

GraphX

Camelia Constantin

Prénom.Nom@lip6.fr

basé sur la présentation de J. Gonzalez

De nombreux algorithmes de calculs parallèles dans les graphes

- Collaborative Filtering
 - Alternating Least Squares
 - Stochastic Gradient Descent
 - Tensor Factorization
- Structured Prediction
 - Loopy Belief Propagation
 - Max-Product Linear Programs
 - Gibbs Sampling
- Semi-supervised ML
- Graph SSL
- CoEM
- Community Detection
 - Triangle-Counting
 - K-core Decomposition
 - K-Truss
- Graph Analytics
 - PageRank
 - Personalized PageRank
 - Shortest Path
 - Graph Coloring
- Classification
 - Neural Networks

Exemple de calcul de PageRank:

$$R[i] = 0.15 + \sum_{j \in \text{Nbrs}(i)} w_{ji} R[j]$$

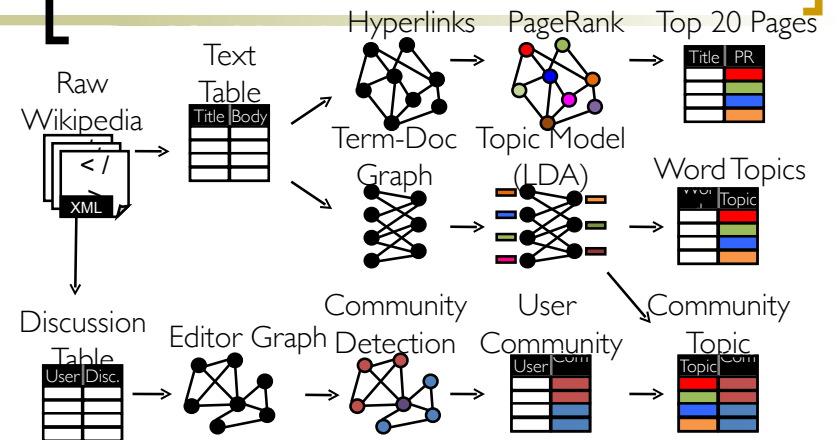
Rang de l'util. i

Somme pondérée des rangs des voisins

• Les calculs des mises à jour des rangs peuvent être fait en parallèle

• On itère jusqu'à la convergence

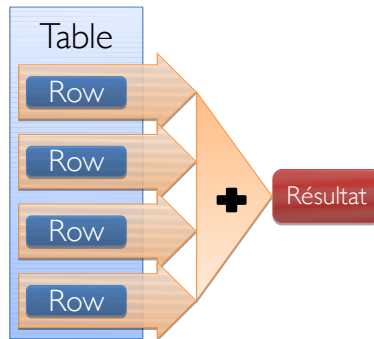
Les Graphes sont au centre de l'analyse de données Web



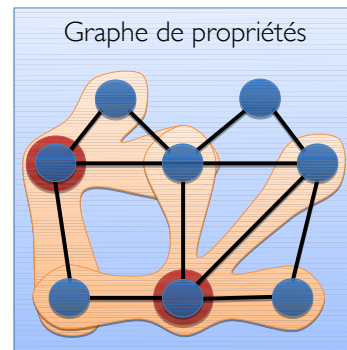
Les mêmes données peuvent avoir différentes "vues" table ou "vues" graphe (souvent utile de changer entre les deux vues)

Systèmes orientés graphe pour chaque vue

Data-parallel

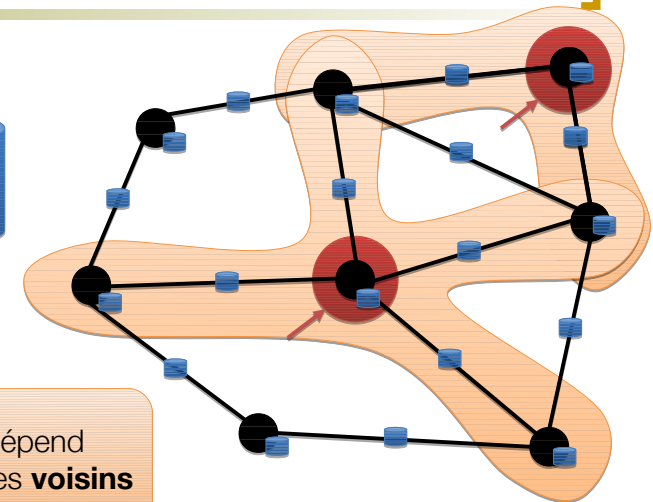


Graph-Parallel



L'abstraction Graph-Parallel

Modèle /
Alg.
Etat



Le calcul dépend
uniquement des **voisins**

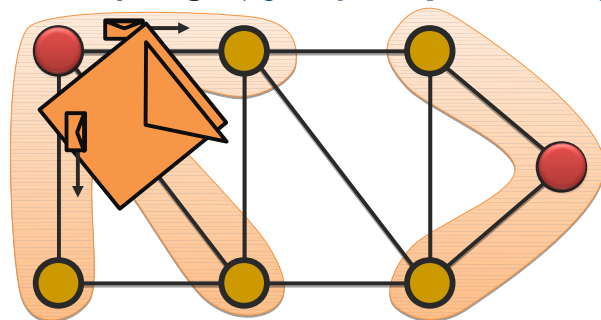
6

L'abstraction **Graph-Parallel**

Un programme défini par l'utilisateur s'exécute **sur chaque sommet**

Le graphe contraint les **interactions** le long des arêtes:

- en utilisant des **messages** (e.g. **Pregel** [PODC'09, SIGMOD'10])
- ou via des **états partagés** (e.g., **GraphLab** [UAI'10, VLDB'12])




Parallélisme: lance plusieurs programmes d'arêtes simultanément

7

Systèmes Graph-Parallel

Pregel
oogle



GraphLab


- Proposent des **APIs spécialisées** pour simplifier la programmation sur des graphes.
- Nouvelles techniques de partitionnement du graphe, restriction des types d'opérations qui peuvent être utilisées.
- Exploitent la structure du graphe pour obtenir des gains en performance de plusieurs ordres de magnitude comparé aux systèmes de données parallèles (Data-Parallel) plus génériques.

