DPark

轻量友好的MapReduce框架

刘洪清 (Davies) davies@douban.com

2011/12/07 Velocity China 2011

豆瓣 douban

- 背景
- 计算模型
- 示例
- 总结

Douban 的规模

豆瓣 douban

Douban 的规模

- 5500万用户

Douban 的规模

- 5500万用户
- 1000G 日志数据, 每月

豆瓣 douban

Douban 的规模

- 5500万用户
- 1000G 日志数据, 每月
- 60+ 台物理服务器

豆瓣 douban

Douban 的规模

- 5500万用户
- 1000G 日志数据, 每月
- 60+ 台物理服务器
- 200+ 员工

豆瓣 douban

Douban 的规模

- 5500万用户
- 1000G 日志数据, 每月
- 60+ 台物理服务器
- 200+ 员工
- 开发效率 > 执行效率

豆瓣 douban

基础架构

基础架构

- MooseFS
  - 260 T, 44 节点

基础架构

- MooseFS
  - 260 T, 44 节点
- InfoBright ICE
  - weblog, 60+ B 记录

基础架构

- MooseFS
  - 260 T, 44 节点
- InfoBright ICE
  - weblog, 60+ B 记录
- Python, R, MPI (C++)

Hadoop

豆瓣 douban

Hadoop

- 08 年，开始尝试

豆瓣 douban

Hadoop

- 08 年，开始尝试
  - 矩阵运算效果不理想

豆瓣 douban

Hadoop

- 08 年，开始尝试
  - 矩阵运算效果不理想
- 09 年，尝试使用

Hadoop

- 08 年，开始尝试
  - 矩阵运算效果不理想
- 09 年，尝试使用
  - HDFS, MapR, ZooKeeper, Hive

豆瓣 douban

Hadoop

- 08 年，开始尝试
  - 矩阵运算效果不理想
- 09 年，尝试使用
  - HDFS, MapR, ZooKeeper, Hive
  - Dumbo

豆瓣 douban

计算方面的问题

计算方面的问题

- 计算资源管理和调度

计算方面的问题

- 计算资源管理和调度
  - Hadoop, MPI 等等

计算方面的问题

- 计算资源管理和调度
  - Hadoop, MPI 等等
- 更好用的计算框架

计算方面的问题

- 计算资源管理和调度
  - Hadoop, MPI 等等
- 更好用的计算框架
  - 比 Hadoop 轻量，灵活

计算方面的问题

- 计算资源管理和调度
  - Hadoop, MPI 等等
- 更好用的计算框架
  - 比 Hadoop 轻量，灵活
  - 比 MPI 简单，鲁棒

Apache Mesos*

- 资源管理和调度框架
  - 开放资源调度接口
  - 隔离，资源限制，Linux Container

http://www.mesosproject.org/

豆瓣 douban

DRun

豆瓣 douban

DRun

- 基于 Mesos 的作业提交

DRun

- 基于 Mesos 的作业提交
  - 支持 MPICH2

DRun

- 基于 Mesos 的作业提交
  - 支持 MPICH2
  - 支持 ad-hoc 并行计算， RANK, SIZE

DRun

- 基于 Mesos 的作业提交
  - 支持 MPICH2
  - 支持 ad-hoc 并行计算， RANK, SIZE

```
$ drun -n 10 -c 1 -m 10m -r 2 hostname
[3@alg221] alg221
[2@alg224] alg224
.....
```

豆瓣 douban

DRun 案例

豆瓣 douban

DRun 案例

- 音频压缩
  - 70万，AAC 格式

DRun 案例

- 音频压缩
  - 70万，AAC 格式
- 抓取北京车牌号抽签结果
  - 几十万页面

豆瓣 douban

DRun + Mesos

- 解决了计算资源管理和调度问题

豆瓣 douban

Spark*

- Lightning-Fast Cluster Computing

```
val file = spark.textFile("hdfs://...")
file.flatMap(line => line.split(" "))
      .map(word => (word, 1))
      .reduceByKey(_ + _)
```

Word Count in Spark

* http://www.spark-project.org/

豆瓣 douban

Spark

- 更好地支持迭代计算

Spark

- 更好地支持迭代计算

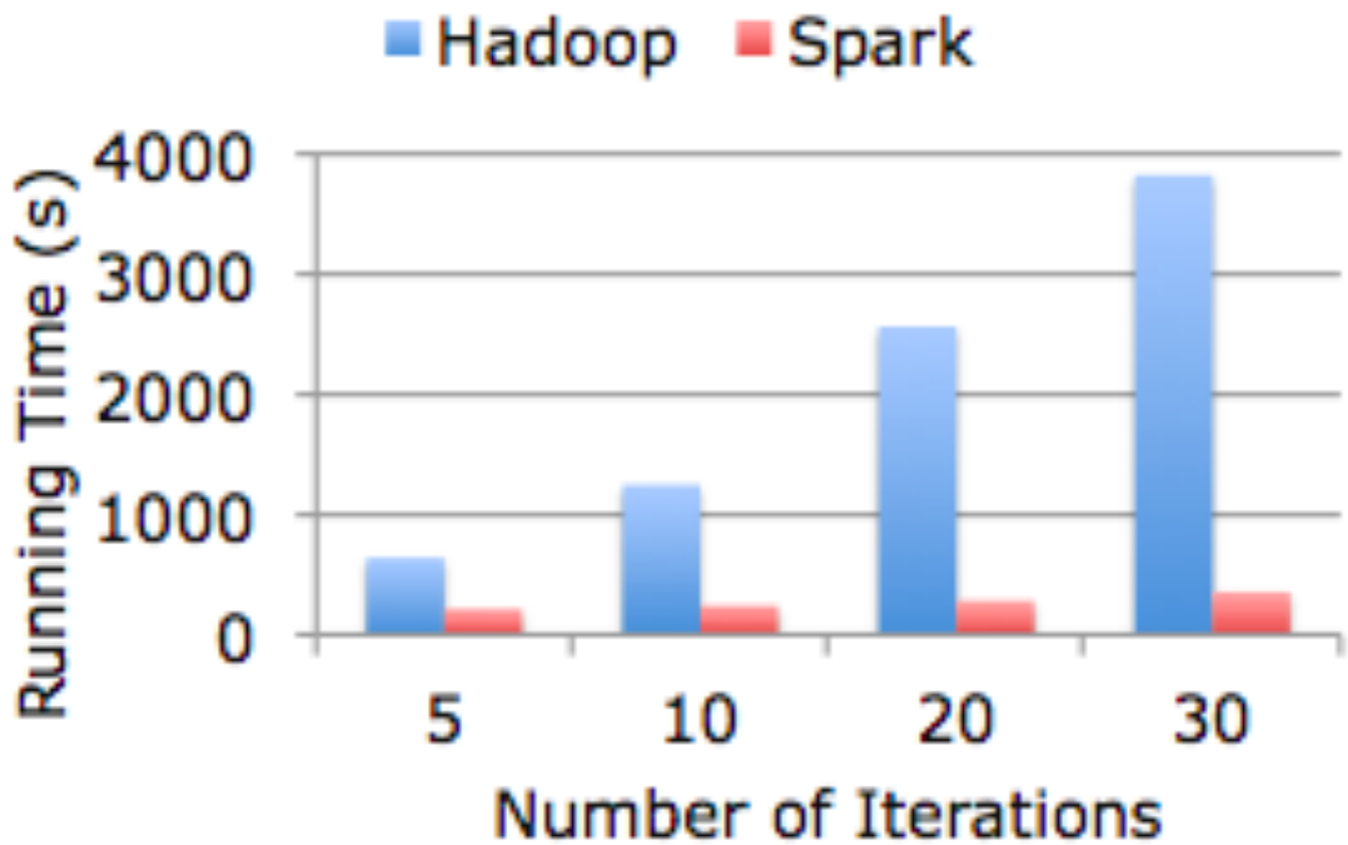

Logistic regression in Spark vs Hadoop

豆瓣 douban

Spark

豆瓣 douban

Spark

Spark: Cluster Computing with Working Sets. Matei Zaharia, Mosharaf Chowdhury, Michael J. Franklin, Scott Shenker, Ion Stoica. *USENIX HotCloud 2010*. June 2010.

1 Resilient Distributed Datasets: A Fault-Tolerant Abstraction for In-Memory Cluster Computing. Matei Zaharia, Mosharaf Chowdhury, Tathagata Das, Ankur Dave, Justin Ma, Murphy McCauley, Michael J. Franklin, Scott Shenker, Ion Stoica.*Technical Report UCB/EECS-2011-82*. July 2011.

Spark

豆瓣 douban

Spark

- 优点

Spark

- 优点
  - 简洁，Scala, 10000 locs

豆瓣 douban

Spark

- 优点
  - 简洁，Scala, 10000 locs
  - 迭代计算更友好

豆瓣 douban

Spark

- 优点
  - 简洁，Scala, 10000 locs
  - 迭代计算更友好
- 缺点

Spark

- 优点
  - 简洁，Scala, 10000 locs
  - 迭代计算更友好
- 缺点
  - 学习 Scala

豆瓣 douban

Spark

- 优点
  - 简洁，Scala, 10000 locs
  - 迭代计算更友好
- 缺点
  - 学习 Scala
  - 不能复用积累的 Python / C代码

豆瓣 douban

DPark 诞生

DPark 诞生

- Spark 的 Python 克隆

豆瓣 douban

DPark 诞生

- Spark 的 Python 克隆
  - 拥抱Python

豆瓣 douban

DPark 诞生

- Spark 的 Python 克隆
  - 拥抱Python
- 第 7 天，基本可用

豆瓣douban

DPark 诞生

- Spark 的 Python 克隆
  - 拥抱Python
- 第 7 天，基本可用
  - 比Hive 快 15 倍 :-)

豆瓣douban

DPark 诞生

- Spark 的 Python 克隆
  - 拥抱Python
- 第 7 天，基本可用
  - 比Hive 快 15 倍 :-)
- 持续改进，性能优化

豆瓣douban

DPark 诞生

- Spark 的 Python 克隆
  - 拥抱Python
- 第 7 天，基本可用
  - 比Hive 快 15 倍 :-)
- 持续改进，性能优化
  - 取代Hadoop

豆瓣 douban

DPark 计算模型

DPark 计算模型

- RDD
  - 弹性分布式数据集(Resilient Distributed Dataset)
  - 只读，可拆分
  - 惰性，需要时才计算，可完全重建

DPark 计算模型

- RDD
  - 弹性分布式数据集(Resilient Distributed Dataset)
  - 只读，可拆分
  - 惰性，需要时才计算，可完全重建

豆瓣 douban

构造RDD

构造RDD

- 数组

构造RDD

- 数组
  - dpark.parallelize(range(100), 10)

构造RDD

- 数组
  - dpark.parallelize(range(100), 10)
- 分布式文件系统中的文件

构造RDD

- 数组
  - dpark.parallelize(range(100), 10)
- 分布式文件系统中的文件
  - dpark.textFile(‘/mfs/weblog/’)

构造 RDD

构造 RDD

- RDD 经过变换得到新的RDD

构造 RDD

- RDD 经过变换得到新的RDD
  - 变换是惰性的

构造 RDD

- RDD 经过变换得到新的RDD
  - 变换是惰性的

构造 RDD

- RDD 经过变换得到新的RDD
  - 变换是惰性的

FileRDD

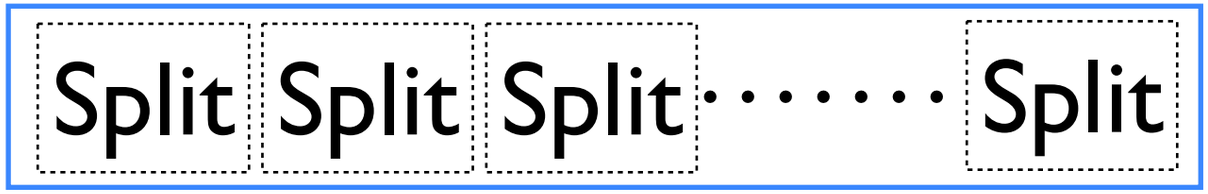

↓ map()

