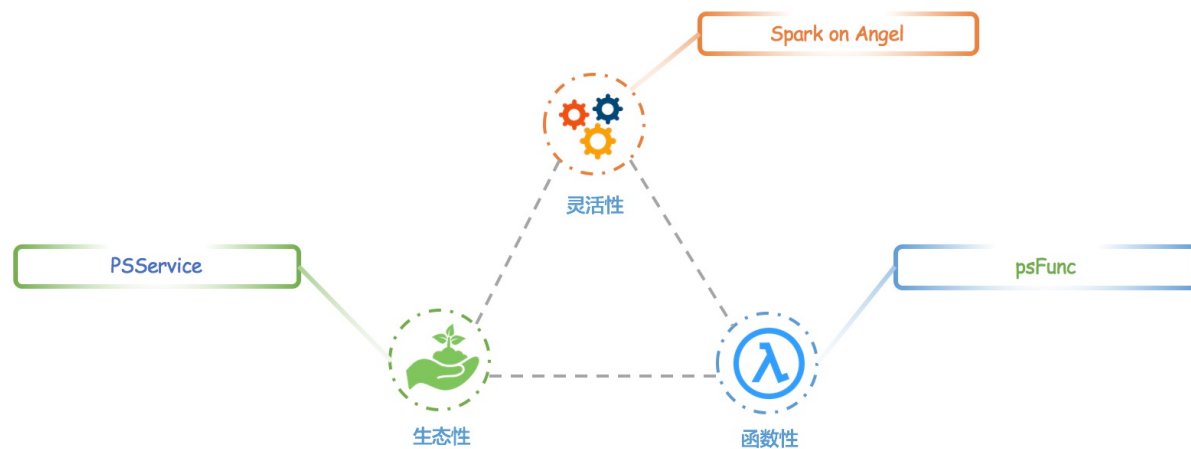


## 进击的巨人

# 基于Angel和Spark Streaming的高维度Online Learning

Andymhuang ( 黄明 )

腾讯——数据平台部



一个基于参数服务器（Parameter Server）理念的高性能分布式机器学习平台

<https://github.com/tencent/angel>

整体介绍

Spark on Angel

性能和比较

Angel的架构



Online Learning with Angel

开源与展望



**源起**



# 分布式机器学习



# 机器学习的目标




$$\arg \min_{\vec{\theta}} f(\vec{x}, y, \vec{\theta}) = J(\{\vec{x}_i, y_i\}_{i=1}^N; \vec{\theta})$$

模型


数据

参数


# 分布式的三种经典范式



MapReduce




MPI



Parameter Server


# 腾讯的现网需求



寻找满足十亿级维度的工业级的分布式机器学习平台



# Spark机器学习的瓶颈



- Driver成为参数汇总的单点瓶颈，难以支撑大规模模型及数据
- 十亿级维度的模型训练，实际应用中降维处理
- Executor之间相互等待，整体效率不高

# 其它机器学习平台



苹果收购了




实验室级别，而且融资后不开源了



转深度学习CNTK



针对性太强



转深度学习TensorFlow



- 能支持十亿级别维度的模型训练
- 基于Matrix/Vector的模型自动切分和管理，兼顾稀疏和稠密两种格式
- 提供多种同步控制机制（BSP/SSP/ASP）

**工业级别可用的  
参数服务器**

### 丰富的机器学习及 数学计算库

- 集成LR（ADMM-LR），SVM，KMeans，LDA，MF，GBDT等机器学习算法
- 多种优化方法，包括ADMM，OWLQN，LBFGS和GD
- 支持多种损失函数、评估指标，包含L1、L2正则项算法

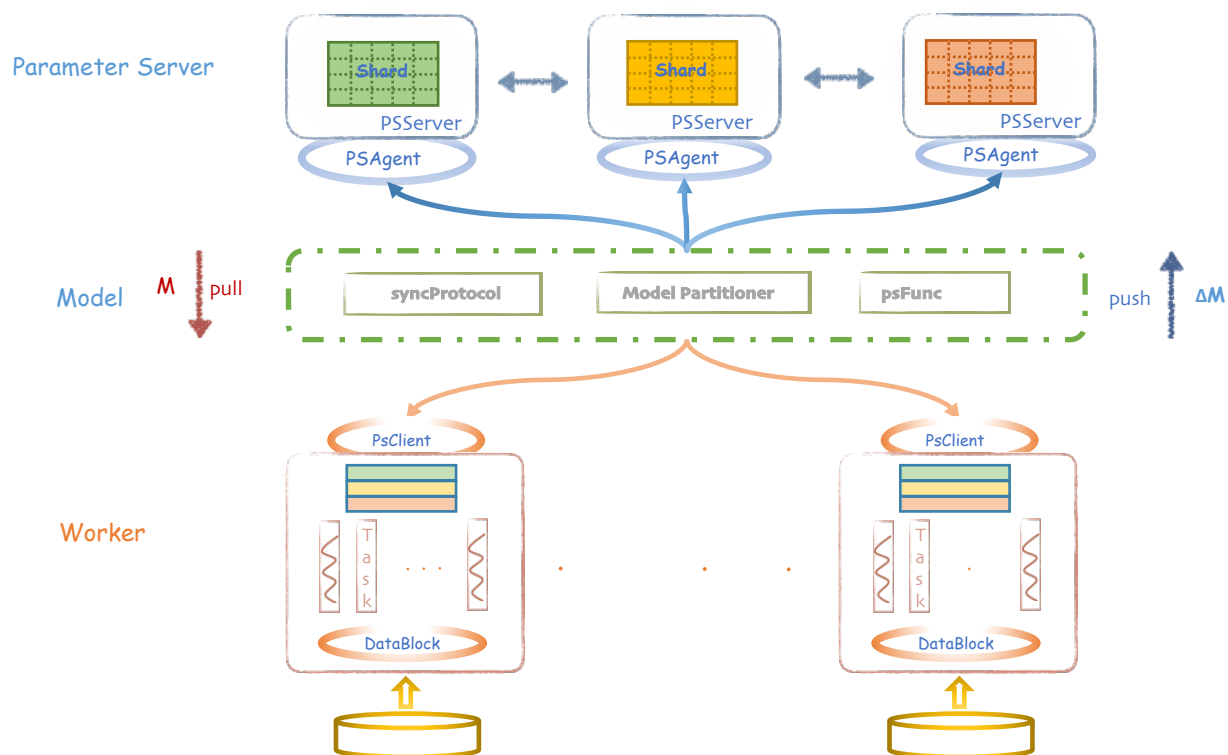
- 基于PSModel的机器学习友好接口，以Model为核心编程
- 支持Spark on Angel，Spark代码小量改动就可以运行Angel之上
- 灵活的psFunc，便于复杂算法的开发，实现模型并行