Inconvénients: difficile d'exprimer les différentes étapes d'un pipeline de traitement sur des graphes (construire/modifier le graphe, calculs sur plusieurs graphes)

8

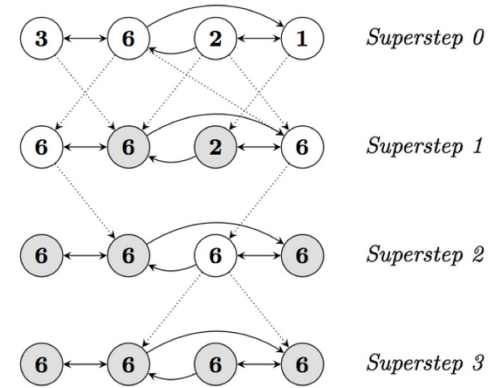
L'abstraction Pregel

Bulk Synchronous Parallel Model:

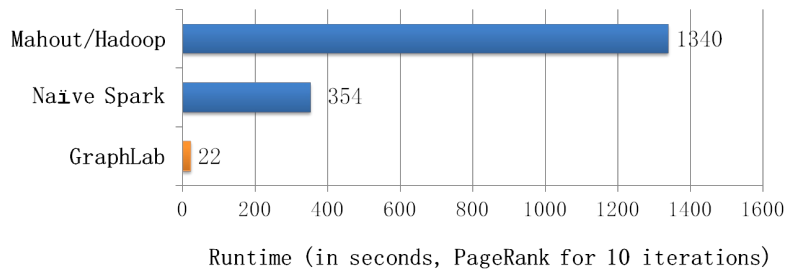


Illustration

Trouver le max des id des noeuds

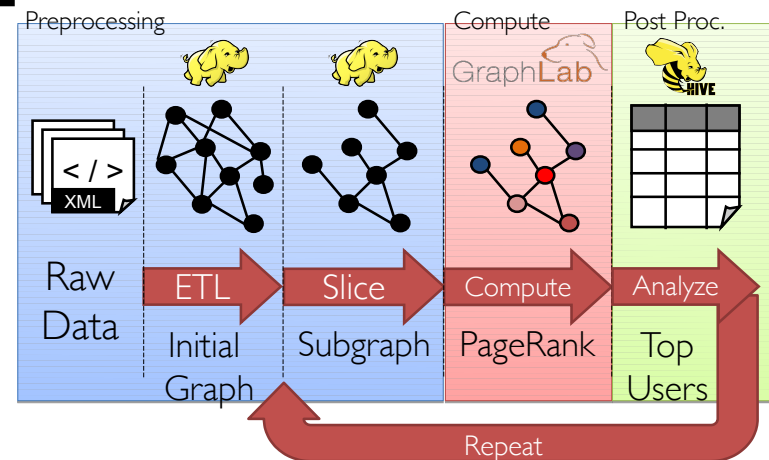


Exemple: calcul de PageRank sur le graphe de Live-Journal



GraphLab est *60x plus rapide que* Hadoop
 GraphLab is *16x plus rapide que* Spark

Pipeline d'analyse de graphes



Difficultés pour la programmation et l'utilisation

Les utilisateurs doivent **apprendre**, **déployer**, et **gérer** de multiples systèmes




Conduit à des interfaces compliquées à implanter et souvent complexes à utiliser, est particulièrement inefficace

13

Inefficacité

D'importants **déplacements de données** et de **duplications** à travers le réseau et le système de fichiers



Ré-utilisation limitée de structures de données internes d'une étape à l'autre

14


L'approche unifiée GraphX

Nouvelle API

Atténue la distinction entre les Tables et les Graphes

New System

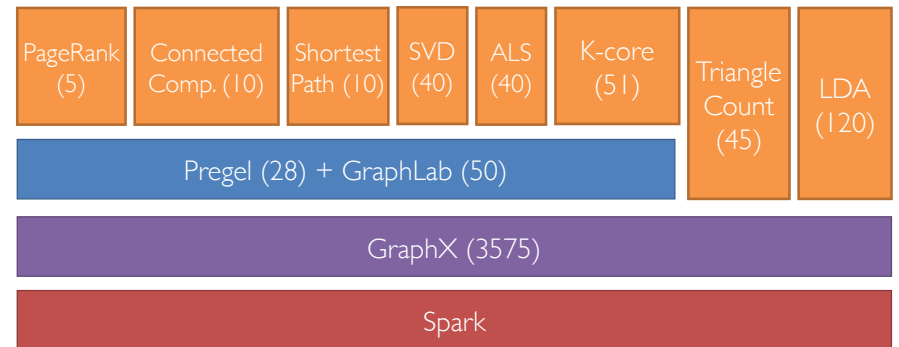
Combine les systèmes Data-Parallel et Graph-Parallel



Permet aux utilisateurs:

- d'exprimer facilement et efficacement le pipeline entier de l'analyse de graphe.
- de voir les données à la fois comme collections (RDD) et comme graphe sans déplacement/duplication

GraphX (Lignes de Code)



