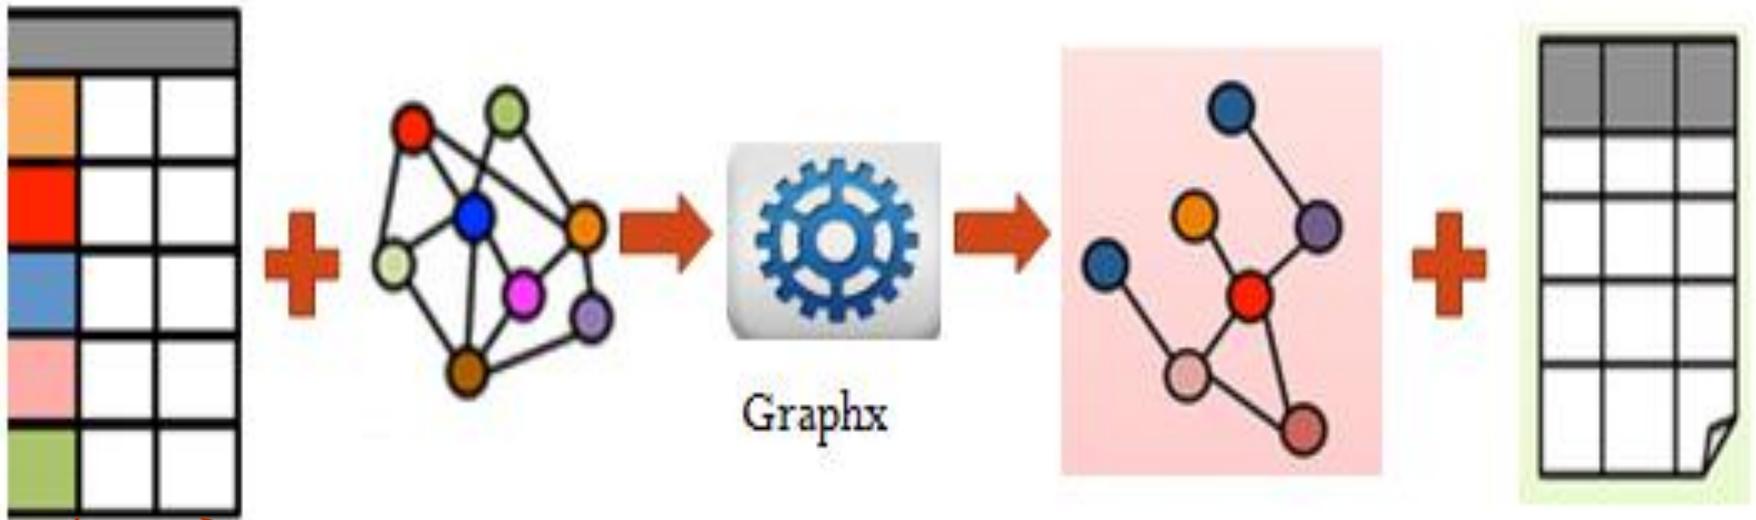
Graphx

Définition

- ✚ une bibliothèque de graphes qui tourne au-dessus de Spark Apache;
- ✚ Se base sur RDD de Spark.
- ✚ Les utilisateurs peuvent construire, transformer, restreindre des graphes.
 - Un graphe est défini par:
 - $G(V, E, P)$, avec $P = (P_V, P_E)$.

Graphx

Définition



Id	Property (V)
3	(rxin, student)
7	(jgonzal, postdoc)
5	(franklin, professor)
2	(istoica, professor)

SrcId	DstId	Property (E)
3	7	Collaborator
5	3	Advisor
2	5	Colleague
5	7	PI

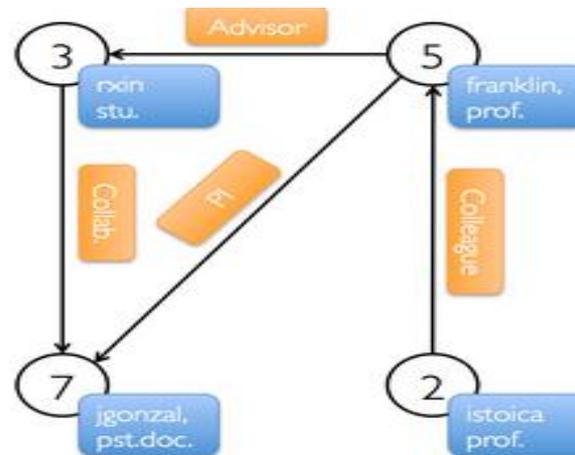
Graphx

Opérateurs de Graphx

- Map
- Filter
- ReduceByKey
- Subgraph

Id	Property (V)
3	(rxin, student)
7	(jgonzal, postdoc)
5	(franklin, professor)
2	(istoica, professor)

SrcId	DstId	Property (E)
3	7	Collaborator
5	3	Advisor
2	5	Colleague
5	7	PI



Plan




Motivations



La plateforme Spark



Graphx



objectifs

Objectifs

- ❑ Une évaluation de performance : SPARK et MapReduce:
 - Variation de la taille de données;
 - Variation du nombre de nœuds;

- ❑ Proposer un algorithme d'extraction des sous graphes fréquents à partir d'un seul graphe en utilisant Apache SPARK;

Merci pour votre attention