构造 RDD

- RDD 经过变换得到新的RDD
  - 变换是惰性的

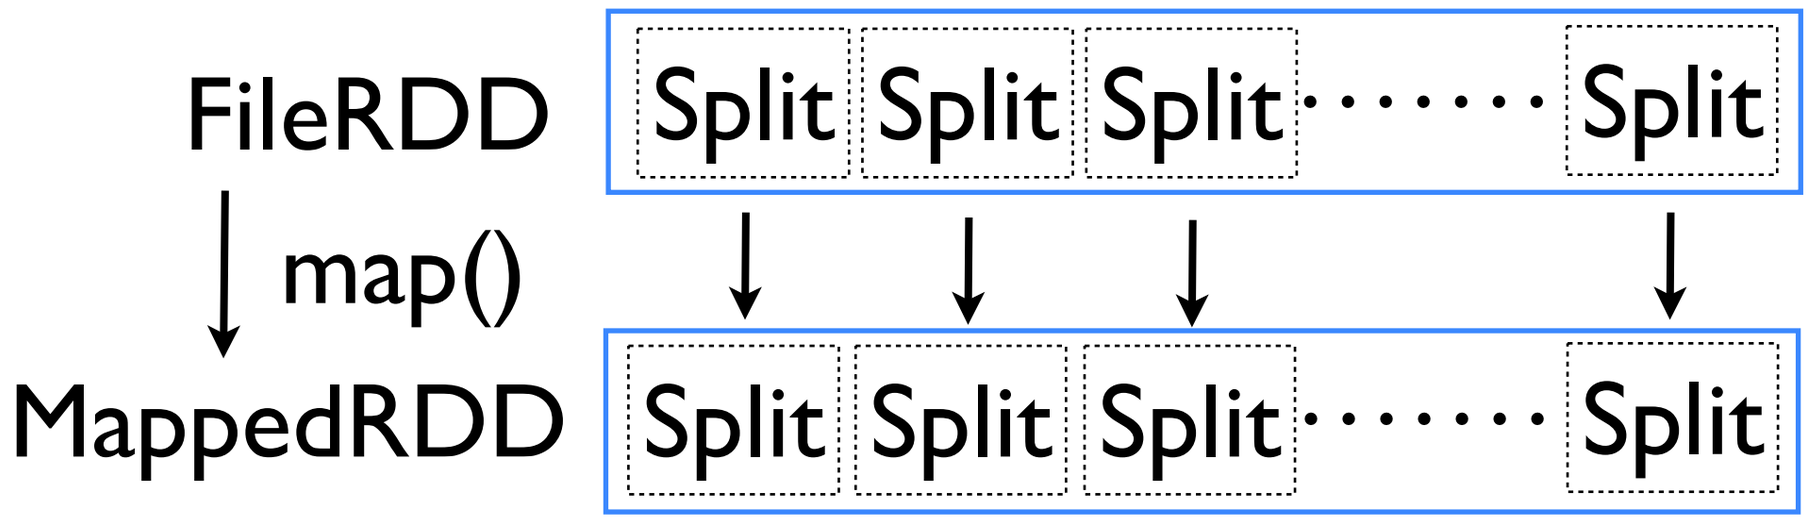

构造 RDD

- RDD 经过变换得到新的RDD
  - 变换是惰性的

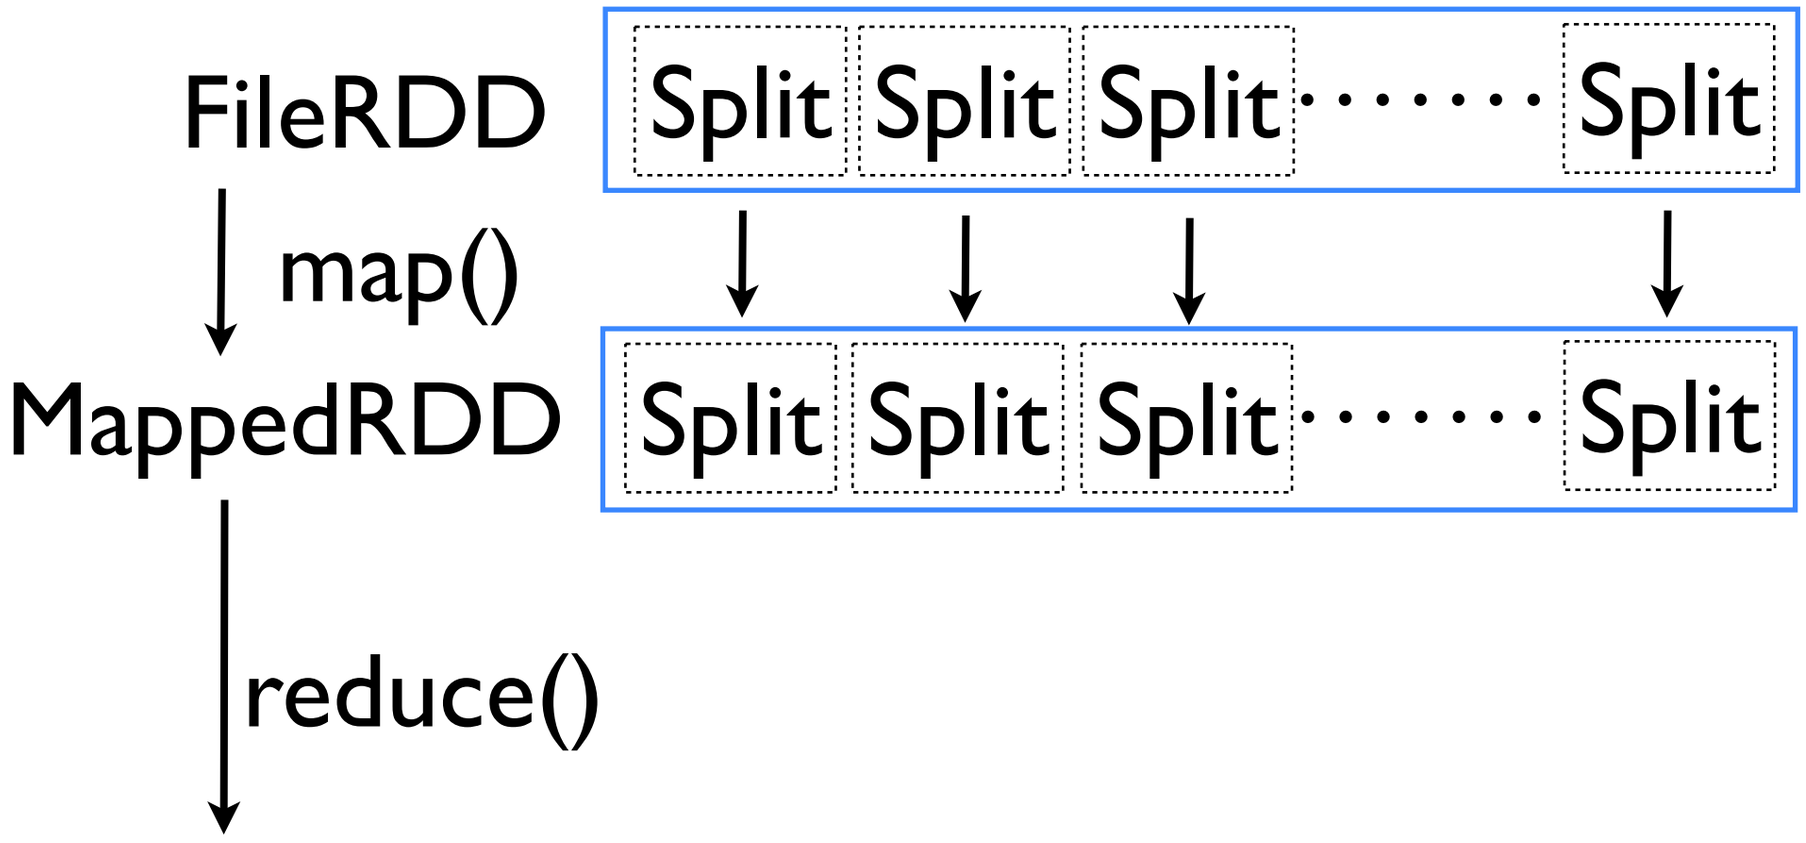

构造 RDD

- RDD 经过变换得到新的RDD
  - 变换是惰性的

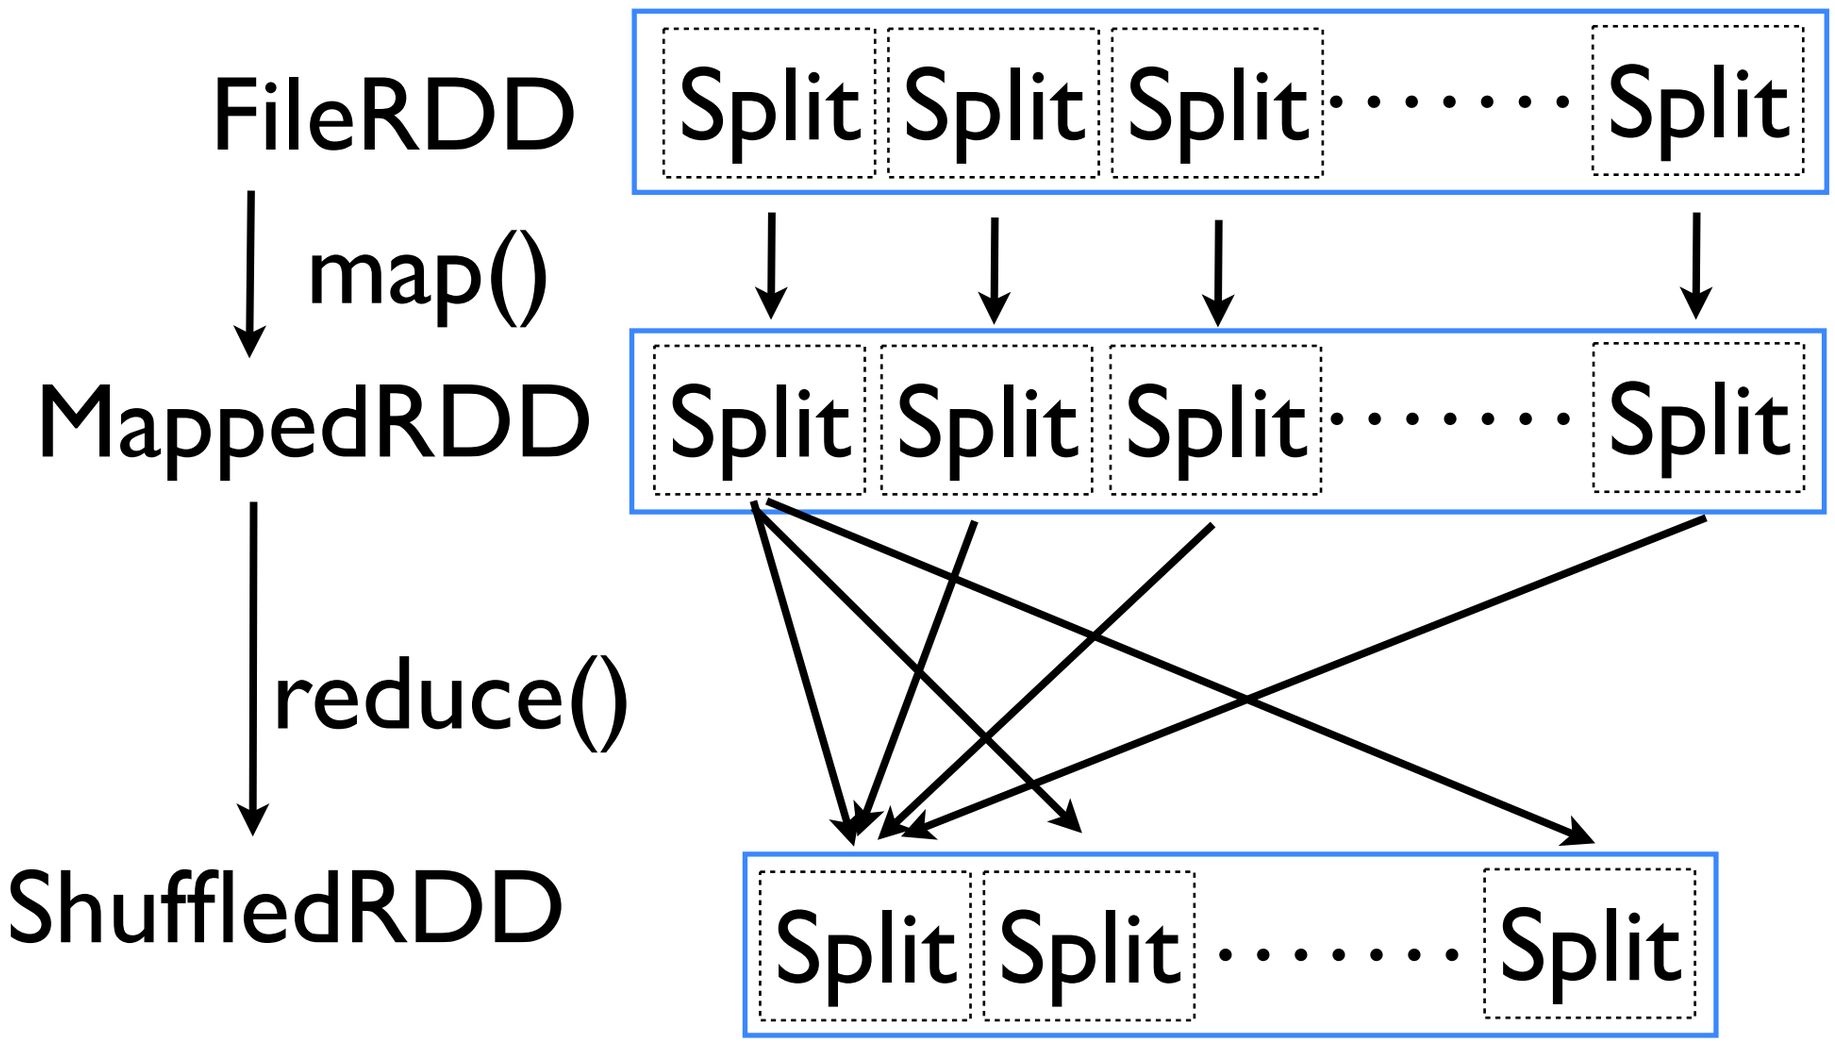

RDD计算过程

- 由操作发起计算
  - count(), collect(),save()
- 根据依赖关系生成 DAG
- 划分Stage
  - Shuffle, Result

RDD计算过程

- 由操作发起计算
  - count(), collect(),save()
- 根据依赖关系生成 DAG
- 划分Stage
  - Shuffle, Result