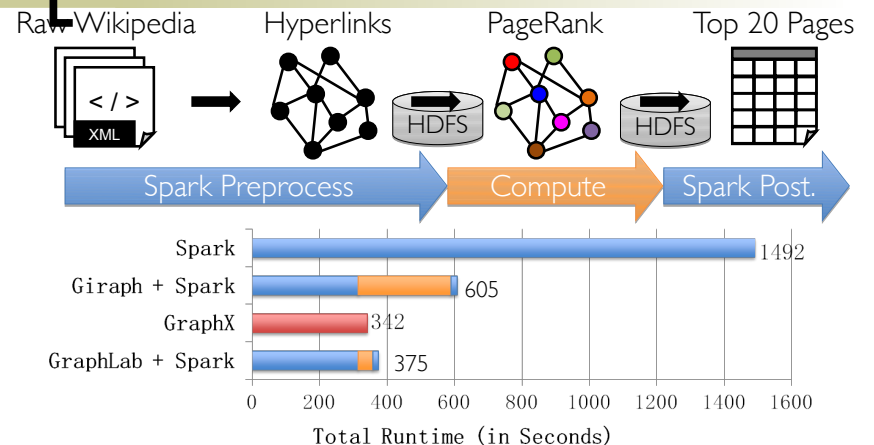
GraphX: avantages

Les abstractions Pregel et GraphLab peuvent être réalisées avec les **opérateurs GraphX** en moins de **50 lignes de code!**

En composant ces opérateurs on peut construire **les pipelines entiers d'analyses de graphe.**

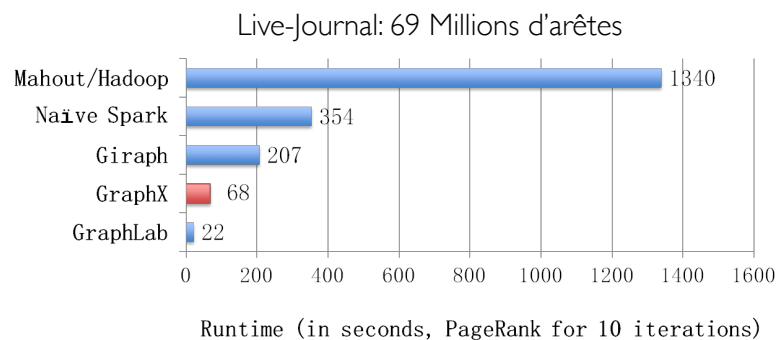
17

Un exemple de pipeline



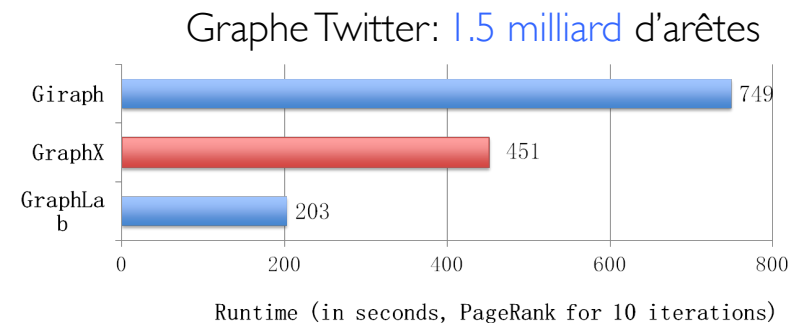
Le temps de traitement de GraphX pour tout le pipeline est plus **rapide** que Spark+GraphLab

Comparaisons des performances



GraphX est environ **3x plus lent** que GraphLab

GraphX passe à l'échelle sur de plus grands graphes




GraphX est environ **2x plus lent** que GraphLab

- » Surcoûts liés à Scala + Java: Lambdas, GC time, ...
- » Pas de parallélisation de la mémoire partagée: **2x plus de** comm.

Différentes vues

Les Tables et les Graphes sont des **vues composables** des mêmes données physiques



Chaque vue a ses propres **opérateurs** qui **exploitent la sémantique** de la vue pour obtenir une **exécution efficace**

Voir un Graphe comme une Table(RDD)

Graphe de propriétés




Table des sommets

Id	Propriété (V)
Rxin	(Stu., Berk.)
Jegonzal	(PstDoc, Berk.)
Franklin	(Prof., Berk)
Istoica	(Prof., Berk)

Table des arêtes

Src_Id	Dst_Id	Propriété (E)
rxin	jegonzal	Friend
franklin	rxin	Advisor
istoica	franklin	Coworker
franklin	jegonzal	PI

Gestion du graphe

- Comme les RDD, les graphes de propriétés sont:
- **Non-modifiable**: les changements de valeurs ou de la structure du graphe se font en produisant un nouveau graphe
- **Distribués**: le graphe est partitionné en utilisant un ensemble d'heuristiques pour le partitionnement des noeuds
- **Résistant aux pannes**: comme avec RDD, chaque partition sur le graphe peut être recréé sur une autre machine pour la tolérance aux pannes

Le graphe de propriétés

- Multigraphe dirigé avec des objets définis par l'utilisateur attachés à chaque arête et à chaque sommet
- Multi-graphe signifie qu'il peut y avoir plusieurs arêtes partageant la même source et destination (dans le cas où on veut modéliser plusieurs relations entre nœuds)
- Chaque sommet a une clé unique VertexID de 64 bits (**VertexId**)
- Chaque arête a l'ID du sommet source et l'ID du sommet destination

Le graphe de propriétés

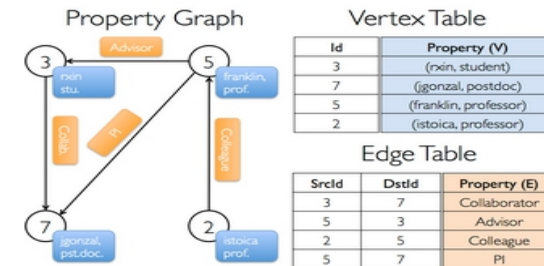
Le graphe de propriétés correspond à deux RDD :

- `VertexRDD[VD]`, version optimisée de `RDD[(VertexID,VD)]`, pour les sommets
- `EdgeRDD[ED]` versions optimisée de `RDD[Edge[ED]]`, pour les arcs
- `VD` et `ED` : types des objets associés aux sommets/arcs
- `VertexRDD[VD]` et `EdgeRDD[ED]` fournissent des fonctionnalités supplémentaires pour les calculs de graphe

Exemple de graphe de propriétés

Exemple du graphe de propriétés des collaborateurs du projet GraphX:

- Les sommets contiennent le nom et la fonction
- Les arcs annotés avec la nature de la collaboration



Graphe obtenu: `val userGraph: Graph[(String, String), String]`

Construction du graphe

type `VertexId` = `Long`

```
//Créer une RDD pour les sommets
val vertices :RDD[(VertexId,(String, String))] = sc.parallelize(Array((3L,
("rxin","student")), (7L,("jgonzal","postdoc")), (5L,("franklin","prof")), (2L,
("istoica", "prof"))))
```

```
class Edge[ED] (val srcId : VertexId, val dstId : VertexId, val attr : ED)
```

```
//Créer une RDD pour les arcs
val edges :RDD[Edge[String]] = sc.parallelize(Array(Edge(3L,7L,
"collab"),Edge(5L, 3L,"advisor" ), Edge(2L,5L, "colleague"),
Edge(5L,7L,"pi")))
```

```
val graph = Graph(vertices, edges)
```

Le graphe obtenu a la signature : `Graph[(String, String), String]`

Opérateurs de Tables

Les opérateurs de table (RDD) sont hérités de Spark:

<code>map</code>	<code>reduce</code>	<code>sample</code>
<code>filter</code>	<code>count</code>	<code>take</code>
<code>groupBy</code>	<code>fold</code>	<code>first</code>
<code>sort</code>	<code>reduceByKey</code>	<code>partitionBy</code>
<code>union</code>	<code>groupByKey</code>	<code>mapWith</code>
<code>join</code>	<code>cogroup</code>	<code>pipe</code>
<code>leftOuterJoin</code>	<code>cross</code>	<code>save</code>
<code>rightOuterJoin</code>	<code>zip</code>	<code>...</code>

Opérateurs de Graphe

```
class Graph [ V, E ] {
  def Graph(vertices: Table[ (Id, V) ],
            edges: Table[ (Id, Id, E) ])
  // Vues -----
  val vertices: VertexRDD[VD]
  val edges: EdgeRDD[ED]
  val triplets: RDD[EdgeTriplet[VD, ED]]
  // Transformations -----
  def reverse: Graph[V, E]
  def subgraph(pV: (Id, V) => Boolean,
              pE: Edge[V, E] => Boolean): Graph[V, E]
  def mapV(m: (Id, V) => T): Graph[T, E]
  def mapE(m: Edge[V, E] => T): Graph[V, T]
  // Joins -----
  def joinV(tbl: Table [(Id, T)]): Graph[(V, T), E]
  def joinE(tbl: Table [(Id, Id, T)]): Graph[V, (E, T)]
  // Computation -----
  def aggregateMessages(sendMsg: EdgeContext[VD, ED, Msg] => Unit,
                       mergeMsg: (Msg, Msg) => Msg,
                       tripletFields: TripletFields = TripletFields.All): VertexRDD[Msg]
}
```

29

Utilisation des vues

Décomposition du graphe en vue sommets ou vue arêtes avec `graph.vertices` et `graph.edges`

```
val graph: Graph[(String, String), String] // Constructed from above
// Count all users which are postdocs
graph.vertices.filter { case (id, (name, pos)) => pos == "postdoc" }.count
// Count all the edges where src > dst
graph.edges.filter(e => e.srcId > e.dstId).count
```

Résultats : 1, 1

`graph.vertices` retourne un `VertexRDD[(String, String)]` qui étend `RDD[(VertexID, (String, String))]` => on peut utiliser le `case` pour décomposer le tuple (idem pour les arêtes)

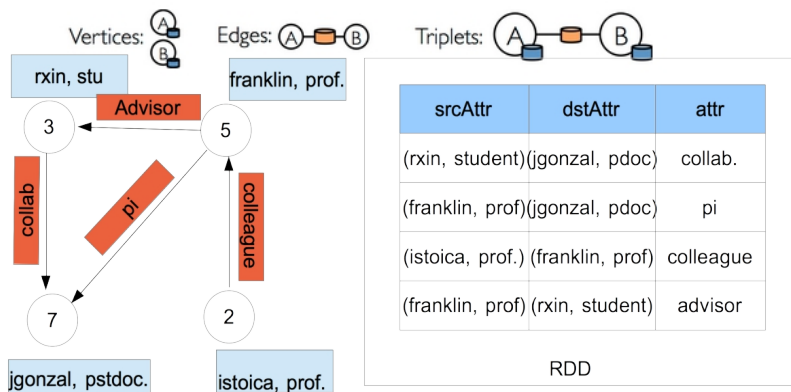
`graph.edges` retourne `EdgeRDD[String]` (`RDD[Edge[String]]`) =>

on pouvait également utiliser `case` comme suit:

```
graph.edges.filter { case Edge(src, dst, prop) => src > dst }.count
```

Vue triplets

- En plus de la vue sommets et la vue arêtes, il existe une vue `triplets` `RDD[EdgeTriplet[VD, ED]]`
- La classe `EdgeTriplet` étend la classe `Edge` en ajoutant `srcAttr` et `dstAttr` contenant les propriétés des noeuds source/destination



Vue triplets

Exemple : afficher les relations entre les utilisateurs :

```
val graph: Graph[(String, String), String] // Constructed from above
// Use the triplets view to create an RDD of facts.
val facts: RDD[String] =
  graph.triplets.map(triplet =>
    triplet.srcAttr._1 + " is the " + triplet.attr + " of " + triplet.dstAttr._1)
facts.collect.foreach(println(_))
```

Résultat :

```
rxin is the collab of jgonzal
franklin is the advisor of rxin
istoica is the colleague of franklin
franklin is the pi of jgonzal
```


Opérateurs d'information

```
// Information about the Graph =====  
=====  
val numEdges: Long  
val numVertices: Long  
val inDegrees: VertexRDD[Int]  
val outDegrees: VertexRDD[Int]  
val degrees: VertexRDD[Int]  
// Views of the graph as collections =====  
=====  
val vertices: VertexRDD[VD]  
val edges: EdgeRDD[ED]  
val triplets: RDD[EdgeTriplet[VD, ED]]
```