**友好的  
用户编程接口**

# Angel的架构

---

# Angel的系统框架



# 核心抽象

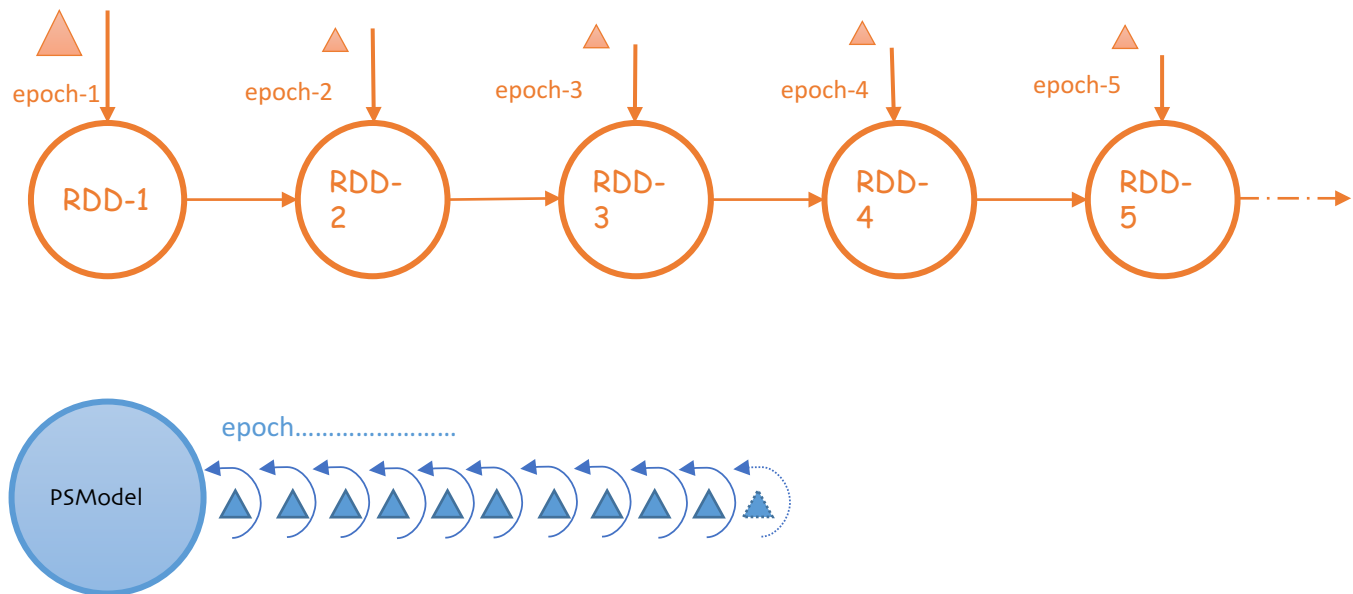
Mapper  
Reducer

RDD

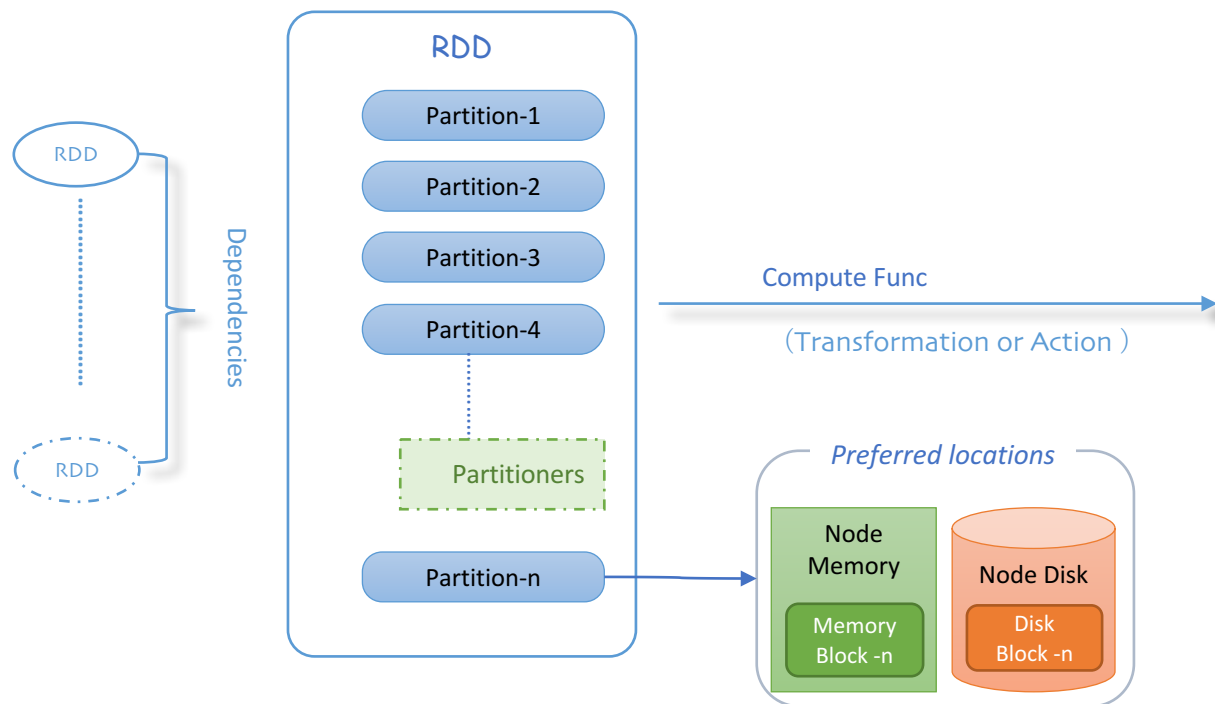
PSModel



# RDD vs PSModel

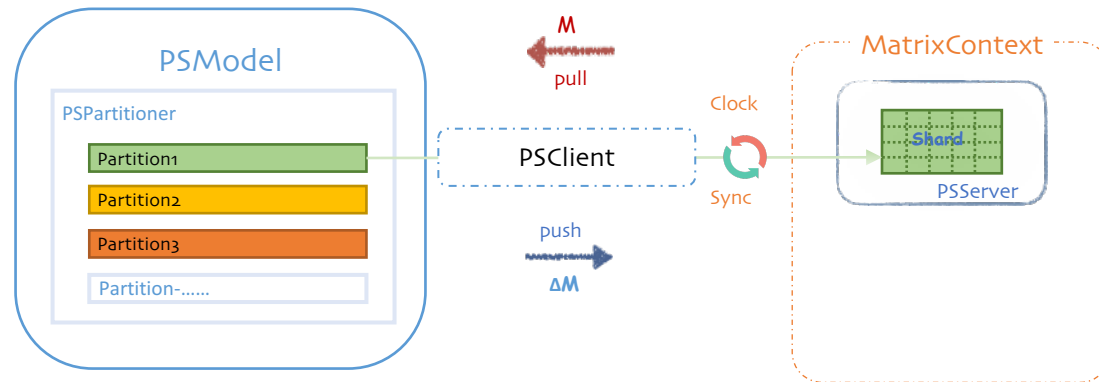


# RDD和核心抽象

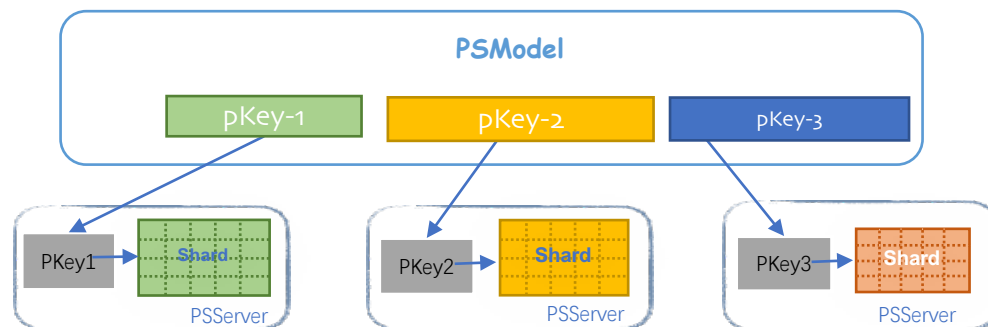




# PSModel



# 模型分区 (Model Partitioner)



将模型切分成多个分区，  
存储在不同PS节点上


## 优点

- 保证Server负载均衡
- 避免Server单点性能瓶颈
- 支撑10亿~100亿级别维度参数

## Angel的模型分区

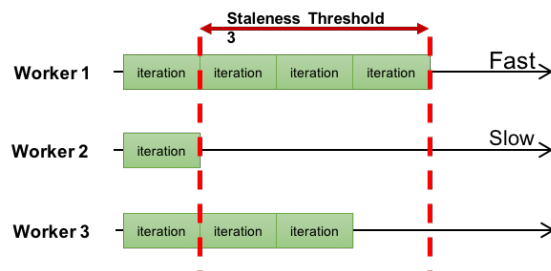
- 默认将模型分成大小相等的块
- 可以指定分区块大小
- 支持横切和纵切
- 自定义矩阵分区，量身定制区块分布方式