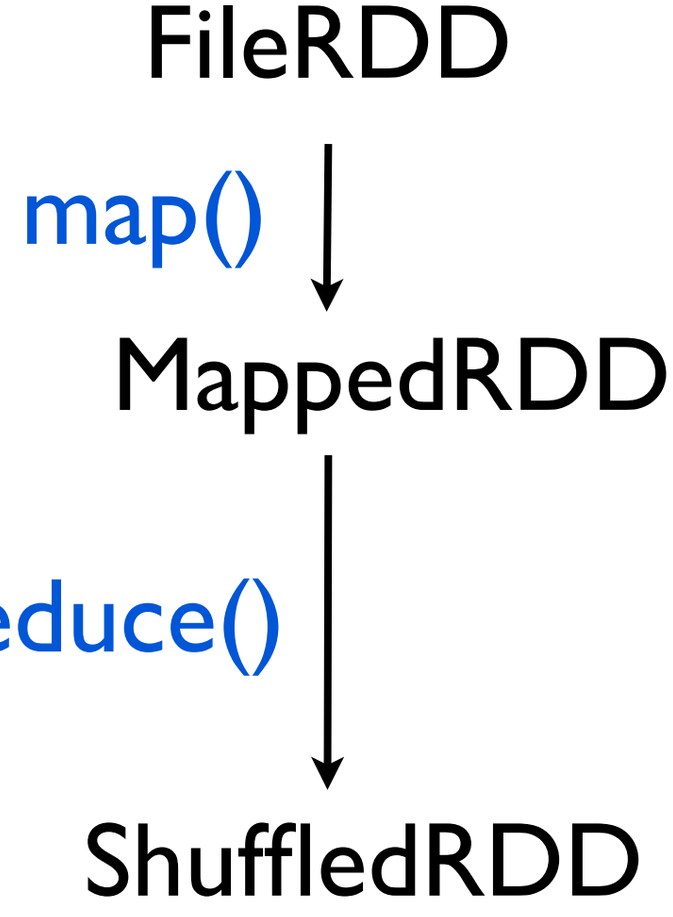

RDD计算过程

- 由操作发起计算
  - count(), collect(),save()
- 根据依赖关系生成 DAG
- 划分Stage
  - Shuffle, Result

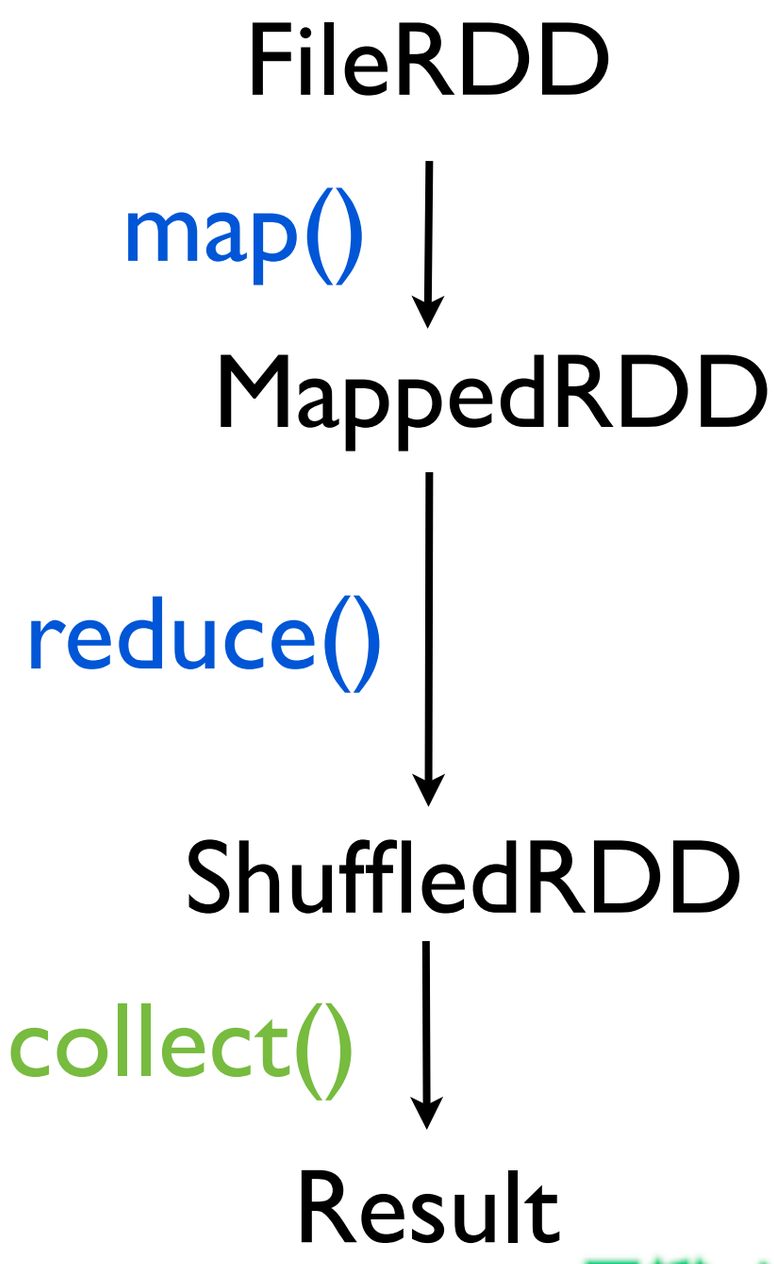

豆瓣douban

RDD计算过程

- 由操作发起计算
  - count(), collect(),save()
- 根据依赖关系生成 DAG
- 划分Stage
  - Shuffle, Result

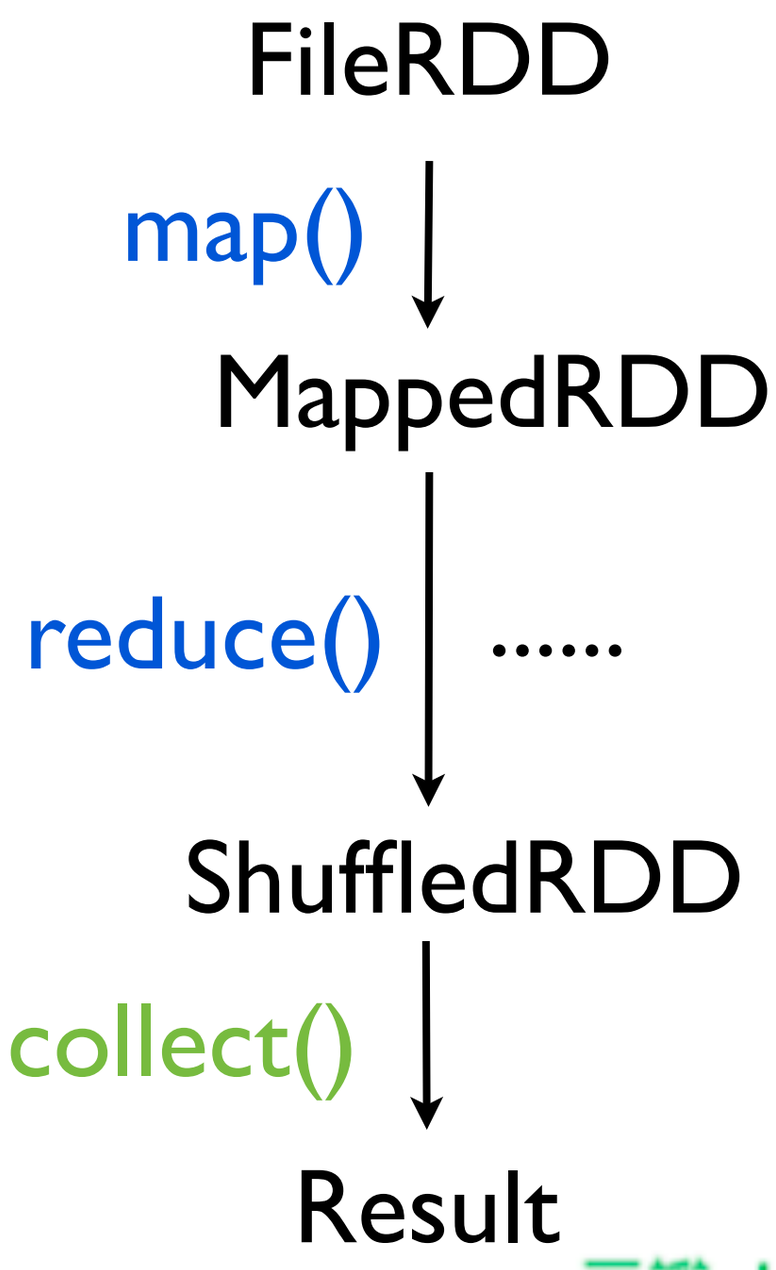

RDD计算过程

- 由操作发起计算
  - count(), collect(),save()
- 根据依赖关系生成 DAG
- 划分Stage
  - Shuffle, Result

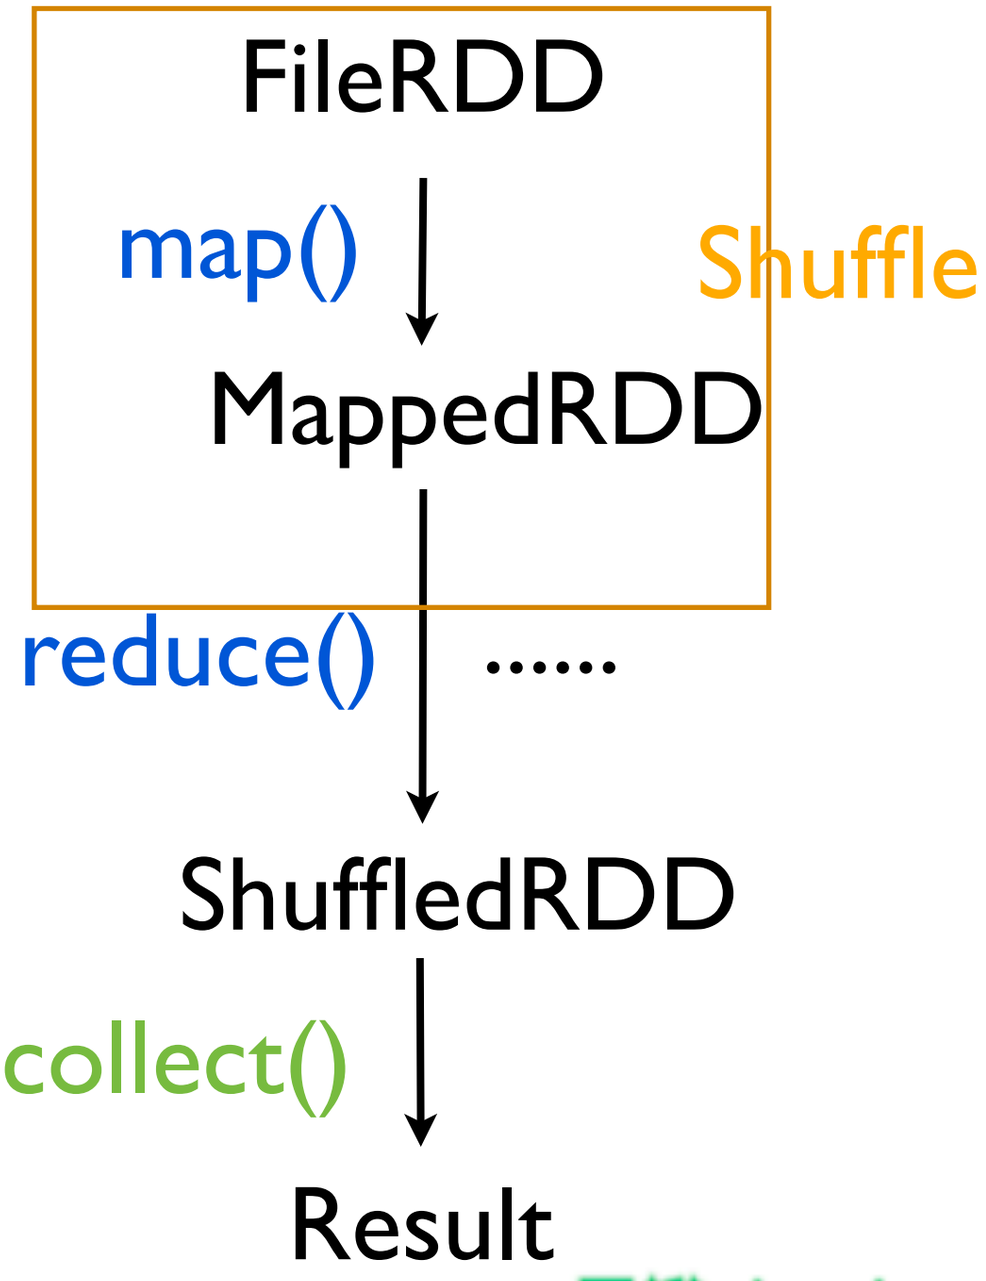

RDD计算过程

- 由操作发起计算
  - count(), collect(),save()
- 根据依赖关系生成 DAG
- 划分Stage
  - Shuffle, Result