Exemple(1)

- Calculer le degré entrant de chaque sommet :

```
val graph: Graph[(String, String), String]  
// Utiliser l'opérateur GraphOps.inDegrees  
val inDegrees: VertexRDD[Int] = graph.inDegrees  
inDegrees.collect.foreach(println(_))
```

- Résultat :

```
(3, 1)  
(5, 1)  
(7, 2)
```

Exemple(2)

```
// Define a reduce operation to compute the highest degree vertex  
def max(a: (VertexId, Int), b: (VertexId, Int)): (VertexId, Int) = {  
  if (a._2 > b._2) a else b  
}  
// Compute the max degrees  
val maxInDegree: (VertexId, Int) = graph.inDegrees.reduce(max)  
val maxOutDegree: (VertexId, Int) = graph.outDegrees.reduce(max)  
val maxDegrees: (VertexId, Int) = graph.degrees.reduce(max)
```

- Calculer le degré entrant/sortant/total maximum de chaque sommet :

Résultat:

```
maxDegrees : (5,3)  
maxInDegree : (7,2)  
maxOutDegree : (5,2)
```

Opérateurs de transformation(1)


```
// Change the partitioning heuristic =====  
def partitionBy(partitionStrategy: PartitionStrategy): Graph[VD, ED]  
// Transform vertex and edge attributes =====  
def mapVertices[VD2](map: (VertexID, VD) => VD2): Graph[VD2, ED]  
def mapEdges[ED2](map: Edge[ED] => ED2): Graph[VD, ED2]  
def mapEdges[ED2](map: (PartitionID, Iterator[Edge[ED]]) => Iterator[ED2]): Graph[VD, ED2]  
def mapTriplets[ED2](map: EdgeTriplet[VD, ED] => ED2): Graph[VD, ED2]  
def mapTriplets[ED2](map: (PartitionID, Iterator[EdgeTriplet[VD, ED]]) => Iterator[ED2])  
: Graph[VD, ED2]
```

- mapXX : produit un nouveau graphe de même structure avec XX modifié par la fonction de l'utilisateur map
- La structure n'est pas affectée (le graphe résultat réutilise les index structurels du graphe d'origine)
- Ces opérateurs sont souvent utilisés pour initialiser le graphe pour un calcul ou enlever des propriétés inutiles

Exemple : mapTriplets

Créer un nouveau graphe où chaque arc est étiqueté avec un poids

```
val outputGraph: Graph[Double, Double] =  
graph.mapTriplets(triplet => 1.0 / triplet.srcAttr).mapVertices((id, _) => 1.0)
```



Opérateurs sur structure

```
// Modify the graph structure =====  
def reverse: Graph[VD, ED]  
def subgraph(  
  epred: EdgeTriplet[VD, ED] => Boolean = (x => true),  
  vpred: (VertexID, VD) => Boolean = ((v, d) => true))  
  : Graph[VD, ED]  
def mask[VD2, ED2](other: Graph[VD2, ED2]): Graph[VD, ED]  
def groupEdges(merge: (ED, ED) => ED): Graph[VD, ED]
```

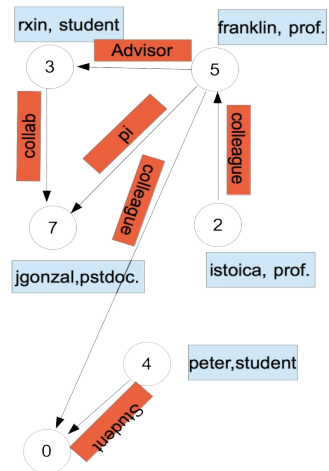
Opérateurs sur structure (2)

- `reverse`: retourne un nouveau graphe en inversant la direction des arêtes
- `subgraph`: prend des prédicats sur sommets et arêtes et retourne le graphe contenant les sommets satisfaisants les prédicats et reliés par les arêtes satisfaisant les prédicats (si l'on veut restreindre à certains nœuds/arcs)
- `mask`: retourne un sous-graphe correspondant à l'intersection d'un graphe donné et d'un graphe-masque
- `groupEdges`: pour un multi-graphe, fusionne les différentes arêtes entre 2 sommets en une seule

Exemple : subgraph (1)

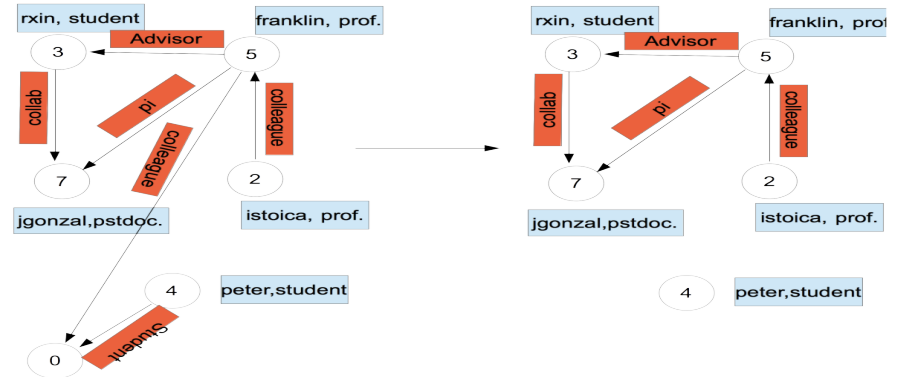
```
//RDD pour les sommets  
val users: RDD[(VertexId, (String, String))] =  
  sc.parallelize(Array((3L, ("rxin", "student")), (7L, ("jgonzal", "postdoc")), (5L, ("franklin",  
    "prof")), (2L, ("istoica", "prof")), (4L, ("peter", "student"))))  
  
//RDD pour les arcs  
val relationships: RDD[Edge[String]] = sc.parallelize(Array(Edge(3L, 7L, "collab"),  
  Edge(5L, 3L, "advisor"), Edge(2L, 5L, "colleague"), Edge(5L, 7L, "pi"), Edge(4L, 0L,  
    "student"), Edge(5L, 0L, "colleague")))  
  
// Définir un utilisateur par défaut pour les arcs dont un des sommets n'est pas défini  
val defaultUser = ("John Doe", "Missing")  
  
// Construire le graphe  
val graph = Graph(users, relationships, defaultUser)
```