# 同步控制 (Sync Controller)




BSP

适用范围广，但等待时间长  
`angel.staleness = 0`



SSP

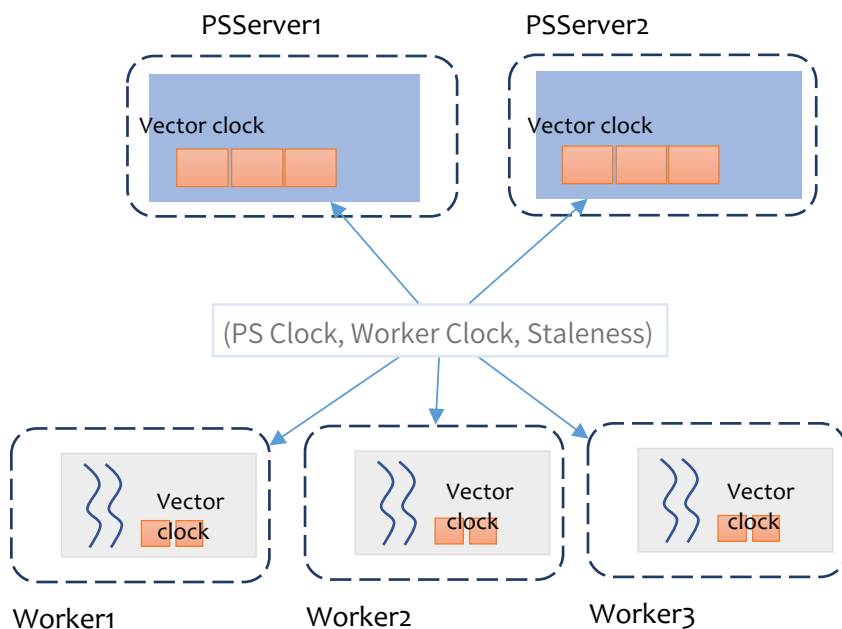
等待时间较短，但需要更多迭代  
`angel.staleness = N`



ASP

无等待时间较短，收敛无保证  
`angel.staleness = -1`

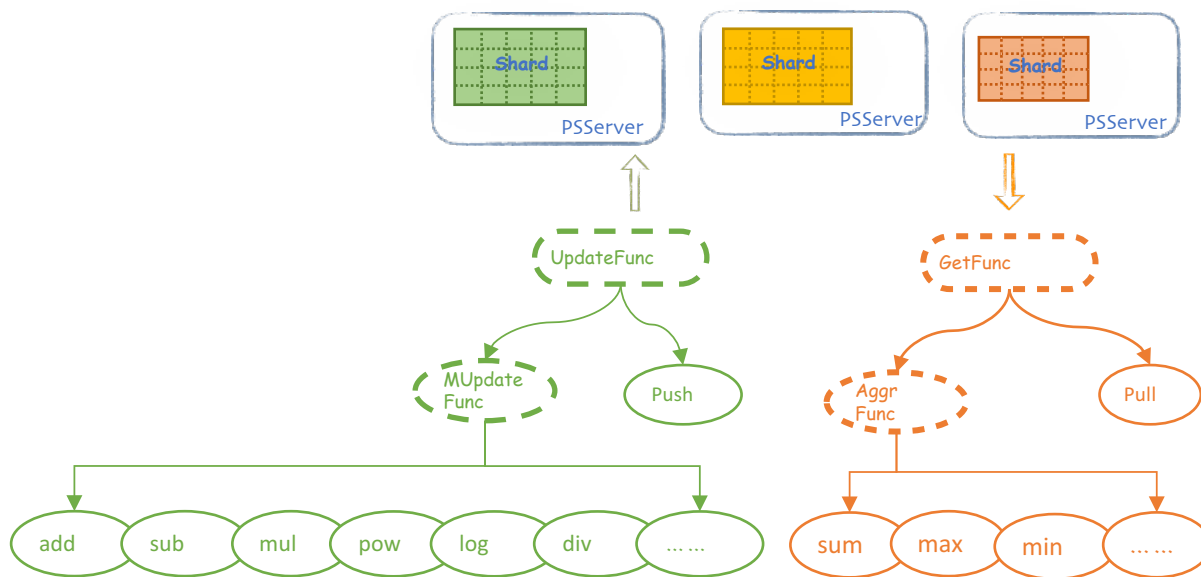
# 同步控制 (Sync Controller)



## 向量时钟

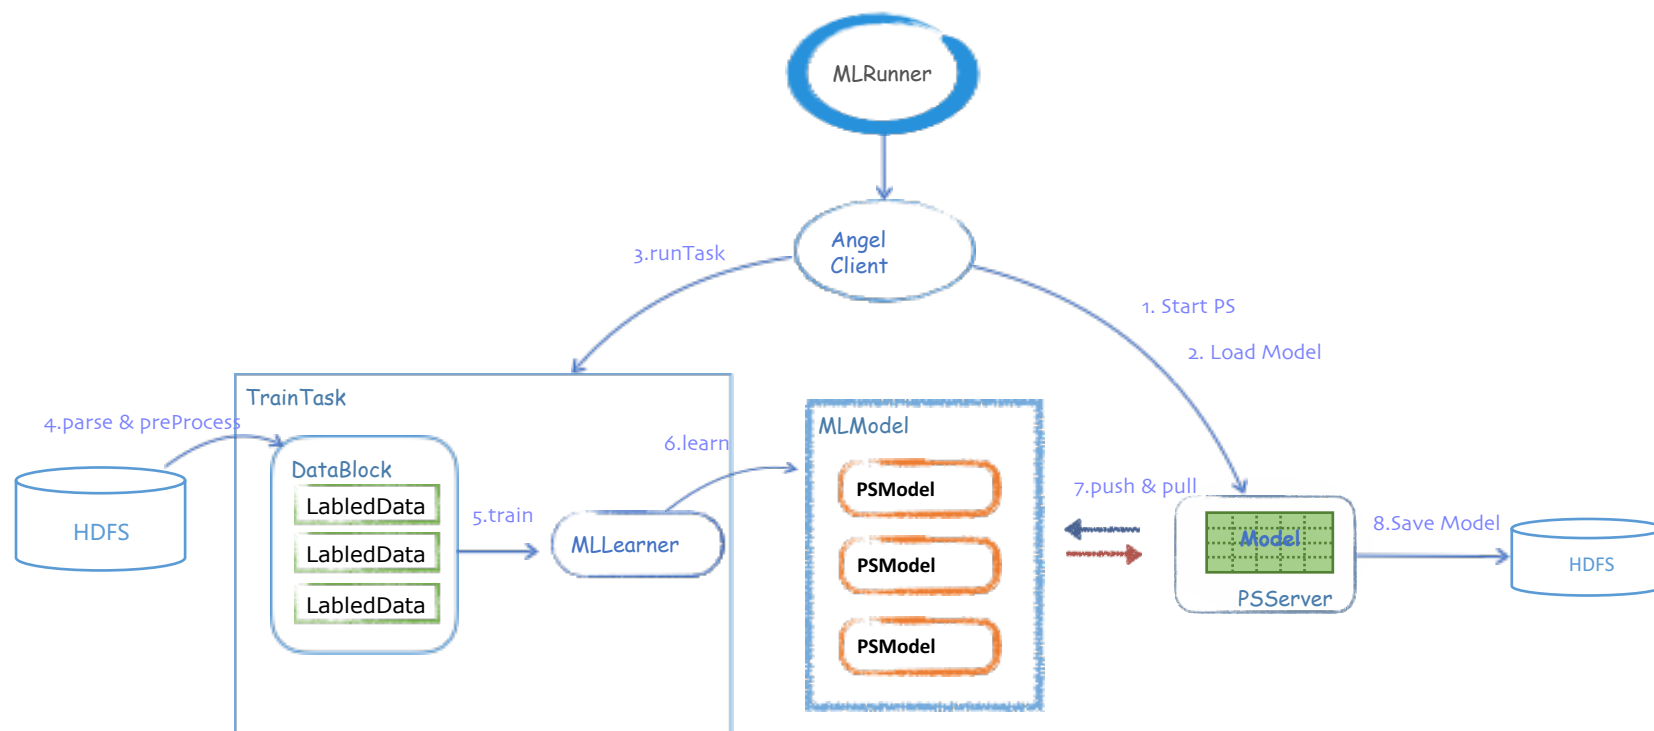
- 在Server端为每个分区维护一个向量时钟，记录每个worker在该分区的时钟信息
- 在Worker端维护一个后台同步线程，用于同步所有分区的时钟信息
- Task在对PSModel进行Get或其他读取操作时，根据本地时钟信息和staleness进行判断，选择是否进行等待操作
- 每次迭代完，调用Clock方法，更新向量时钟