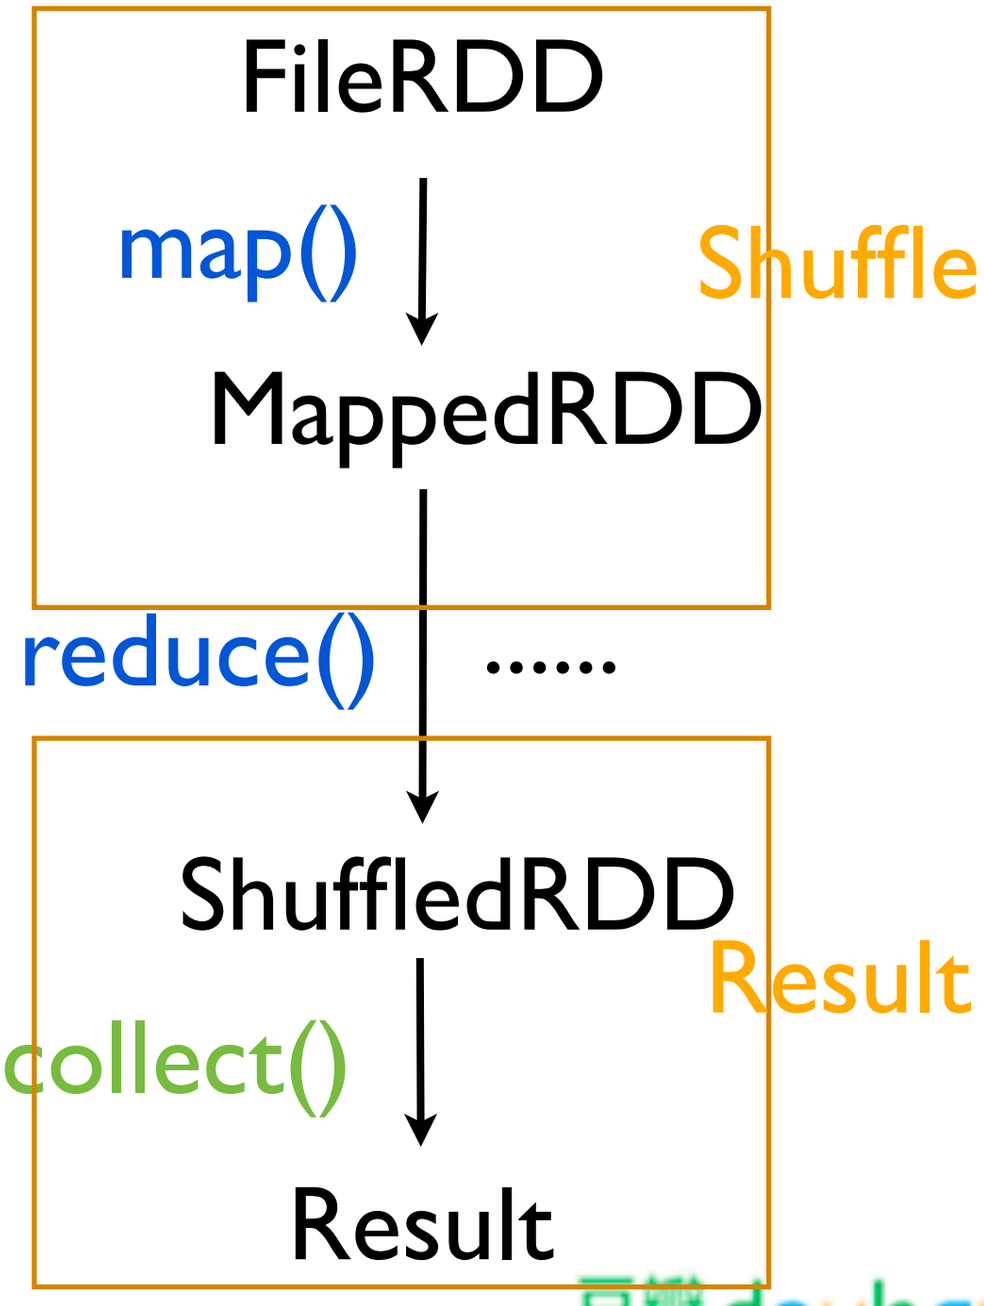

RDD计算过程

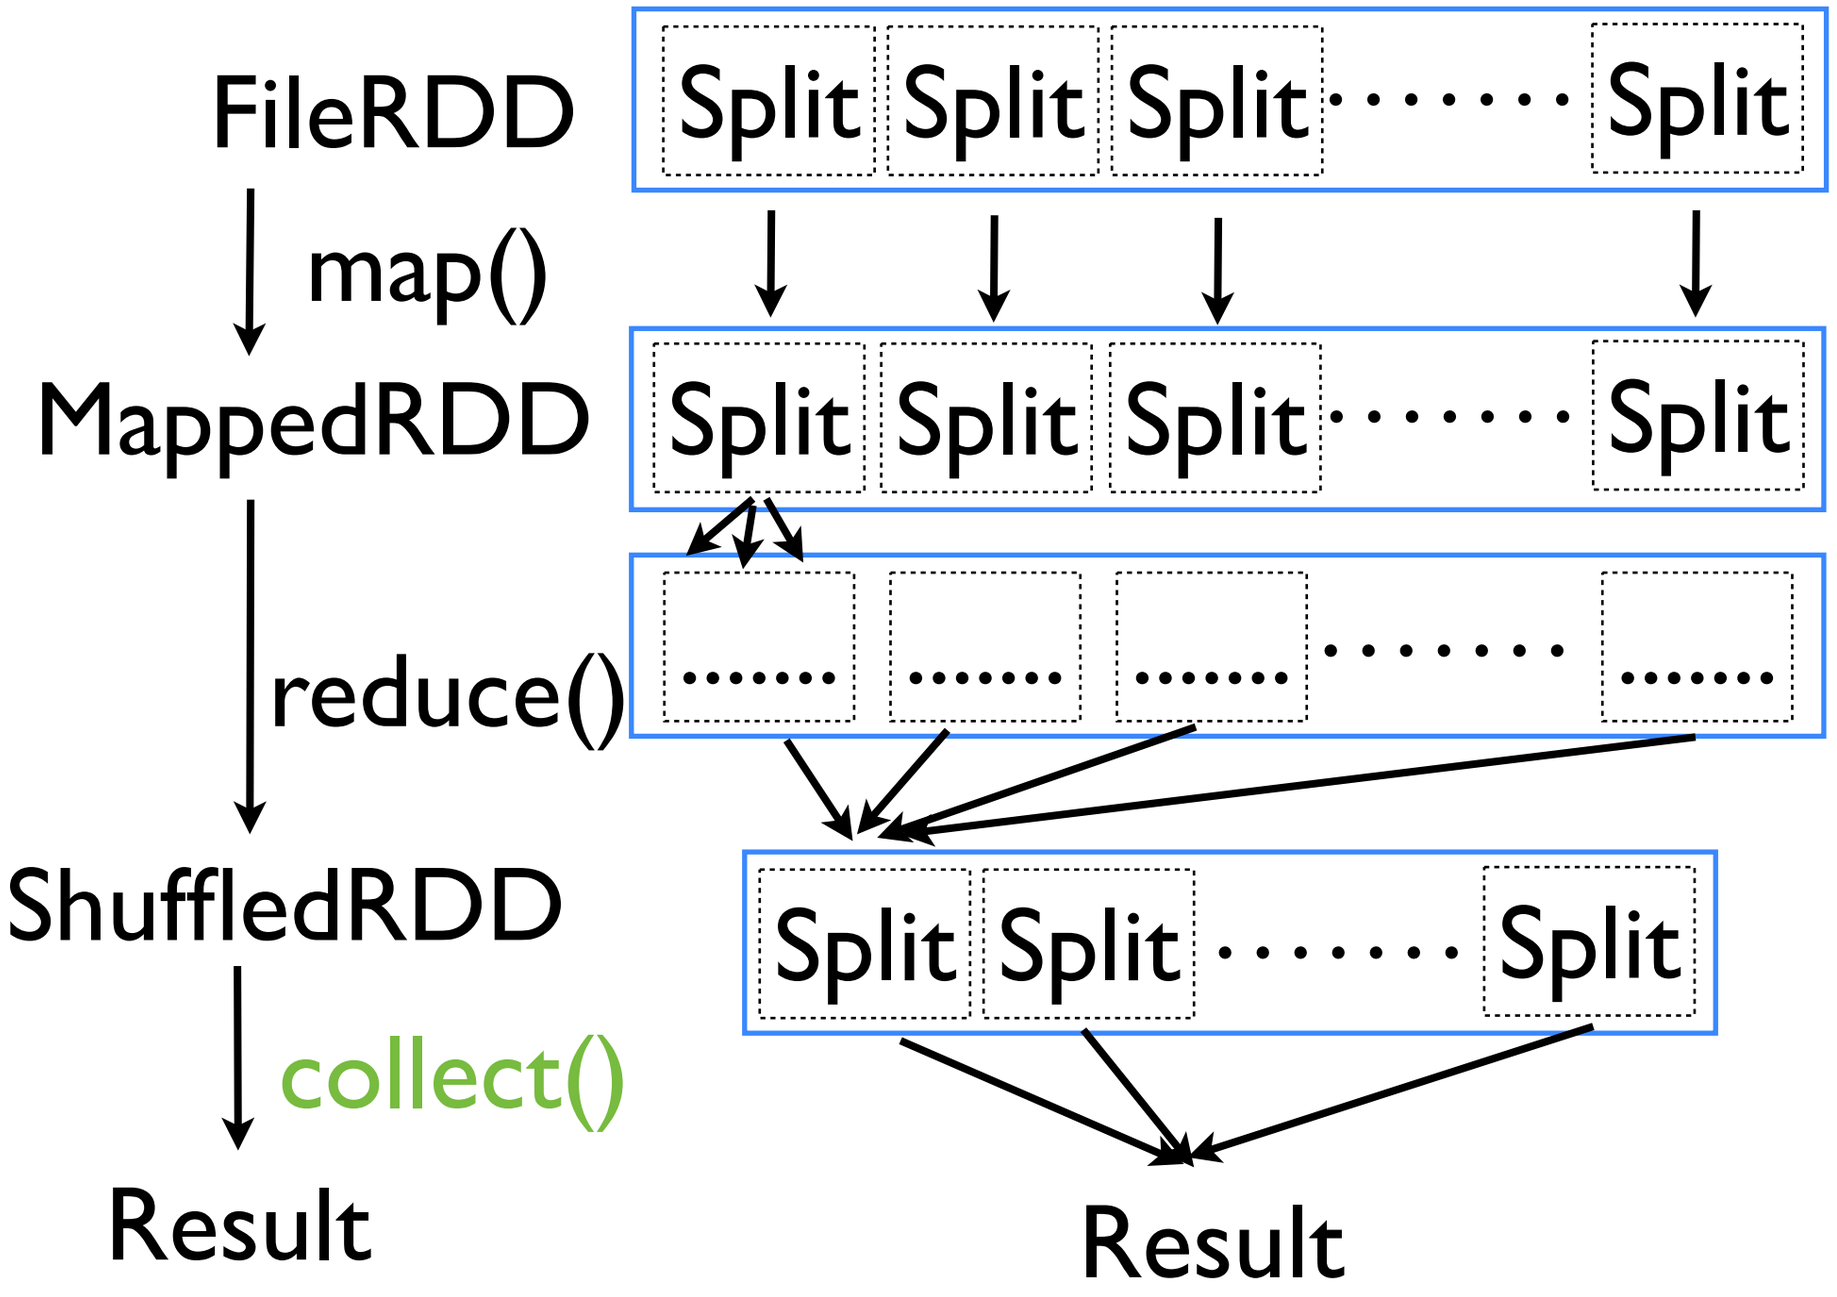
FileRDD
Split
Split
Split
Split
map()
MappedRDD
Split
Split
Split
Split
reduce()
ShuffledRDD
Split
Split
Split
collect()
Result
Result