Exemple : subgraph (2)



Exemple : subgraph (3)

```
val validGraph = graph.subgraph(vpred = (id, attr) => attr._2 != "Missing")
```



Exemple : subgraph (4)

```
validGraph.vertices.collect.foreach(println(_))
```

Résultat :

```
(2, (istoica, prof))
(3, (rxin, student))
(4, (peter, student))
(5, (franklin, prof))
(7, (jgonzal, postdoc))
```

```
validGraph.triplets.map( triplet => triplet.srcAttr._1 + " is the " + triplet.attr + "
of " + triplet.dstAttr._1).collect.foreach(println(_))
```

Résultat

```
rxin is the collab of jgonzal
franklin is the advisor of rxin
istoica is the colleague of franklin
franklin is the pi of jgonzal
```

Exemple : mask et subgraph

Calculer les composantes connexes en utilisant tous les arrêtes, y compris celles passant par des nœuds « inconnus » mais ne pas garder ces nœuds dans le résultat.

```
// Run Connected Components
val ccGraph = graph.connectedComponents() // No longer contains missing field
// Remove missing vertices as well as the edges to connected to them
val validGraph = graph.subgraph(vpred = (id, attr) => attr._2 != "Missing")
// Restrict the answer to the valid subgraph
val validCCGraph = ccGraph.mask(validGraph)
```

Opérateurs de jointure


```
// Join RDDs with the graph =====
def joinVertices[U](table: RDD[(VertexID, U)])(mapFunc: (VertexID, VD, U) => VD): Graph[VD, ED]
def outerJoinVertices[U, VD2](other: RDD[(VertexID, U)])(
  mapFunc: (VertexID, VD, Option[U]) => VD2
): Graph[VD2, ED]
```

Souvent il est nécessaire de joindre des données de collections externes (RDD) avec des graphes

Ex.: on souhaite ajouter d'autres propriétés à un graphe existant, ou copier des propriétés d'un graphe à l'autre

`joinVertices`: joint les sommets avec le RDD en entrée et retourne un nouveau graphe avec les propriétés obtenues en appliquant la fonction map aux sommets joignant

Exemple : joinVertices



```
val joinRDD: RDD[(VertexId, String)] = sc.parallelize(Array((3L, "étudiant"), (5L, "professeur")))
val joinedGraph = graph.joinVertices(joinRDD)((id, oldVal, newVal) => (oldVal._1, newVal))
joinedGraph.vertices.collect.foreach(println(_))
```

Résultat :


```
(2,(istoica, prof)) (3,(rxin,étudiant)) (5,(franklin,professeur)) (7,(jgonzal, pstdoc))
```

- les sommets qui n'ont pas de correspondants dans la RDD gardent leur valeur initiale.
- `joinVertices` ne peut pas changer le type des propriétés des sommets (ex. : toujours (String, String))

Exemple : outerJoinVertices

Créer un nouveau graphe, à chaque sommet on associe son degré sortant :

```
val degreesRDD : VertexRDD[Int] = graph.outDegrees
val joinedGraph: Graph[Int, String] = graph.outerJoinVertices(degreesRDD)((vid, _, degOpt) => degOpt.getOrElse(0))
```



```
joinedGraph.vertices.collect.foreach(println(_))
```

Résultat :

```
(2,1) (3,1) (5,2) (7,0)
```

- La fonction map est appliquée à tous les sommets, elle prend comme paramètre un type **Option**.
- `outerJoinVertices` peut changer le type des propriétés des sommets (ex. : Int au lieu de (String, String))

Opérateurs d'agrégation

```
// Aggregate information about adjacent triplets =====
def collectNeighborIds(edgeDirection: EdgeDirection): VertexRDD[Array[VertexID]]
def collectNeighbors(edgeDirection: EdgeDirection): VertexRDD[Array[(VertexID, VD)]]
def aggregateMessages[Msg: ClassTag](
  sendMsg: EdgeContext[VD, ED, Msg] => Unit,
  mergeMsg: (Msg, Msg) => Msg,
  tripletFields: TripletFields = TripletFields.All
): VertexRDD[A]
```

- rassembler sur les sommets des informations sur leur voisinage

Exemple : collectNeighbors

```
class GraphOps[VD, ED] {
  def collectNeighborIds(edgeDirection: EdgeDirection): VertexRDD[Array[VertexId]]
  def collectNeighbors(edgeDirection: EdgeDirection): VertexRDD[Array[(VertexId, VD)] ]
}
```

- rassembler sur chaque sommet ses voisins et leur attributs
- pas efficaces, essayer d'utiliser **aggregateMessages**

```
val resultat:VertexRDD[Array[(VertexId, (String, String))]] =
  graph.collectNeighbors(EdgeDirection.Both)
```

```
resultat.collect.foreach(sommet=>(print(sommet._1),
  sommet._2.foreach(print(_),println())))
```

Résultat :

```
2(5, (franklin, prof))
3(7, (jgonzal, postdoc)) (5, (franklin, prof))
5(3, (rxin, student)) (2, (istoica, prof)) (7, (jgonzal, postdoc))
7(3, (rxin, student)) (5, (franklin, prof))
```

Exemple : aggregateMessages

```
class Graph[VD, ED] {
  def aggregateMessages[Msg: ClassTag] (
    sendMsg: EdgeContext[VD, ED, Msg] => Unit,
    mergeMsg: (Msg, Msg) => Msg,
    tripletFields: TripletFields = TripletFields.All)
    : VertexRDD[Msg]
}
```