# ps函数 (psFunc)



PServer不仅仅是存储，也具备计算功能，可以实现模型并行

# 核心流程和类



# Algorithms on Angel

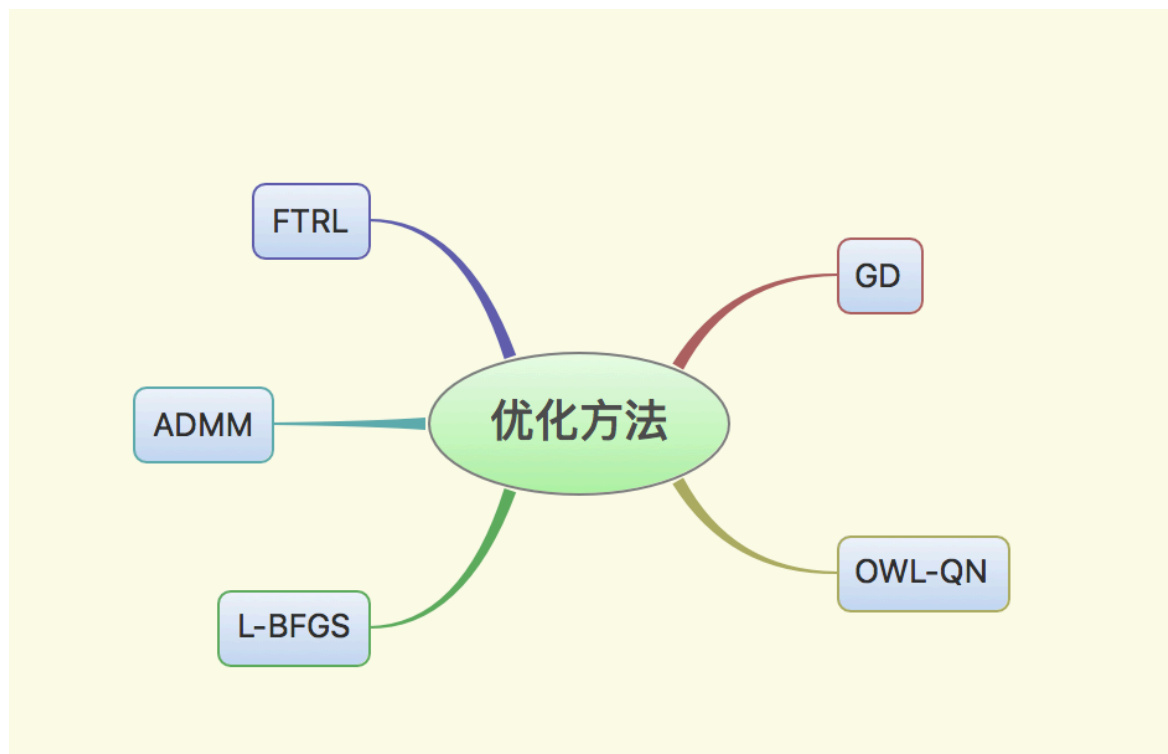
---

# Angel的算法



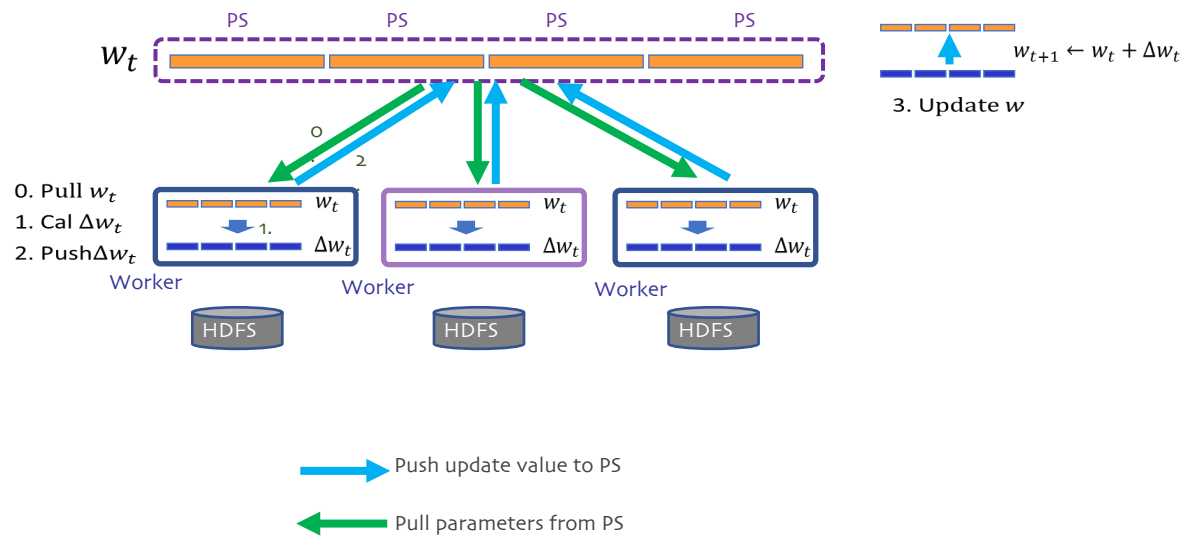


# 优化方法



# LR on Angel

- Step 0:** Worker从PS获得参数 $w_t$   
**Step 1:** Worker计算参数的更新值 $\Delta w_t$   
**Step 2:** Worker把 $\Delta w_t$ 推送给PS  
**Step 3:** PS更新参数 ( $w_{t+1} \leftarrow w_t + \Delta w_t$ )