RDD计算过程

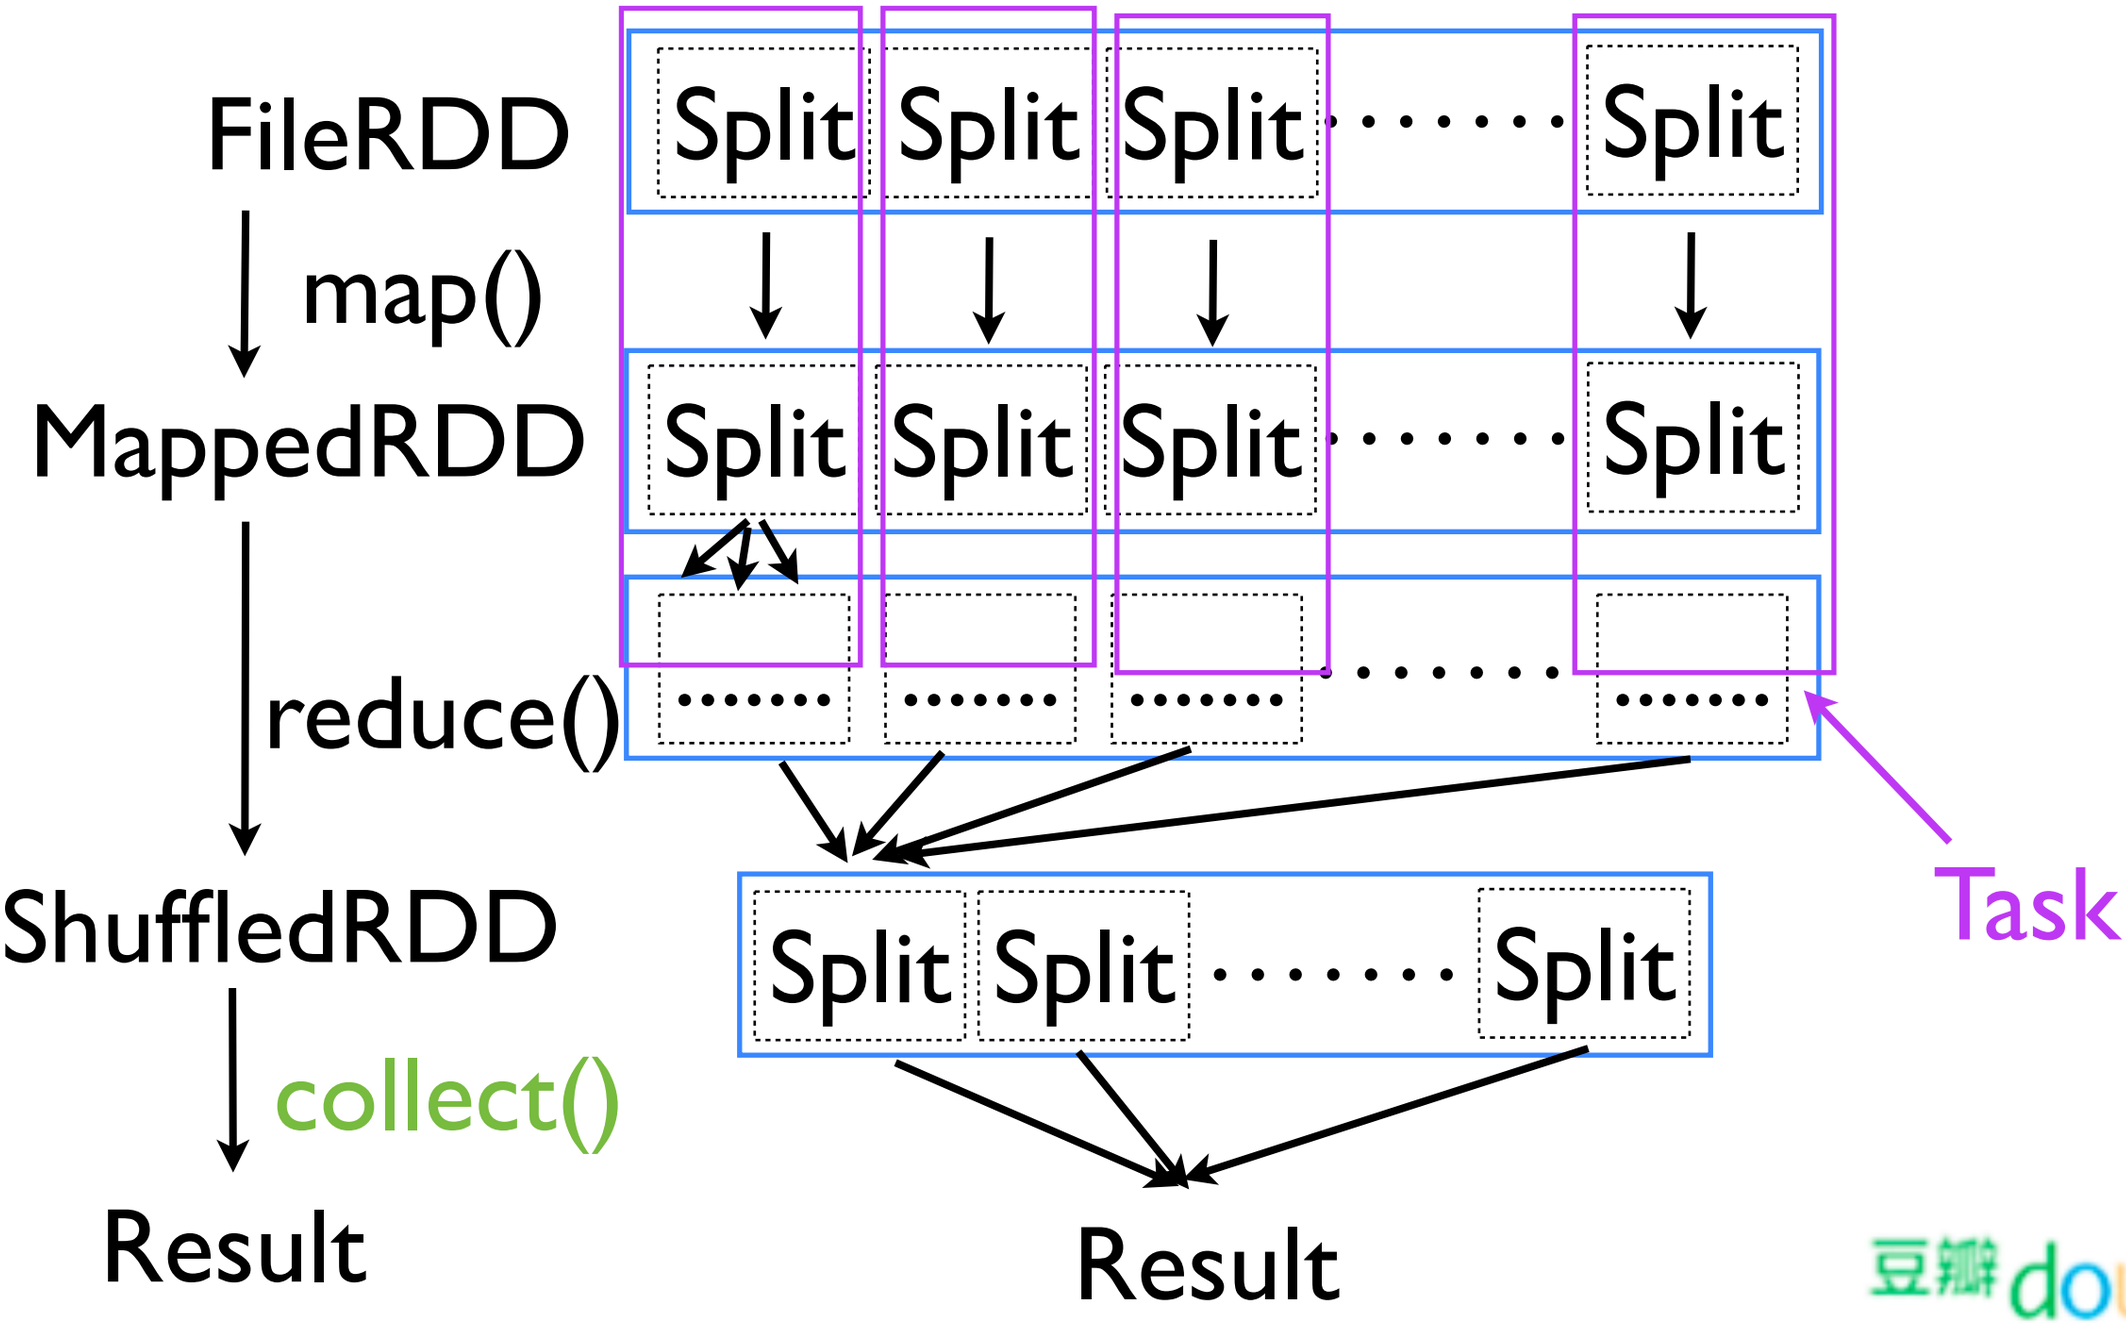
FileRDD
map()
MappedRDD
reduce()
ShuffledRDD
collect()
Result
Split
Split
Split
Split
Split
Split
Split
Split
Split
Split
Split
Split
Task
Result