- **aggregateMessage**: applique une fonction sendMsg (≈map) définie par l'utilisateur à chaque triplet puis utilise mergeMsg (≈reduce) pour agréger ces messages pour le sommet destination
- **EdgeContext**: représente une arête avec les sommets correspondants et permet d'envoyer des messages aux sommets
- **VertexRDD[Msg]**: contient les messages agrégés (de type Msg) pour chaque sommet. Les sommets qui n'ont pas reçu de message ne sont pas inclus dans le résultat
- **tripletFields**: indique quelles informations de EdgeContext sont accessibles pour sendMsg (autres valeurs possibles: Dst, Src, EdgeOnly, None)

Exemple


Calculer le nombre de followers plus âgés pour chaque sommet et la somme de leurs âges

```
val olderFollowers: VertexRDD[(Int, Double)] = graph.aggregateMessages((Int, Double)({
  triplet => { // Map Function
    if (triplet.srcAttr > triplet.dstAttr) {
      // Send message to destination vertex containing counter and age
      triplet.sendToDst(1, triplet.srcAttr)
    }
  },
  // Add counter and age
  (a, b) => (a._1 + b._1, a._2 + b._2) // Reduce Function
})
```

- olderFollowers.collect.foreach(println(_))

Résultats :

```
(A, (1, 42.0))
(C, (1, 75.0))
(F, (1, 30.0))
```



51

VertexRDD

VertexRDD[VD]:

- représente un ensemble de nœuds, chacun ayant un attribut de type VD.
- chaque VertexID doit être unique, n'apparaît pas explicitement
- les attributs des nœuds sont stockés dans un hash-map => permet de faire les jointures en temps constants entre deux VertexRDD dérivées à partir de la même VertexRDD

```
class VertexRDD[VD] extends RDD[(VertexId, VD)] {
  // Filter the vertex set but preserves the internal index
  def filter(pred: Tuple2[VertexId, VD] => Boolean): VertexRDD[VD]
  // Transform the values without changing the ids (preserves the internal index)
  def mapValues[V2](map: VD => V2): VertexRDD[V2]
  def mapValues[V2](map: (VertexId, VD) => V2): VertexRDD[V2]
  // Remove vertices from this set that appear in the other set
  def diff(other: VertexRDD[VD]): VertexRDD[VD]
  // Join operators that take advantage of the internal indexing to accelerate joins (substantially)
  def leftJoin[V2, V3](other: RDD[(VertexId, V2)])(f: (VertexId, VD, Option[V2]) => V3): VertexRDD[V3]
  def innerJoin[U, V2](other: RDD[(VertexId, U)])(f: (VertexId, VD, U) => V2): VertexRDD[V2]
  // Use the index on this RDD to accelerate a 'reduceByKey' operation on the input RDD.
  def aggregateUsingIndex[V2](other: RDD[(VertexId, V2)], reduceFunc: (V2, V2) => V2): VertexRDD[V2]
}
```

EdgeRDD

- Les arcs sont organisés en blocks, partitionnés avec une des stratégies (*CanonicalRandomVertexCut*, *EdgePartition1D*, *EdgePartition2D*, *RandomVertexCut*)
- Les attributs sont stockés séparément de la structure d'adjacence afin de pouvoir les changer facilement
- Trois fonctions additionnelles, en plus des fonctions hérités de la classe RDD :


```
// Transform the edge attributes while preserving the structure
def mapValues[ED2](f: Edge[ED] => ED2): EdgeRDD[ED2]
// Reverse the edges reusing both attributes and structure
def reverse: EdgeRDD[ED]
// Join two 'EdgeRDD's partitioned using the same partitioning strategy.
def innerJoin[ED2, ED3](other: EdgeRDD[ED2])(f: (VertexID, VertexID, ED, ED2) => ED3): EdgeRDD[ED3]
```

Exemple: moyenne des âges des followers plus âgés

```
// Divide total age by number of older followers to get average age of older followers
val avgAgeOfOlderFollowers: VertexRDD[Double] =
  olderFollowers.mapValues( (id, value) =>
    value match { case (count, totalAge) => totalAge / count } )
// Display the results
avgAgeOfOlderFollowers.collect.foreach(println(_))
```

- `avgAgeOfOlderFollowers.collect.foreach(println(_))`

Résultats :
(A, 42.0)
(C, 75.0)
(F, 30.0)



Autres opérateurs

```
// Iterative graph-parallel computation =====
def pregel[A](initialMsg: A, maxIterations: Int, activeDirection: EdgeDirection)(
  vprog: (VertexID, VD, A) => VD,
  sendMsg: EdgeTriplet[VD, ED] => Iterator[(VertexID,A)],
  mergeMsg: (A, A) => A
): Graph[VD, ED]
```

```
// Basic graph algorithms =====
def pageRank(toI: Double, resetProb: Double = 0.15): Graph[Double, Double]
def connectedComponents(): Graph[VertexID, ED]
def triangleCount(): Graph[Int, ED]
def stronglyConnectedComponents(numIter: Int): Graph[VertexID, ED]
```

API Pregel

```
// Iterative graph-parallel computation =====
def pregel[A](initialMsg: A, maxIterations: Int, activeDirection: EdgeDirection)(
  vprog: (VertexID, VD, A) => VD,
  sendMsg: EdgeTriplet[VD, ED] => Iterator[(VertexID,A)],
  mergeMsg: (A, A) => A
): Graph[VD, ED]
```


- Algorithmes itératifs qui calculent les propriétés des sommets en fonction des propriétés de leur voisins
- Arrêt du calcul : lorsqu'il n'y a plus de messages (à chaque étape les sommets qui n'ont pas reçu de message n'envoient pas de messages)
- `vprog` : fonction exécutée par chaque sommet pour agréger ses propriétés avec les messages reçus à chaque étape
- `sendMsg` : pour envoyer un message à chaque voisin
- `mergeMsg` : fonction pour agréger les messages reçus