# Spark on Angel

---

# Spark on PS的回顾



**An Asynchronous Parameter Server for Spark**

Rolf Jagerman  
University of Amsterdam



## Scaling Machine Learning To Billions of Parameters

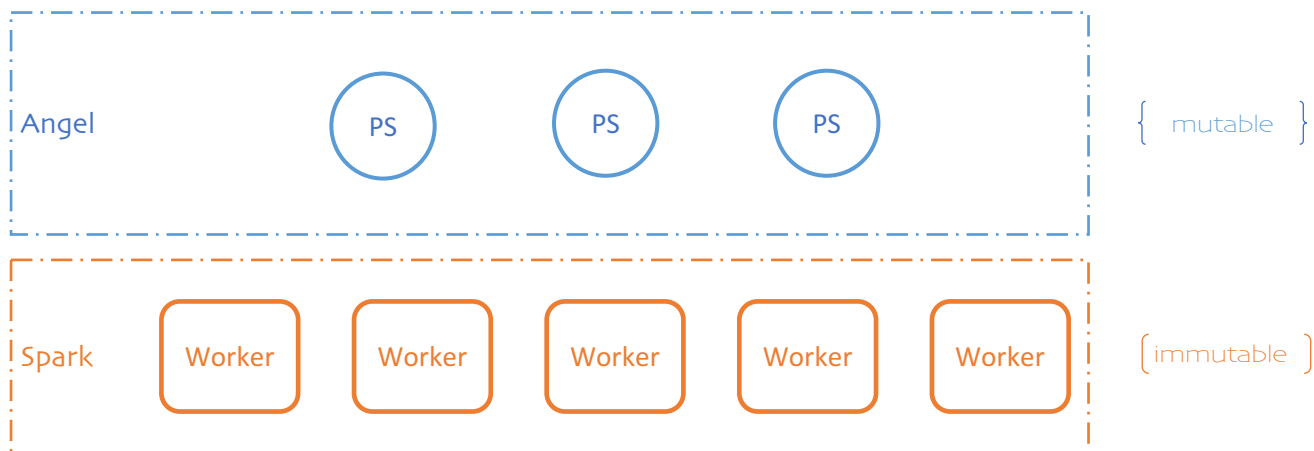
Badri Bhaskar, Erik Ordentlich  
(joint with Andy Feng, Lee Yang, Peter Cnudde)  
Yahoo, Inc.



SPARK SUMMIT 2016  
DATA SCIENCE AND ENGINEERING AT SCALE  
JUNE 6-8, 2016 SAN FRANCISCO

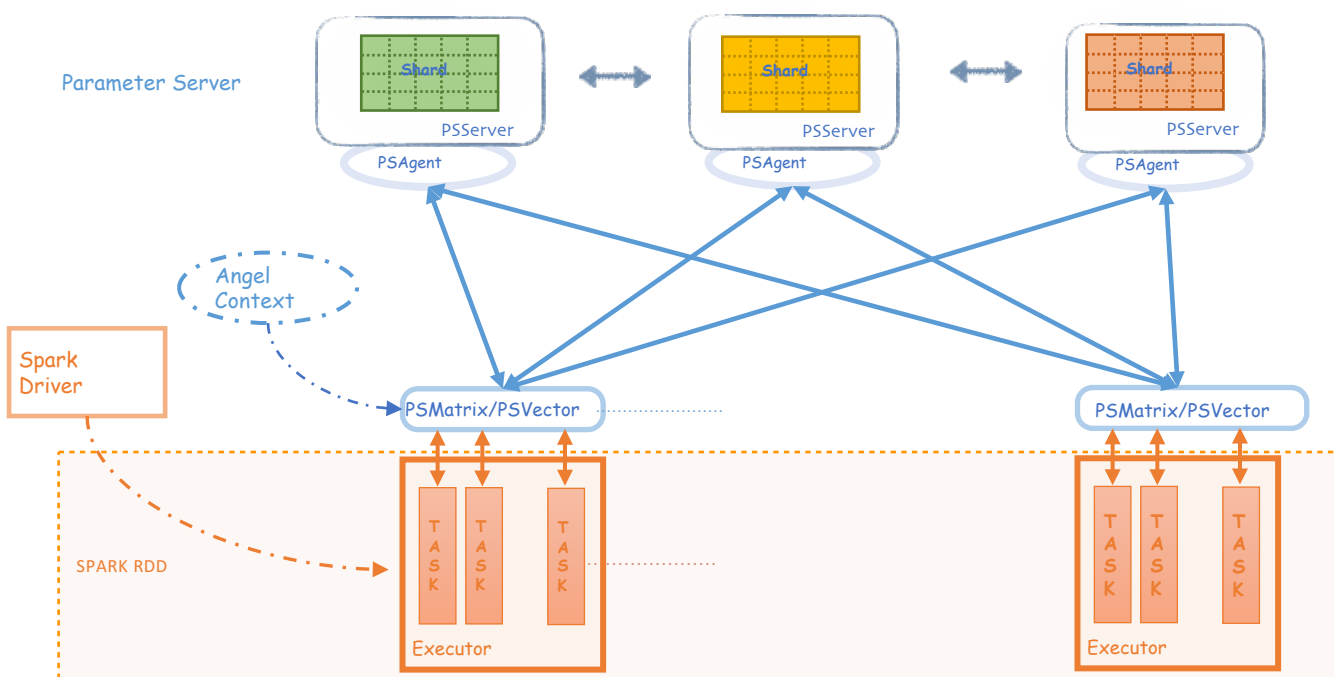
<https://issues.apache.org/jira/browse/SPARK-6932>

# Spark on PS的基本理念



1. 分离变和不变
2. 以少博多
3. 降低侵入性

# Spark on Angel的架构



# Spark on Angel的基础写法

```
PSContext.getOrCreate(spark.sparkContext)
val psVector = PSVector.dense(dim, capacity)
rdd.map { case (label, feature) =>
    psVector.increment(feature)
    ...
}
println("feature sum:" + psVector.pull.mkString(" "))
```

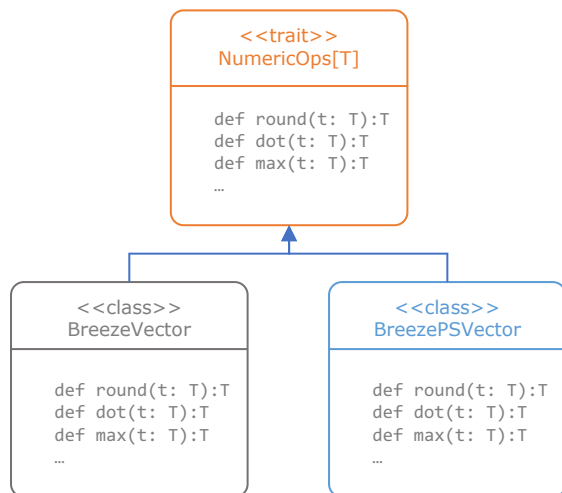
- 启动SparkSession

- 初始化PSContext, 启动Angel的PSServer
- 通过PSContext, 创建PSVector
- 在RDD的运算中, 直接调用PSVector, 进行模型更新
- 终止PSContext