DPark on Mesos

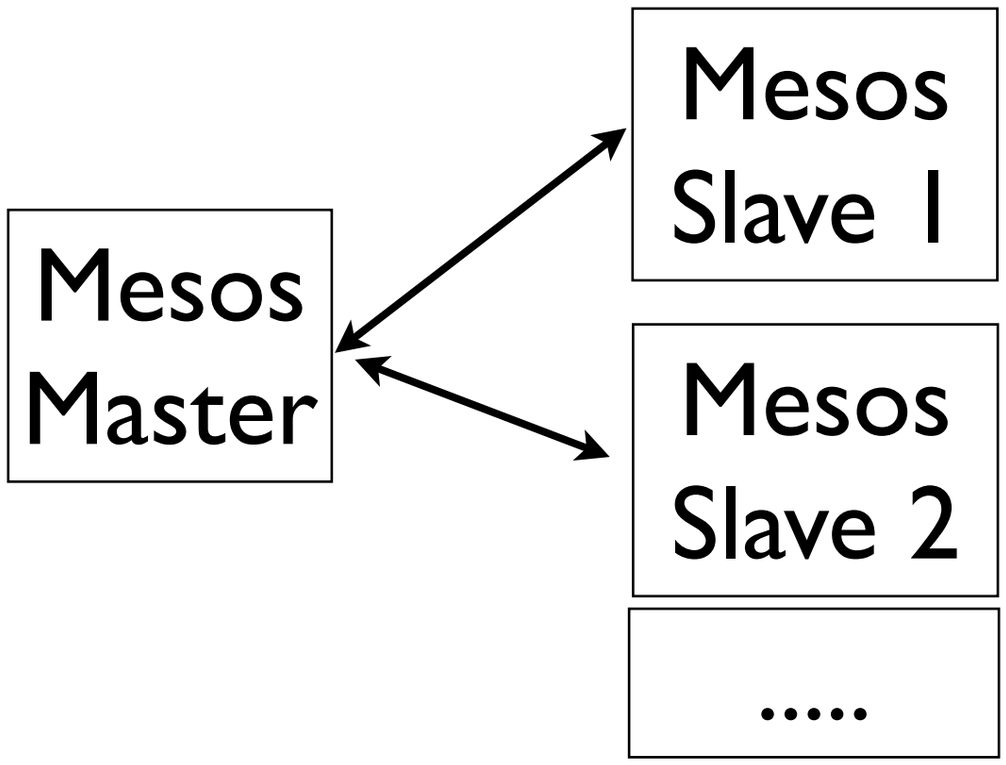

DPark on Mesos

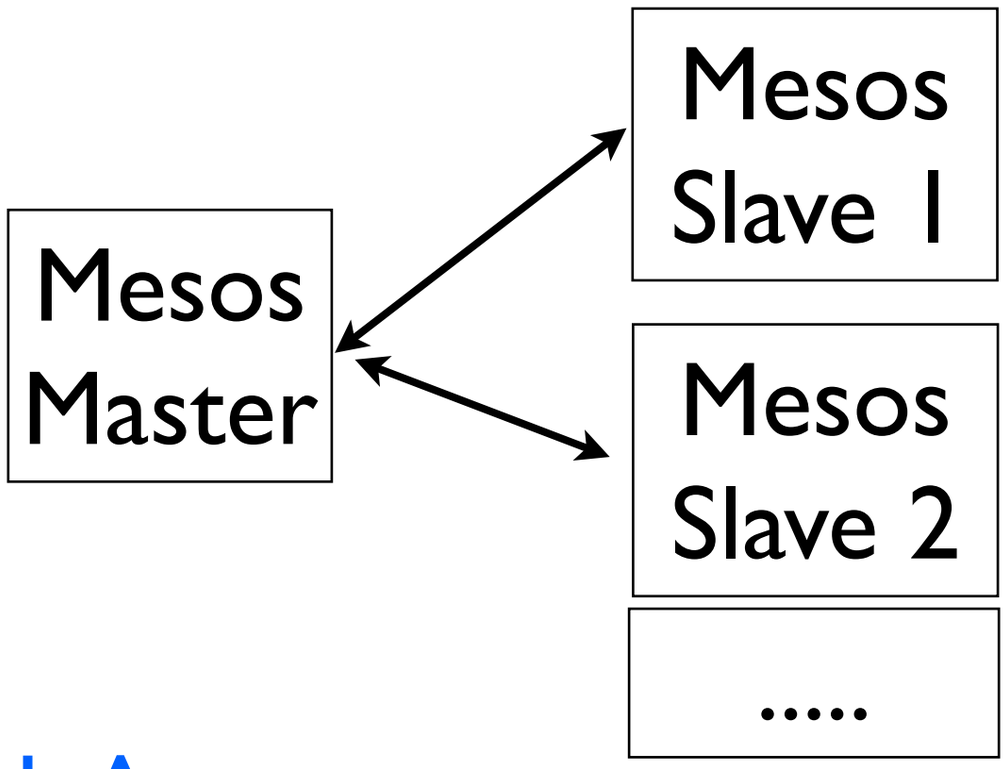

DPark App

DPark on Mesos

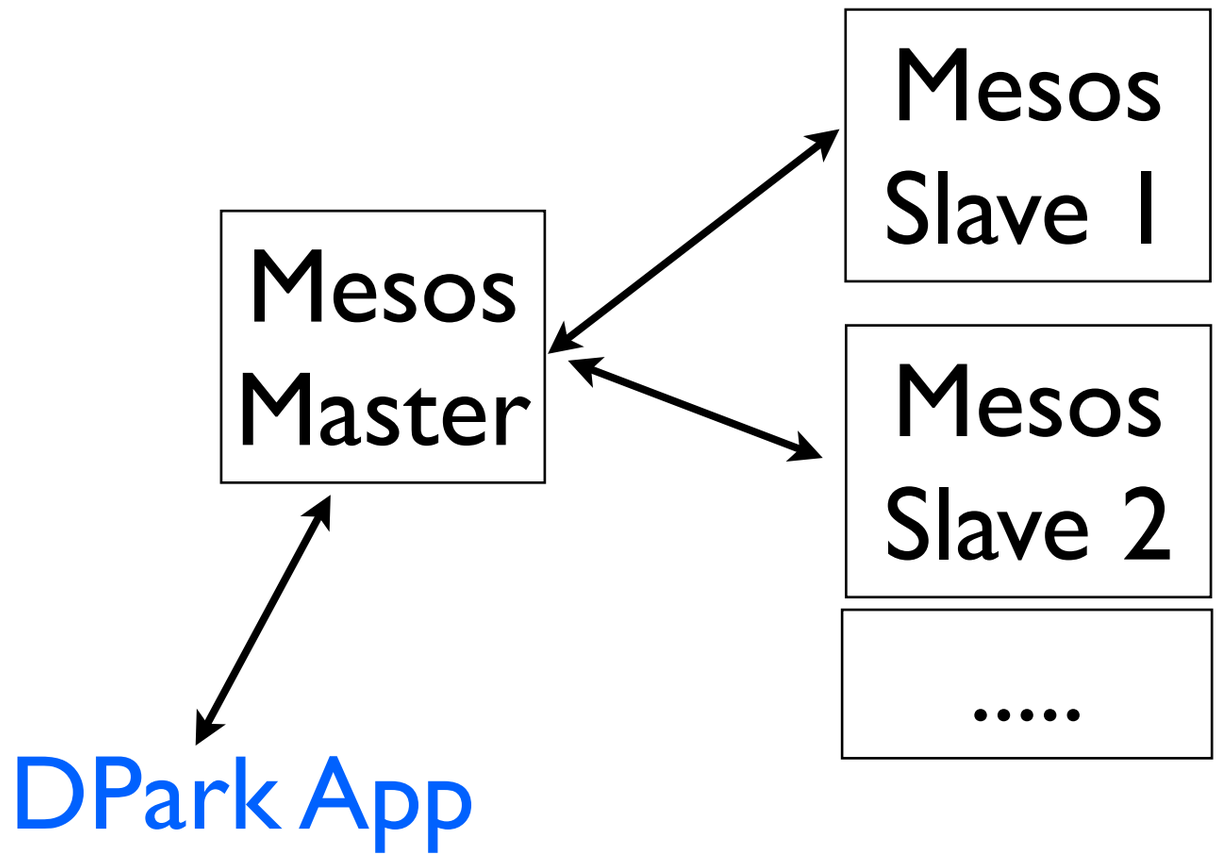

DPark on Mesos

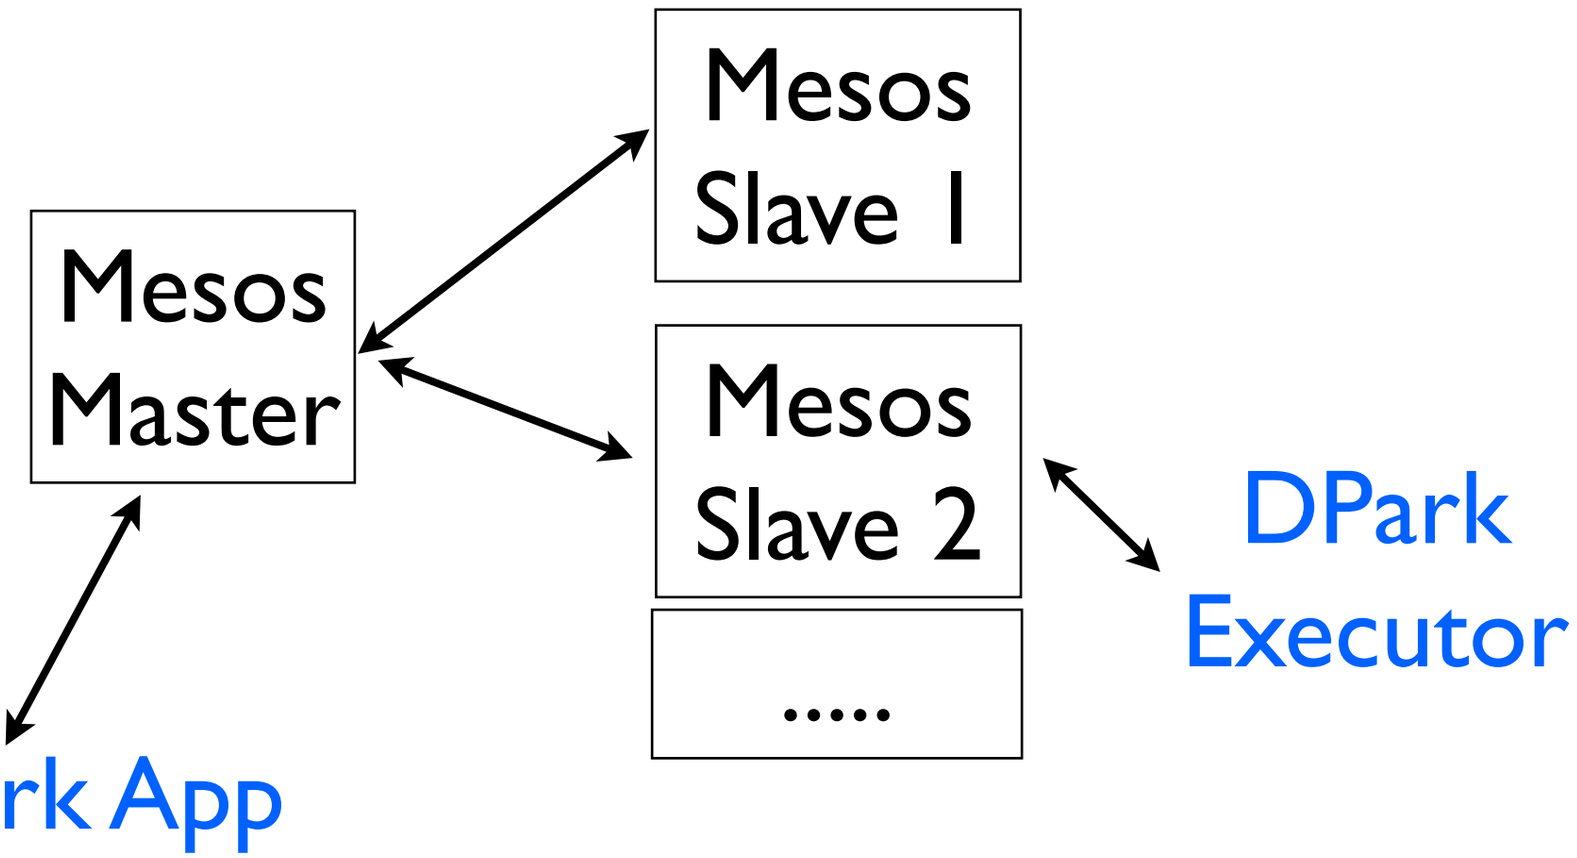

豆瓣 douban

DPark on Mesos

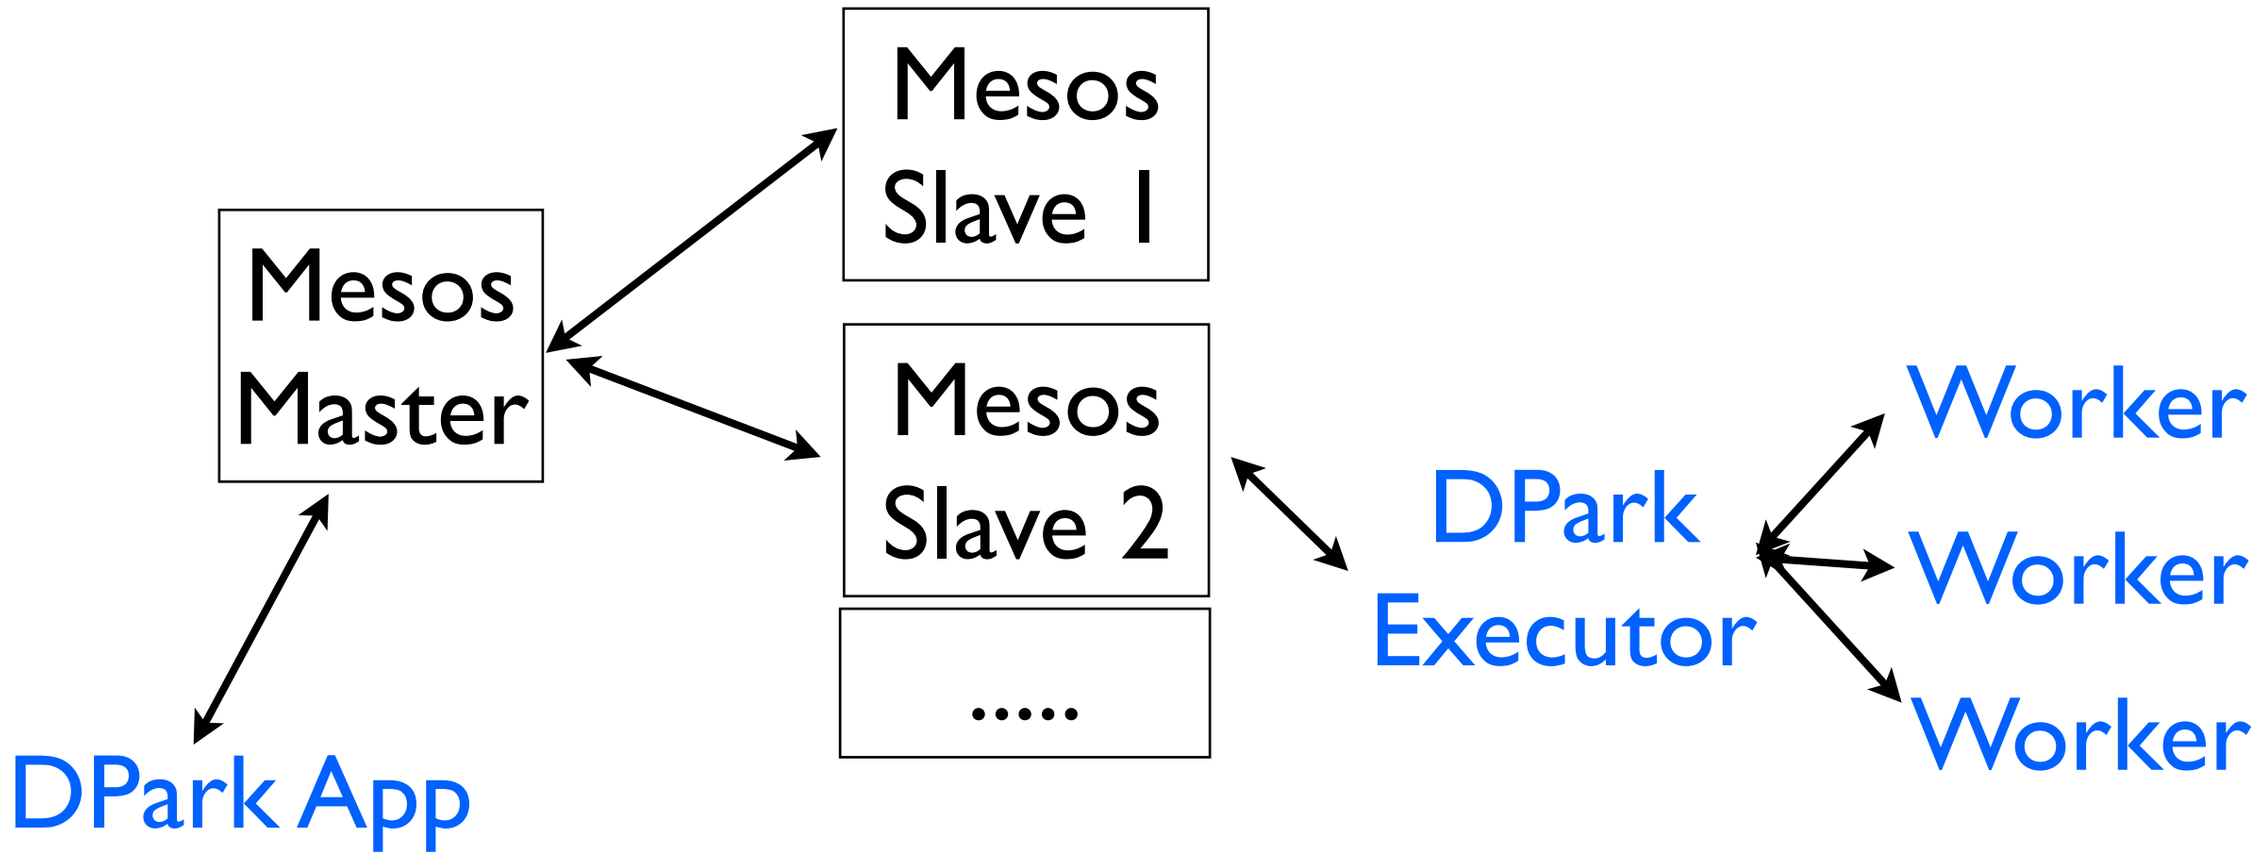

DPark on Mesos

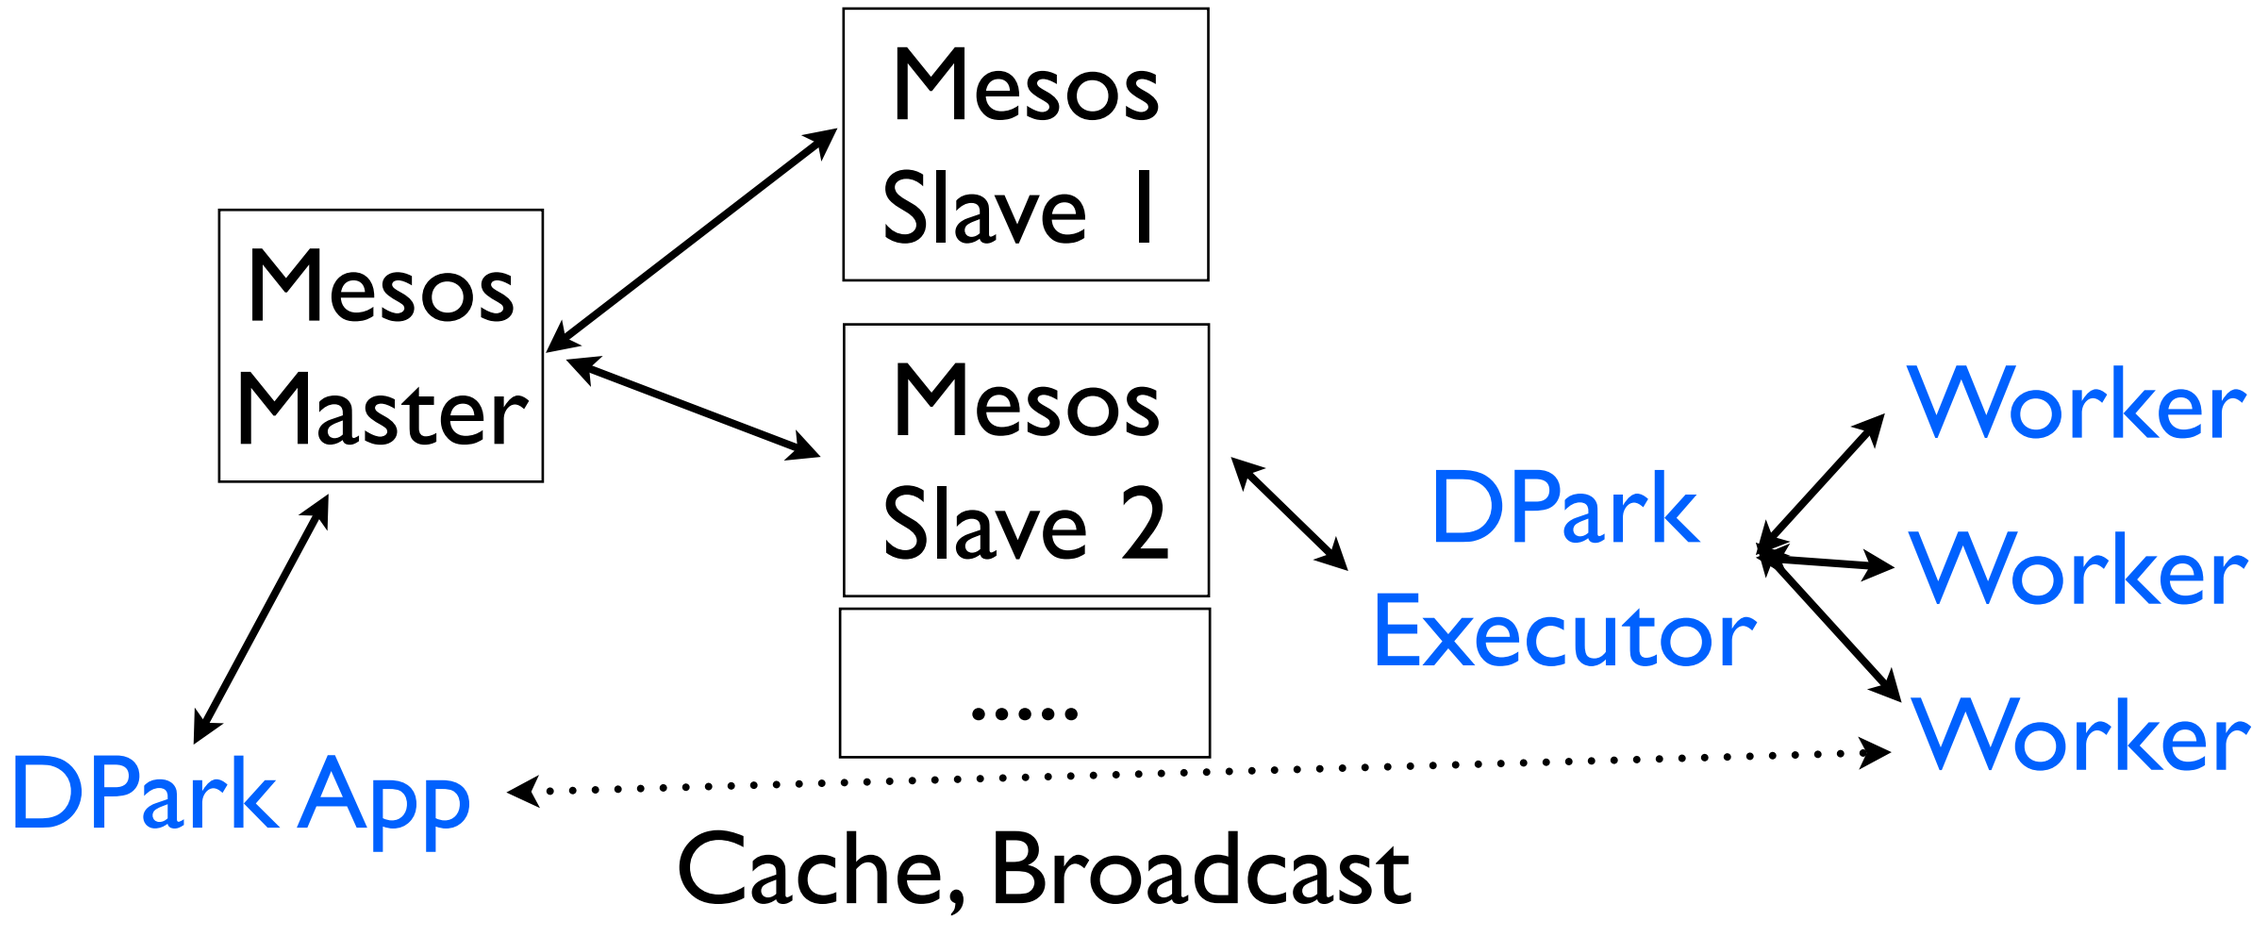

Word Count

豆瓣 douban

Word Count

```
files = dpark.textFile(‘word.txt')
```

Word Count

```
files = dpark.textFile(‘word.txt')

words = files.flatMap(str.split).map(lambda x:(x,1))
```

豆瓣douban

Word Count

```
files = dpark.textFile('word.txt')

words = files.flatMap(str.split).map(lambda x:(x,1))

cnt = words.reduceByKey(add).collectAsMap()
```

豆瓣 douban

Word Count

```
files = dpark.textFile(‘word.txt')

words = files.flatMap(str.split).map(lambda x:(x,1))

cnt = words.reduceByKey(add).collectAsMap()
```

```
$ python wordcount.py
```

豆瓣 douban

Word Count

```
files = dpark.textFile(‘word.txt')

words = files.flatMap(str.split).map(lambda x:(x,1))

cnt = words.reduceByKey(add).collectAsMap()
```

```
$ python wordcount.py
$ python wordcount.py -m mesos
```

豆瓣 douban

交互使用

```
>>> dpark = DparkContext('mesos')
>>> d = dpark.parallelize(range(1000), 10)
>>> print d.reduce(add)
[dpark] 2011-12-02 17:10:47,670 Got a job with 10 tasks
[dpark] 2011-12-02 17:11:04,926 Finished 5 (progress: 1/10)
in 6.64s
.....
499500
```