Plus courts chemins

```

val sourceId: VertexId = 1 // The ultimate source
// Initialize the graph such that all vertices except the root have distance infinity.
val initialGraph = graph.mapVertices((id, _) =>
  if (id == sourceId) 0.0 else Double.PositiveInfinity)
val sssp = initialGraph.pregel(Double.PositiveInfinity)(
  (id, dist, newDist) => math.min(dist, newDist), // Vertex Program
  triplet => { // Send Message
    if (triplet.srcAttr + triplet.attr < triplet.dstAttr) {
      Iterator((triplet.dstId, triplet.srcAttr + triplet.attr))
    } else {
      Iterator.empty
    }
  },
  (a, b) => math.min(a, b) // Merge Message
)
println(sssp.vertices.collect.mkString("\n"))

```



Résultats :
 (1,0.0) (2,12.0) (3,14.0) (4,8.0) (5,9.0) (6,3.0)

Utilisation de PageRank en GraphX

```


import org.apache.spark.graphx.GraphLoader

// Load the edges as a graph
val graph = GraphLoader.edgeListFile(sc, "data/graphx/followers.txt")
// Run PageRank
val ranks = graph.pageRank(0.0001).vertices
// Join the ranks with the usernames
val users = sc.textFile("data/graphx/users.txt").map { line =>
  val fields = line.split(",")
  (fields(0).toLong, fields(1))
}
val ranksByUsername = users.join(ranks).map {
  case (id, (username, rank)) => (username, rank)
}
// Print the result
println(ranksByUsername.collect().mkString("\n"))

```

Joindre les Sommets et les Arêtes

L'opérateur triplets joint les sommets et les arêtes:



L'opérateur mrTriplets somme les triplets adjacents.

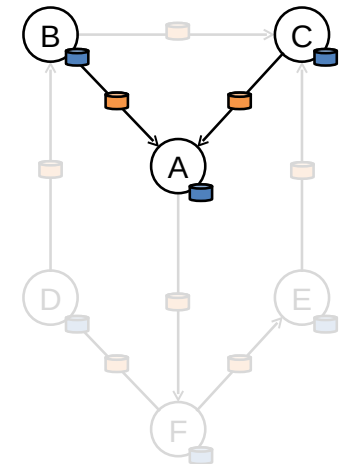

```

SELECT t.dstId, reduceUDF( mapUDF(t) ) AS sum
FROM triplets AS t GROUPBY t.dstId

```

Map Reduce Triplets

Map-Reduce pour chaque sommet



Conclusion et Observations

Vues spécifiques à un domaine: Tables et Graphes

- » Les tables et les graphes sont les objets de base composables
- » opérateurs spécialisés qui exploitent la sémantique des vues

Un système unique qui couvre efficacement le pipeline

- » minimise les mouvements et la duplication de données
- » Plus besoin d'apprendre et gérer différents systèmes

Les graphes vus par l'oeil des BD

- » Graph-Parallel Pattern → Triplet joints en algèbre relationnelle
- » Systèmes de graphe → optimisations de jointures distribuées

61

Programmer avec GraphX

<http://spark.apache.org/docs/latest/graphx-programming-guide.html>

Pour démarrer

il faut d'abord importer GraphX dans la console Spark:

```
import org.apache.spark.graphx._  
import org.apache.spark.rdd.RDD
```

TME

Exercice 1: Construire un graphe à partir des fichiers facebook_edges_prop.csv et facebook_users_prop.csv (voir la section "Graph Builders").

Le fichier facebook_edges_prop.csv contient sur chaque ligne les informations suivantes pour un arc:

source, destination, type_relation, nombre_messages_échangés

Le fichier facebook_users_prop.csv contient les informations suivantes sur chaque utilisateur:

utilisateur, prénom, nom, âge

TME

- Le type de la structure Spark qui stocke les sommets est :

```
org.apache.spark.rdd.RDD[(org.apache.spark.graphx.VertexId, (String, String, Int))]
```

- Le type de la structure Spark qui stocke les arêtes est :

```
org.apache.spark.rdd.RDD[org.apache.spark.graphx.Edge[(String, Int)]]
```

- Le type de la structure Spark qui stocke le graphe est :

```
org.apache.spark.graphx.Graph[(String, String, Int),(String, Int)]
```

TME

Afficher les prénoms des amis de Kendall. On considère le graphe non-dirigé.

```
graph.triplets.filter{t =>t.srcAttr._1 == "Kendall" ||  
  t.dstAttr._1 ==  
  "Kendall"}.map(t=>if(t.srcAttr._1 == "Kendall")  
  t.dstAttr._1 else  
  t.srcAttr._1).collect.foreach(u=>println(u))
```

Réponse

Il faut source, destination, type_relation, nombre_messages_échangés

Code

```
var lines = sc.textFile("facebook_edges_prop.csv", 4)  
val edgesList:RDD[Edge[(String, Int)]] = lines.map{s=>  
  val parts = s.split(",")  
  Edge(parts(0).toLong, parts(1).toLong, (parts(2), parts(3).toInt)) }.distinct()  
var lines = sc.textFile("facebook_users_prop.csv", 4)  
val vertexList:RDD[(VertexId,(String, String, Int))] = lines.map{s=>  
  val parts = s.split(",")  
  (parts(0).toLong, (parts(1), parts(2), parts(3).toInt))  
  }.distinct()  
val graph = Graph.apply(vertexList, edgesList)
```

TME

Afficher pour l'utilisateur 'Kendall' son nom et son âge (utiliser la vue graph.vertices).

```
graph.vertices.filter{case(id,(p,n,a)) =>  
  p=="Kendall"}.collect.foreach(u=>println(u._1+" "  
  "+u._2._2+" "+u._2._3))
```