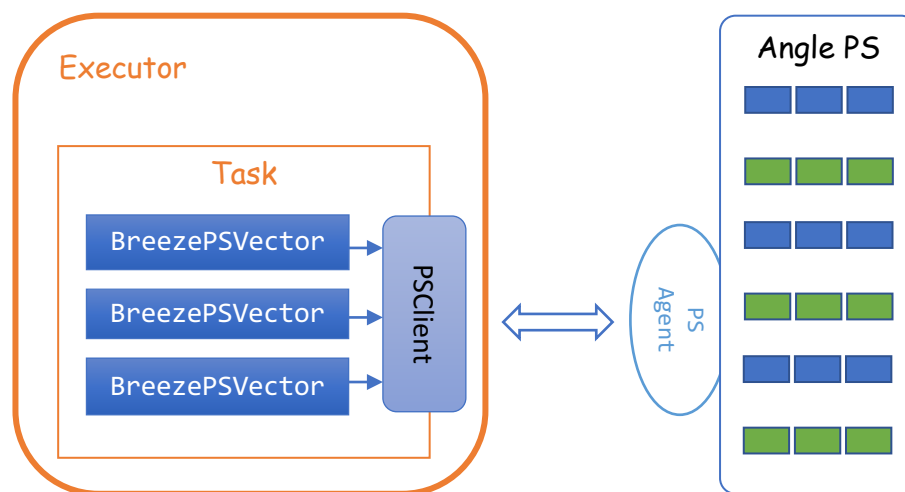
- 停止SparkSession

# Vector的透明替换

混入相同特征



进行透明替换



- 将BreezeVector透明替换为PsVector
- 适用于MLlib大部分算法
- 替代成本非常低



# Spark on Angel的进阶写法

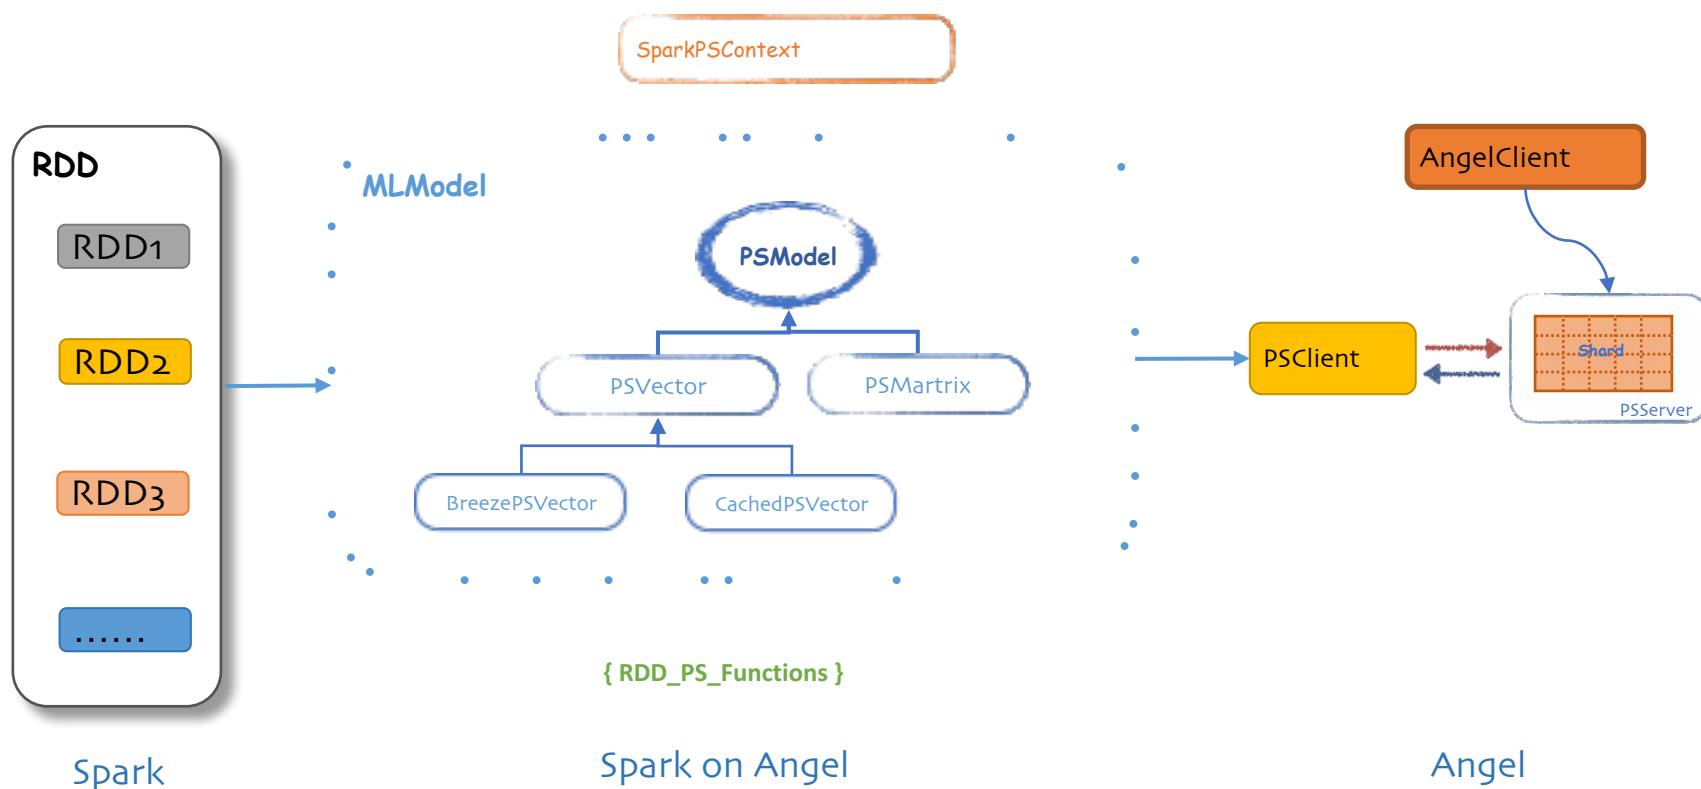
- Spark

```
def runOWLQN(trainData: RDD[(Vector, Double)], dim: Int, m: Int, maxIter: Int): Unit = {  
  
    val initWeight = new DenseVector[Double](dim)  
    val l1reg = 0.0  
    val owlqn = new BrzOWLQN[Int, DenseVector[Double]](maxIter, m, 0.0, 1e-5)  
  
    val states = owlqn.iterations(CostFunc(trainData), initWeight)  
    .....  
}
```

- Spark on Angel

```
def runOWLQN(trainData: RDD[(Vector, Double)], dim: Int, m: Int, maxIter: Int): Unit = {  
  
    val initWeightPS = PSVector.dense(dim, 20).toBreeze()  
    val l1regPS = PSVector.duplicate(initWeightPS.component).zero().toBreeze  
  
    val owlqn = new OWLQN(maxIter, m, l1regPS, tol)  
    val states = owlqn.iterations(PSCostFunc(trainData), initWeightPS)  
    .....  
}
```

# Spark on Angel的API设计

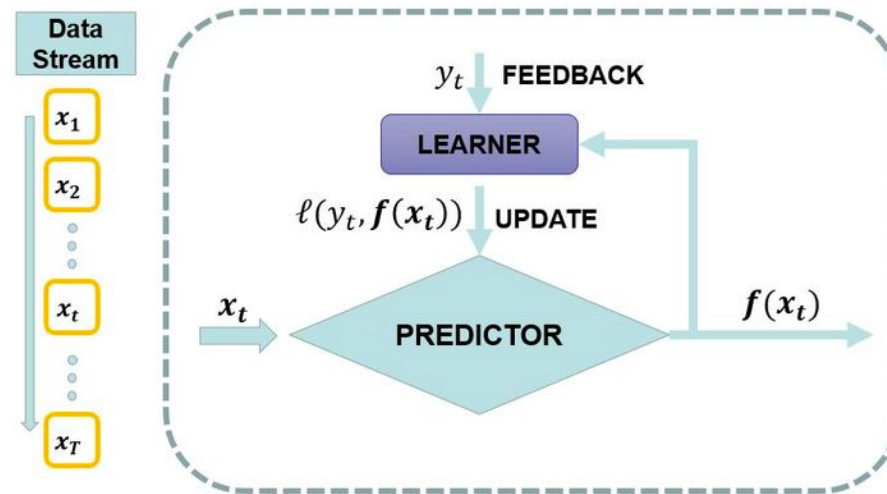


# Spark Streaming on Angel

---

A Better Way of Online Learning

# Online Learning



[https://en.wikipedia.org/wiki/Online\\_machine\\_learning](https://en.wikipedia.org/wiki/Online_machine_learning)

# 在线随机优化 – 目标

- 目标：在online的场景下最小化后悔(regret)

For  $t = 1, 2, \dots, T$

- Learner receive an input  $x_t \in X$
- Learner output prediction  $p_t = f_t(x_t) \in Y$
- Nature looks at output  $p_t$  and send the learner the true label  $y_t \in Y$
- Learner suffers loss  $V(p_t, y_t)$  and updates its model

The learner is trying to minimize the regret

$$R_T(H) = \sum_{t=1}^T V(p_t, y_t) - \min_{f \in H} \sum_{t=1}^T V(f(x_t), y_t)$$