豆瓣 douban

K-Means 算法

K-Means 算法

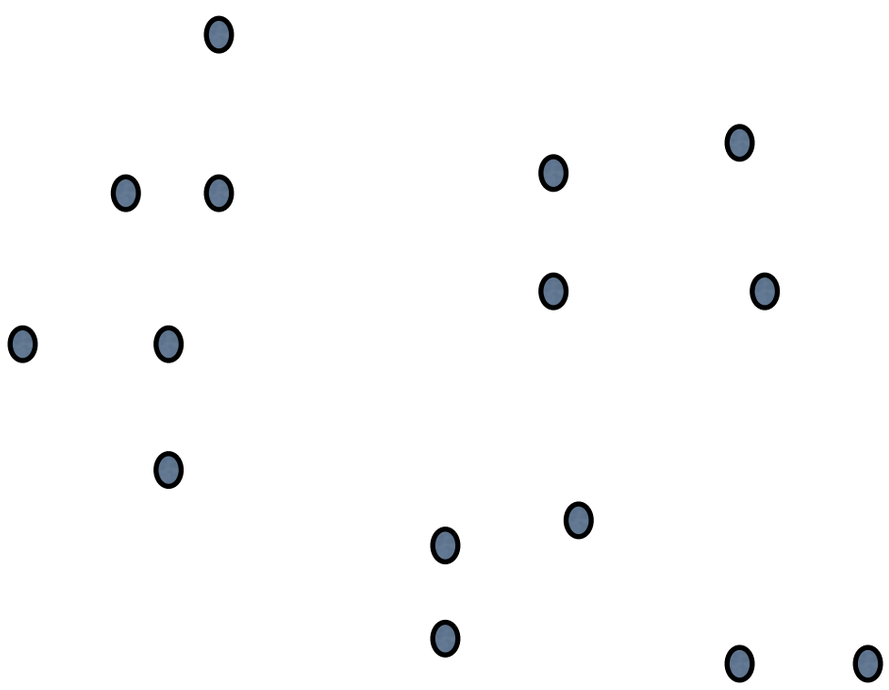

K-Means 算法

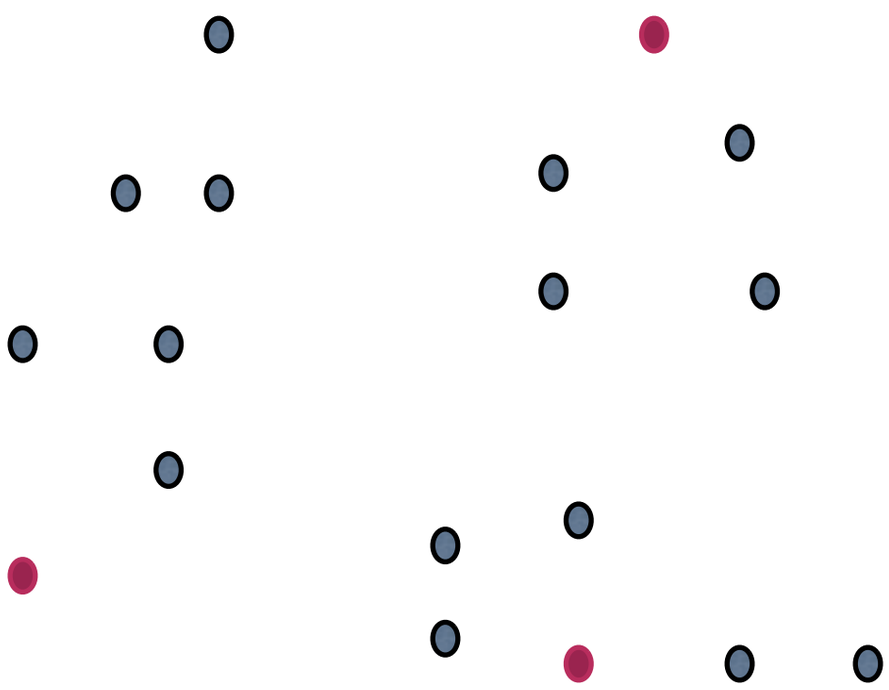

K-Means 算法

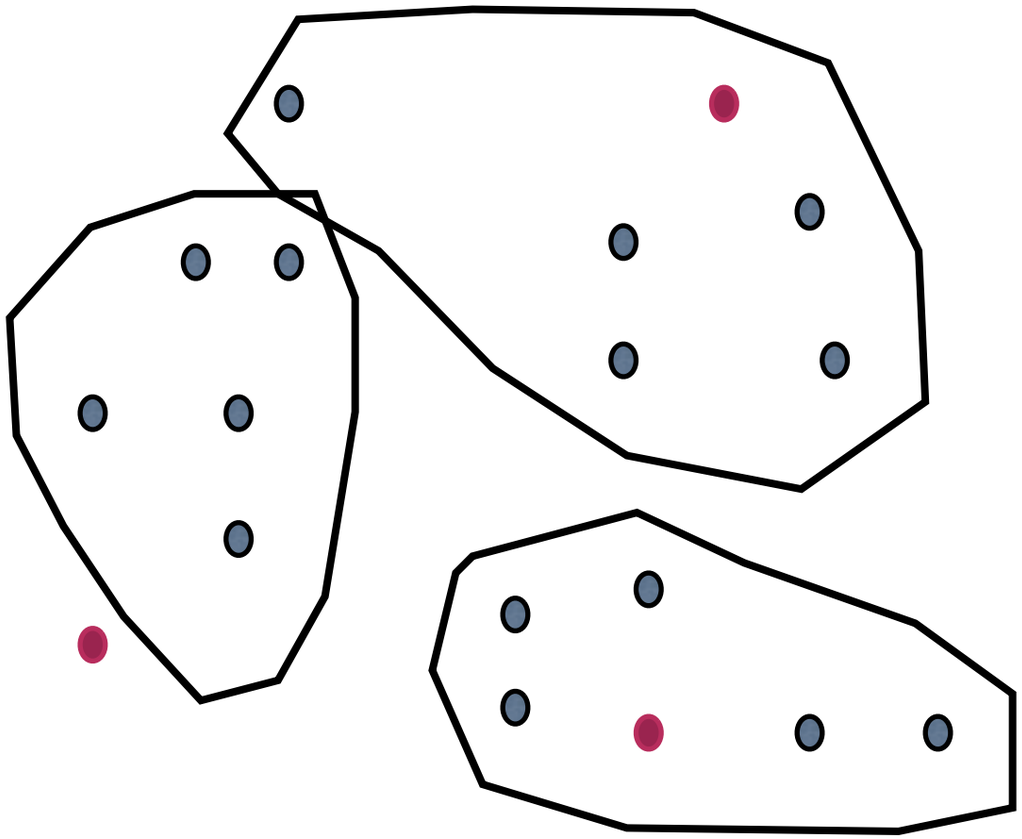

K-Means 算法

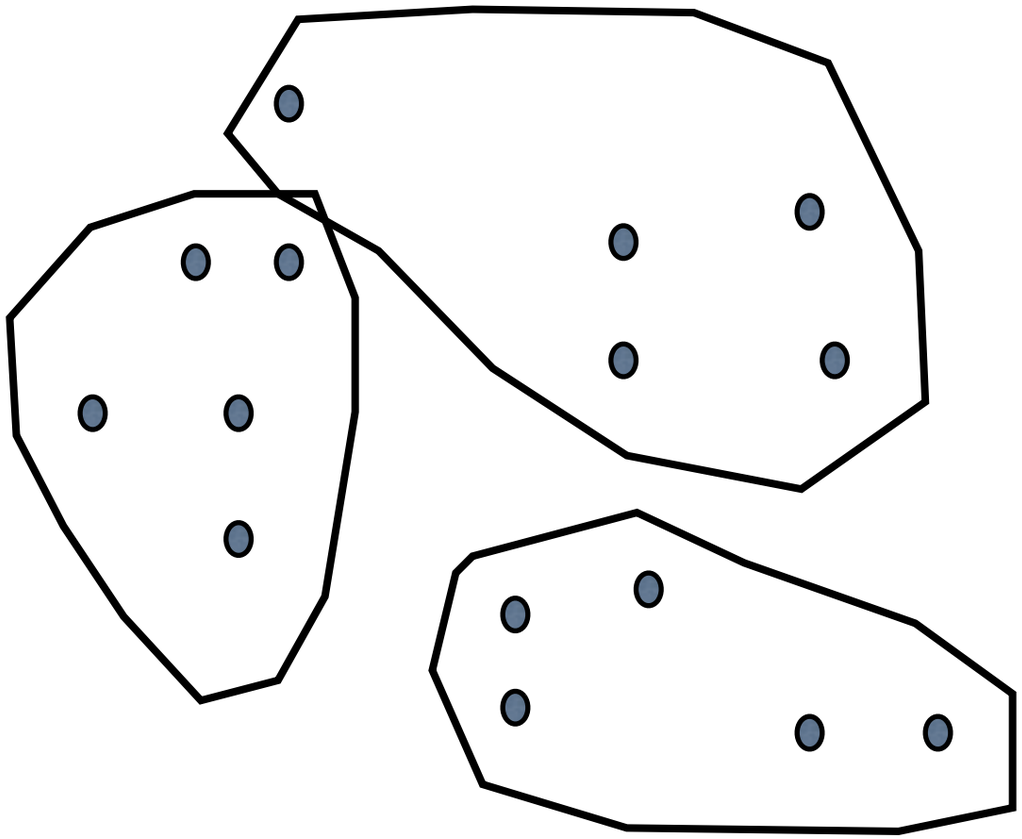

K-Means 算法

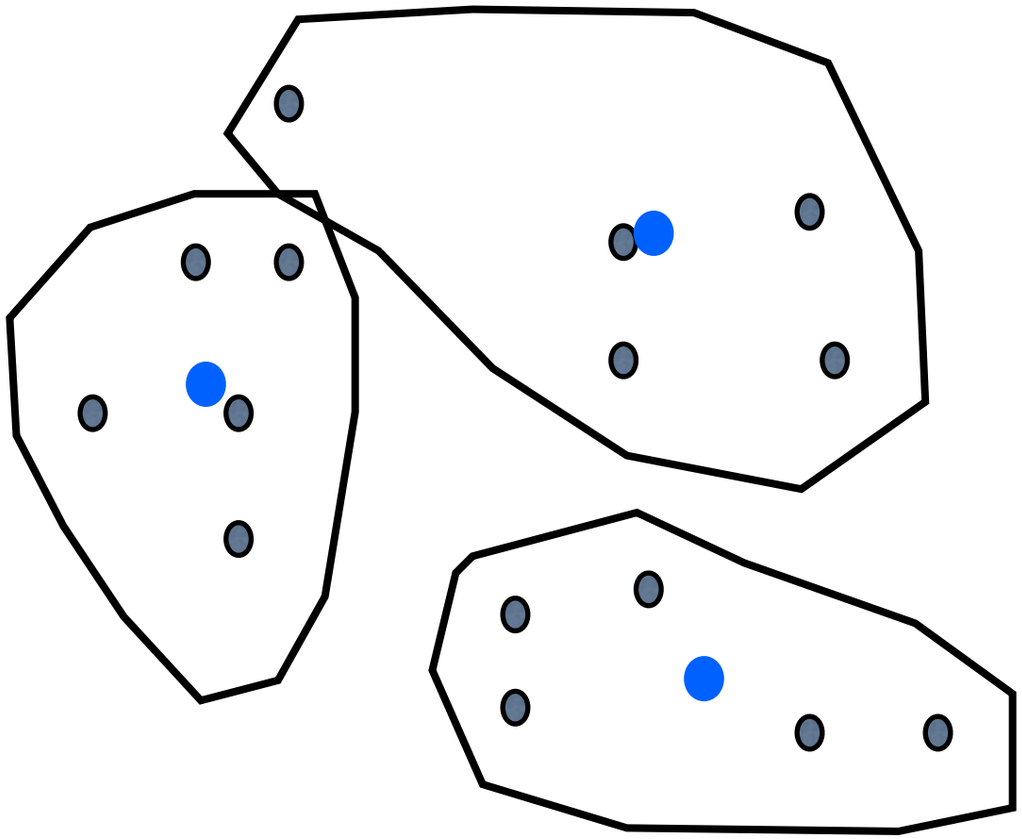

K-Means 算法

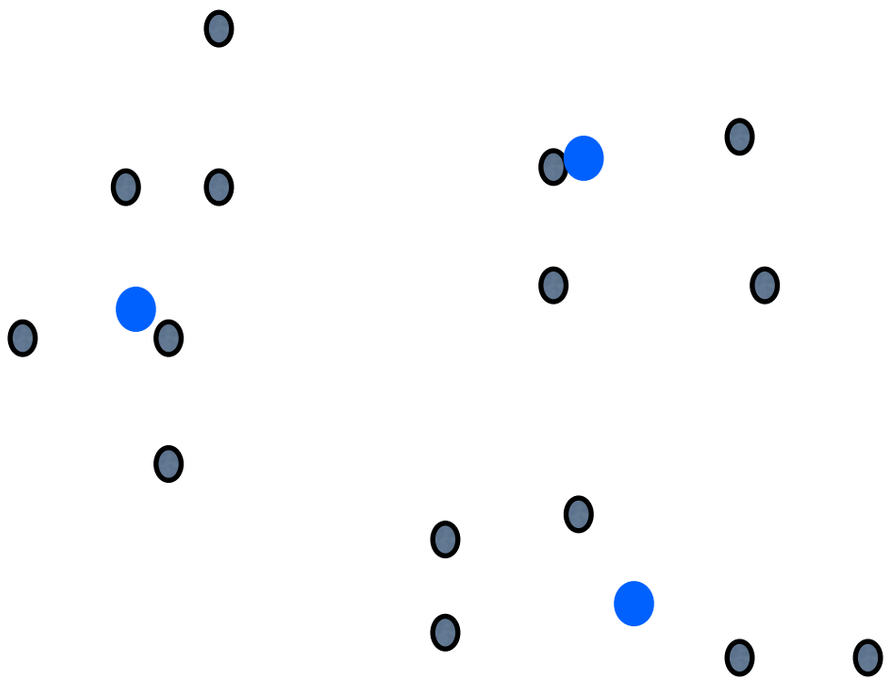

K-Means 算法

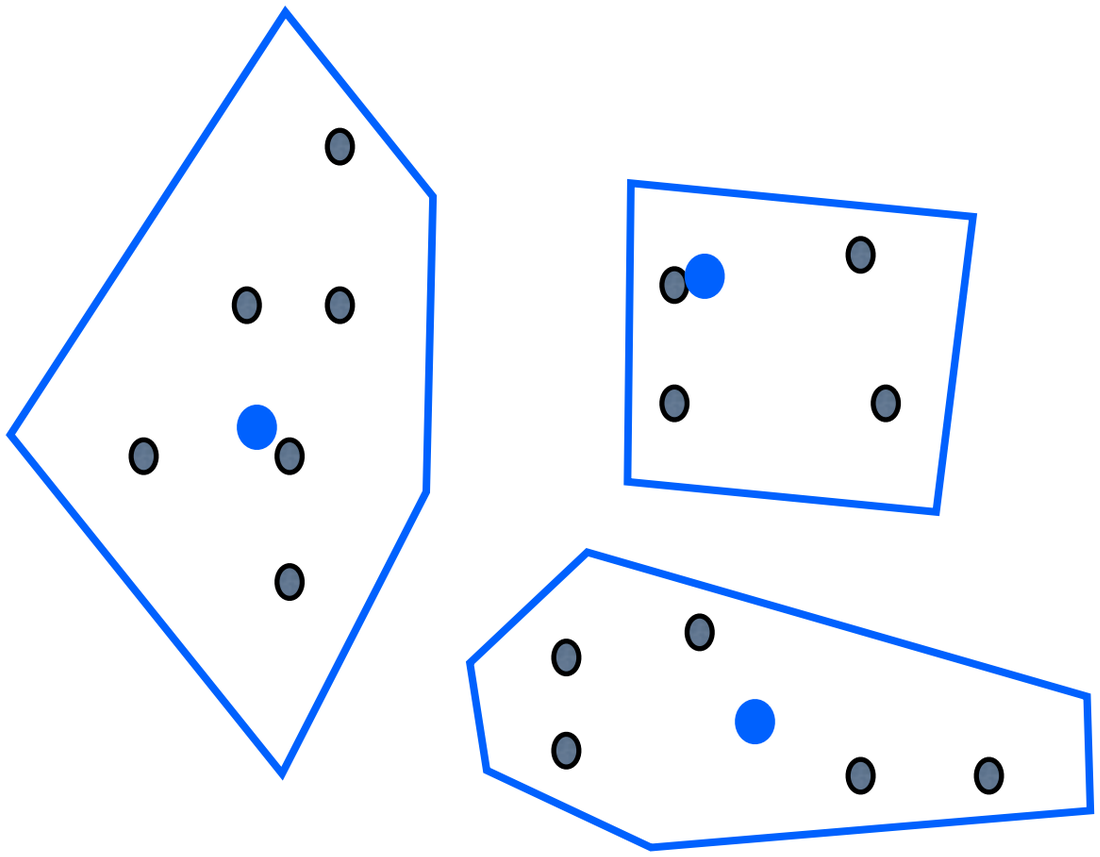

K-Means

豆瓣 douban

K-Means

```
points = dpark.textFile('kmeans.txt').map(parseVector).cache()
```

豆瓣 douban

K-Means

```
points = dpark.textFile('kmeans.txt').map(parseVector).cache()
centers = [Vector() for i in range(K)]
```

豆瓣 douban

K-Means

```
points = dpark.textFile('kmeans.txt').map(parseVector).cache()
centers = [Vector() for i in range(K)]
for it in range(N):
```

K-Means

```
points = dpark.textFile('kmeans.txt').map(parseVector).cache()
centers = [Vector() for i in range(K)]
for it in range(N):
    ps = points.map(lambda p:(closestCenter(p, centers), (p, 1)))
```

豆瓣 douban

K-Means

```
points = dpark.textFile('kmeans.txt').map(parseVector).cache()
centers = [Vector() for i in range(K)]
for it in range(N):
    ps = points.map(lambda p:(closestCenter(p, centers), (p, 1)))
    ncenters = ps.reduceByKey(mergePoints).collectAsMap()
```

豆瓣 douban

K-Means

```
points = dpark.textFile('kmeans.txt').map(parseVector).cache()
centers = [Vector() for i in range(K)]
for it in range(N):
    ps = points.map(lambda p:(closestCenter(p, centers), (p, 1)))
    ncenters = ps.reduceByKey(mergePoints).collectAsMap()
    centers = ncenters.values()
```

豆瓣 douban

相似度计算

```
def cos((a, b)):
    return cos_sim(a, b)

ratings = spark.csvFile('r.csv').map(parse).groupByKey()
blocks = ratings.glom().cache()
sims = blocks.cartesion(blocks).flatMap(cos)
final = sims.reduceByKey(lambda x,y:x+y)
```

豆瓣 douban

相似度计算

```
def cos((a, b)):
    return cos_sim(a, b)

ratings = spark.csvFile('r.csv').map(parse).groupByKey()
blocks = ratings.glom().cache()
sims = blocks.cartesion(blocks).flatMap(cos)
final = sims.reduceByKey(lambda x,y:x+y)
```

可以通过C实现核心算法来提升性能

豆瓣douban

DPark 的性能

豆瓣 douban

DPark 的性能

- 比Hadoop慢

DPark 的性能

- 比Hadoop慢
- 基本够用

豆瓣 douban

DPark 的性能

- 比Hadoop慢
- 基本够用
- 优化方向

豆瓣 douban

DPark 的性能

- 比Hadoop慢
- 基本够用
- 优化方向
  - C 扩展

DPark 的性能

- 比Hadoop慢
- 基本够用
- 优化方向
  - C 扩展
  - PyPy

总结

总结

- 简单，灵活，友好
- 更好地支持迭代计算
- 在中小规模下可以取代Hadoop

豆瓣 douban

DPark 的未来

豆瓣 douban

DPark 的未来

- 开源

DPark 的未来

- 开源
- 完善文档

DPark 的未来

- 开源
  - 完善文档
- 进一步提升性能和可扩展性

Thank you !

Question ???

豆瓣 douban