- 典型算法：FTRL(follow the regularized leader)

# 基于Logistic Regression的FTRL

---

**Algorithm 1** Per-Coordinate FTRL-Proximal with  $L_1$  and  $L_2$  Regularization for Logistic Regression

---

*# With per-coordinate learning rates of Eq. (2).*

**Input:** parameters  $\alpha, \beta, \lambda_1, \lambda_2$

$(\forall i \in \{1, \dots, d\})$ , initialize  $z_i = 0$  and  $n_i = 0$

**for**  $t = 1$  **to**  $T$  **do**

    Receive feature vector  $\mathbf{x}_t$  and let  $I = \{i \mid x_i \neq 0\}$

    For  $i \in I$  compute

$$w_{t,i} = \begin{cases} 0 & \text{if } |z_i| \leq \lambda_1 \\ -\left(\frac{\beta + \sqrt{n_i}}{\alpha} + \lambda_2\right)^{-1} (z_i - \text{sgn}(z_i)\lambda_1) & \text{otherwise.} \end{cases}$$

    Predict  $p_t = \sigma(\mathbf{x}_t \cdot \mathbf{w})$  using the  $w_{t,i}$  computed above

    Observe label  $y_t \in \{0, 1\}$

**for all**  $i \in I$  **do**

$g_i = (p_t - y_t)x_i$  *#gradient of loss w.r.t.  $w_i$*

$\sigma_i = \frac{1}{\alpha} \left( \sqrt{n_i + g_i^2} - \sqrt{n_i} \right)$  *#equals  $\frac{1}{\eta_{t,i}} - \frac{1}{\eta_{t-1,i}}$*

$z_i \leftarrow z_i + g_i - \sigma_i w_{t,i}$

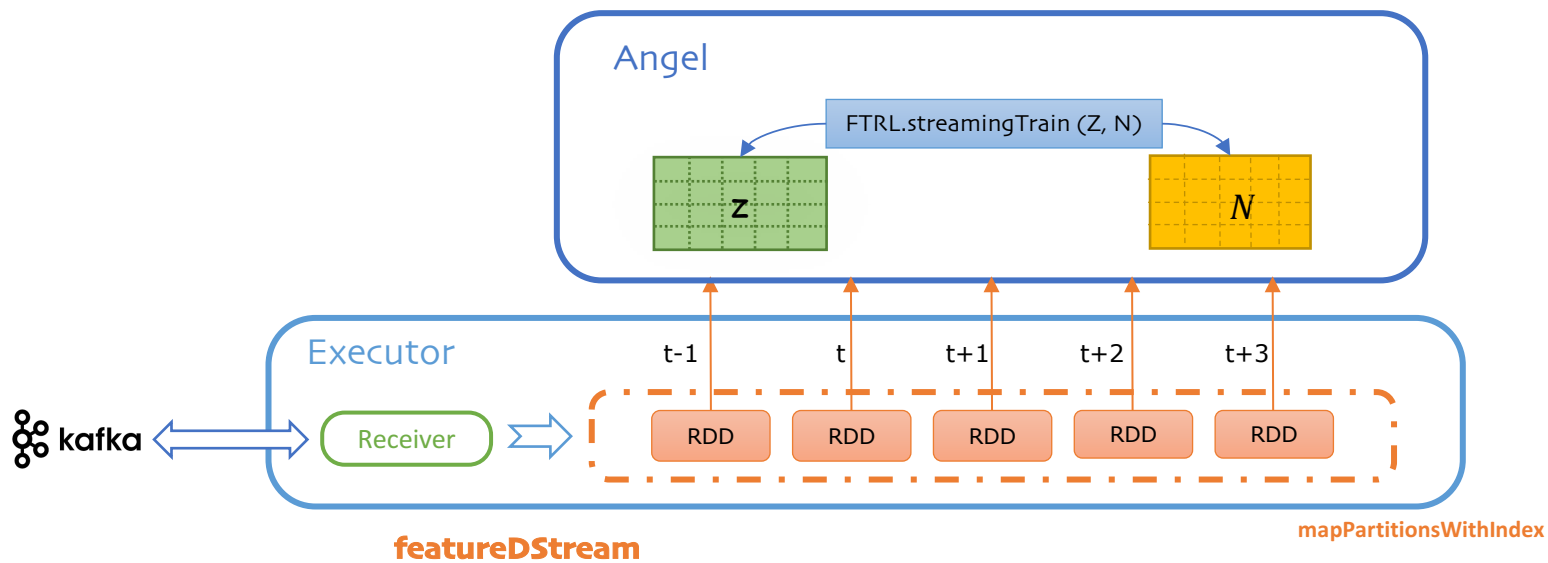
$n_i \leftarrow n_i + g_i^2$

**end for**

**end for**

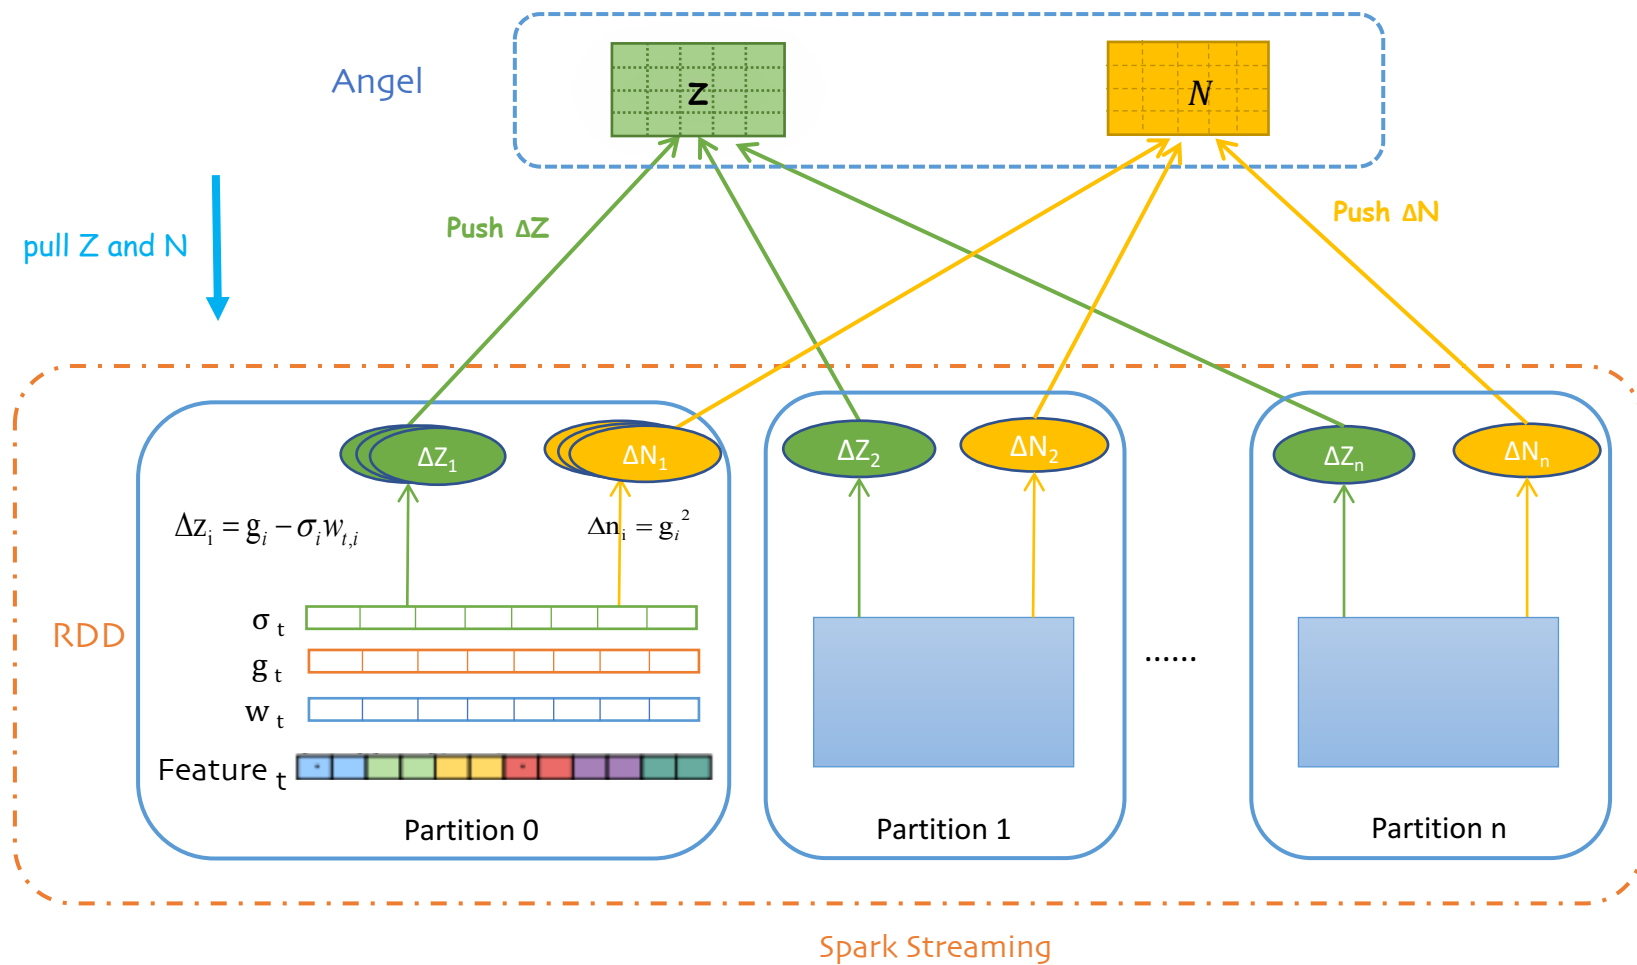
---

# [Spark Streaming on Angel] FTRL架构



[<SparseLRWithFTRL.scala>](#)

# 基于Angel的实现





# FTRL的整体代码框架

## 1. 初始化上下文 (Spark Streaming & Angel)

```
val ssc = new StreamingContext(sparkConf, Seconds(streamingWindow))  
val sc = ssc.sparkContext  
PSContext.getOrCreate(sc)
```

## 2. 对接Kafka，创建DataStream (Receiver-base模式)

```
val topicMap: Map[String, Int] = Map(topic -> 1)  
val featureDS = KafkaUtils.createStream(ssc, zkQuorum, group, topicMap).map(_._2)
```

## 3. 创建Angel的PSModel (PSVector)

```
val zPS: SparsePSVector = PSVector.sparse(dim)  
val nPS: SparsePSVector = PSVector.sparse(dim)
```

## 4. 基于FeatureDS，训练zPS和nPS的算法流程

```
SparseLRWithFTRL.train(zPS, nPS, featureDS)
```

## 5. 启动SparkStreaming


```
ssc.start()  
ssc.awaitTermination()
```

# 资源和性能

资源参数	
* num-executors	<input type="text" value="100"/> 分配计算节点数目
* driver-memory(g)	<input type="text" value="5"/> 主节点内存大小, 上限为30g
* executor-cores	<input type="text" value="3"/> 每个子节点分配的cpu core数, 推荐3~4
* executor-memory(g)	<input type="text" value="10"/> 每个子节点分配的内存大小, 上限为30g, 推荐单个core配置2~3g

Angel资源参数	
* spark.ps.instances	<input type="text" value="20"/> Angel PS节点数
* spark.ps.cores	<input type="text" value="2"/> 每个PS节点的Core数
* spark.ps.memory(g)	<input type="text" value="6"/> 每个PS节点的Memory大小

alpha	<input type="text" value="0.1"/> FTRL的alpha参数
beta	<input type="text" value="1.0"/> FTRL的beta参数
* lambda1	<input type="text" value="0.1"/> FTRL的lambda1参数, L1正则项的系数
lambda2	<input type="text" value="0.1"/> FTRL的lambda2参数, L2正则项的系数
rho1	<input type="text" value="0.7"/> FTRL_VRG中权重W进行移动平均更新时采用的系数
rho2	<input type="text" value="0.85"/> FTRL_VRG中梯度进行移动平均更新时采用的系数




# 性能比对

---


生产数据，现网环境，尽量公平

# Spark on Angel vs Spark —— LR

	Spark	Spark on Angel	加速比例
SGD LR (stepSize=0.05,maxIter=100)	2.9 hour	1.5 hour	48.3%
L-BFGS LR (m=10, maxIter=50)	2 hour	1 hour	50.0%
OWL-QN LR (m=10, maxIter=50)	3.3 hour	1.4 hour	57.6%




# Angel vs XGBoost —— GBDT



框架	Worker	PS	建立20棵树时间
Angel	50 个(内存: 10G / Worker)	10个 (内存: 10G / PS)	58 min
XGBoost	50个 (内存: 10G / Worker)	N/A	2h 25 min

数据：腾讯内部某性别预测数据集， $3.3 \times 10^5$  特征， $1.2 \times 10^8$  样本

# Angel vs Spark —— LDA




框架	Worker	PS	时间
Angel	20个(内存: 8G/Worker)	20个(内存: 4G/PS)	15min
Spark	20个(内存: 20G/Worker)	N/A	>300min

数据: PubMed

框架	Worker	PS	时间
Angel	50个(内存: 10G/Worker)	50个(内存: 4G/PS)	1h 7min

DataSet: 40G Token: 2 billion Word: 52w Topic : 1000


# Angel vs Spark —— LR



框架	Worker	PS	迭代100次时间
Angel	50个(内存:10G/Worker)	20个(内存: 5G/PS)	20min
Spark	50个(内存:14G/Worker)	N/A	145min

数据：腾讯内部某推荐数据， $5 \times 10^7$  特征， $8 \times 10^7$  样本

# Angel vs Spark —— ADMM-LR



框架	Worker	PS	收敛退出
Angel	100个(内存:10G/Worker)	50个(内存: 5G/PS)	27 min
Spark	200个(内存:20G/Worker)	N/A	145 min

数据：腾讯内部某推荐数据，5千万特征，1亿样本




# 开源和展望



OpenSource & Perspective

# Angel开源

 Tencent / **angel**

 Unwatch ▾

321

★ Unstar

2,889

 Fork

704

**github**:issues

(PR 98)

- [LightBGM作者: \[GBDT\] The purposes of using parameter server in GBDT #7](#)
- [海外华人: English translation of documents #95](#)
- [华为工程师: \[WIP\]Upgrade the netty version of RPC to 4.x #94](#)
- [新浪微博: 增强LR算法, 加入y截距因子](#)
- [hbghhy: 加入阿里巴巴用于CTR预估的MLR算法](#)
- .....

# 学术创新

- 国际顶级会议Paper ( CCF A类 )

- [LDA\\*: A Robust and Large-scale Topic Modeling System VLDB, 2017](#)
- [Heterogeneity-aware Distributed Parameter Servers. SIGMOD, 2017](#)
- Angel: a new large-scale machine learning system. National Science Review (NSR), 2017
- TencentBoost: A Gradient Boosting Tree System with Parameter Server. ICDE, 2017
- .....




# 未来展望 (What is Next)



Distributed Serving

V1.6



Deep Learning Framework Support

V2.0

# Q & A



欢迎Star, Fork和PR



Angel技术交流群

扫一扫二维码，加入该群。

微博：@明风