WeBank

FATE：新一代联邦学习技术及应用实战

范涛
微众银行高级研究员
dylanfan@webank.com

FedAI Ecosystem

https://www.fedai.org/
https://github.com/WeBankFinTech/FATE

目录
CONTENTS

01

联邦学习背景介绍

AI落地： 理想vs现实

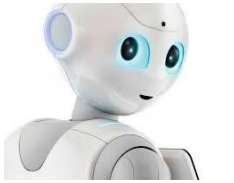

理想

数据质量好 | **标签数据充足** | **数据集中**

现实

数据质量差

Twitter taught Microsoft's AI chatbot to be a racist asshole in less than a day

缺乏标签数据

"昔日的人工智能老大哥，IBM WATSON为什么现在会被看作一个笑话？"

问题：

- 无法了解基因与疾病的关系 （只有医生可以给数据打标签）
- 买数据？ Verily Life Sciences 有一万名志愿者，但需要10年！

数据分散隔离

80% 以上的企业存在数据孤岛问题（information silos)

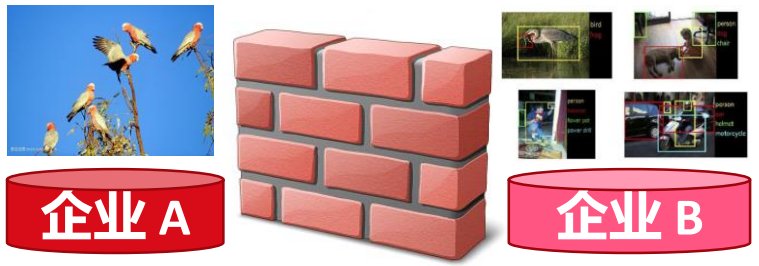

X1 **(X2, Y)**

WeBank

基于联邦学习的技术生态

01 数据隔离

数据不泄露到外部

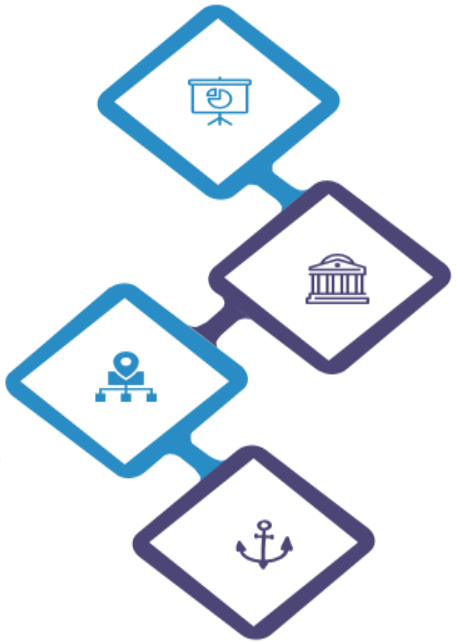

03 对等

参与者地位的对等

无损 02

联邦模型效率等同或
接近全量数据模型

共同获益 04

参与者共同获益

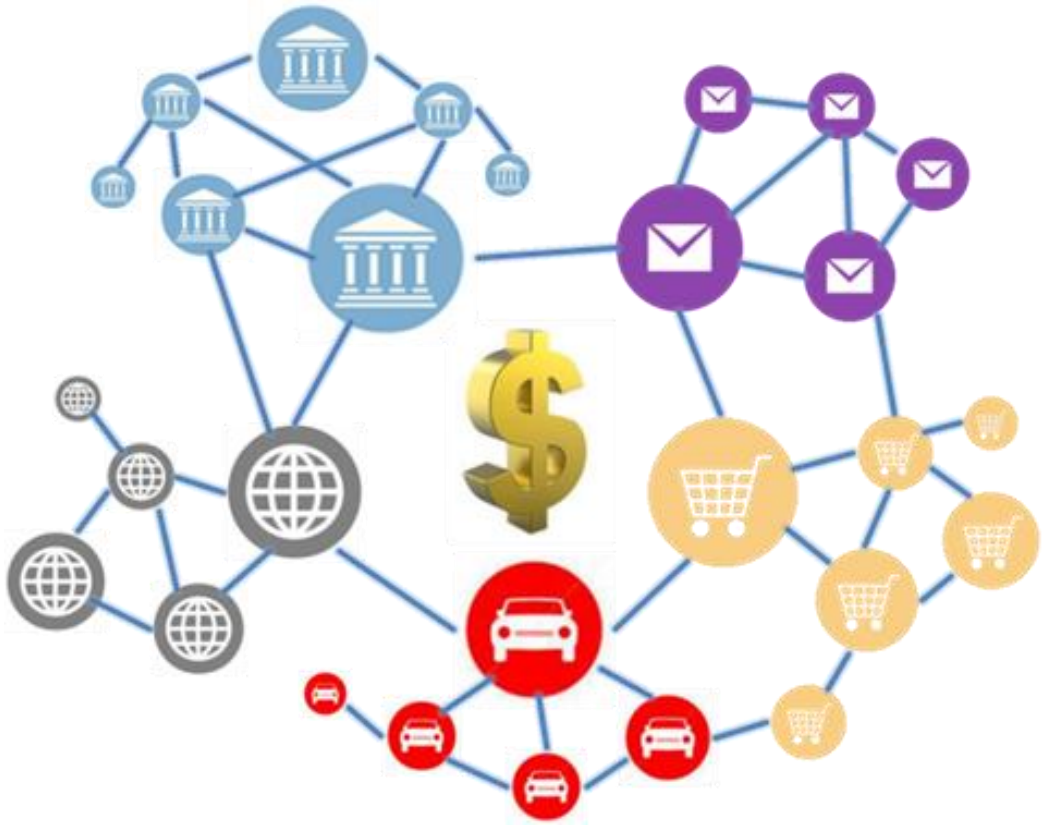

WeBank

联邦学习的分类体系

纵向联邦学习

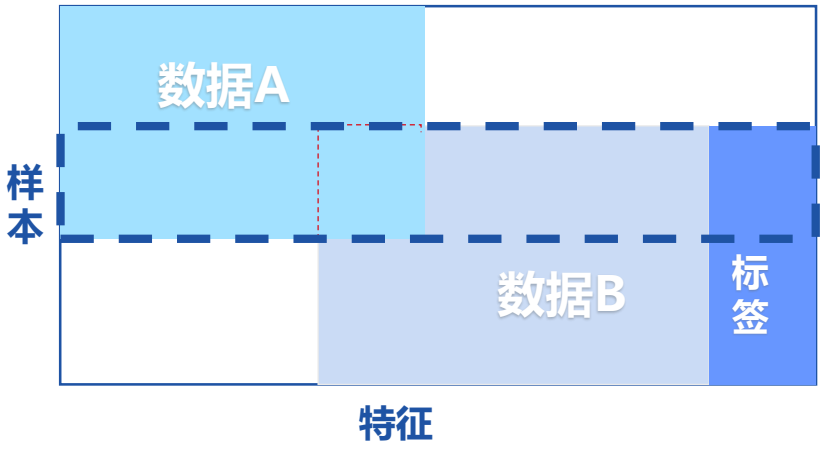

横向联邦学习

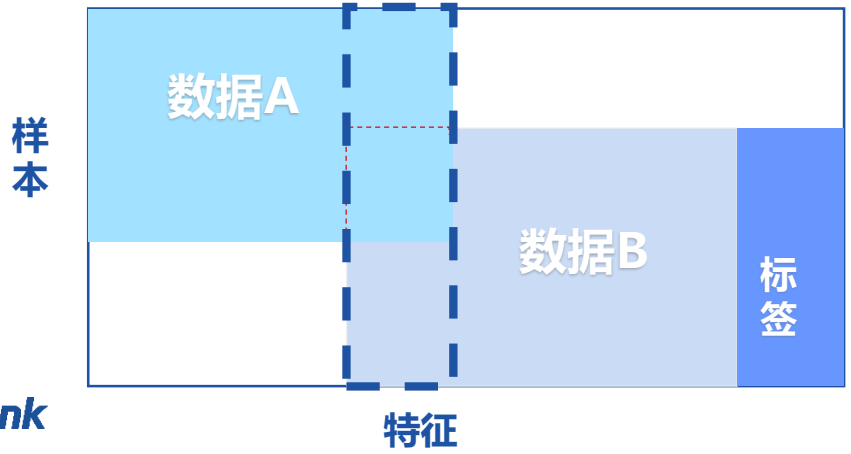

联邦迁移学习

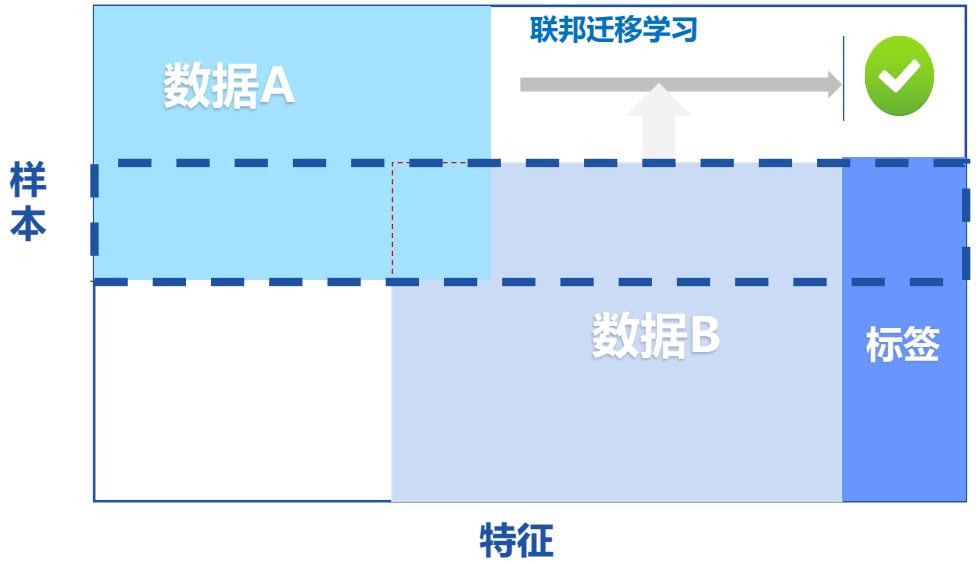

WeBank

02

纵向联邦学习

纵向联邦学习-联合建模需求场景

举例：微众与合作企业联合建模，微众有Y（业务表现），期望优化本方的Y预测模型

◆ 设定：

✓ 只有微众拥有 Y= “逾期表现”

✓ 合作企业无法暴露含有隐私的 X

◆ 传统建模方法问题：

✓ 合作企业缺乏Y无法独立建模

✓ X数据全量传输到微众不可行

◆ 期望结果：

✓ 保护隐私条件下，建立联合模型

✓ 联合模型效果超过单边数据建模

合作企业

ID 证件号 电话号	X1 帐龄	X2 月薪	X3 等级
U1	9	8000	A
U2	4	5000	C
U3	2	3500	C
U4	10	10000	A
U5	5	7500	B
U6	5	7500	A
U7	8	8000	B

业务系统A 数据

微众银行

ID 证件号 电话号	X4 央行征信分	X5 微众 内部分	Y 表现数据
U1	600	600	无
U2	550	500	有
U3	520	500	有
U4	600	600	无
U8	600	600	无
U9	520	500	有
U10	600	600	无

业务系统B 数据

同态加密技术保护隐私

- ◆ 数据隐私保护：
  - ✓ 建模样本ID差集不向对方泄露
  - ✓ 任何底层X，Y数据不向对方泄露
- ◆ 模型参数保护：
  - ✓ 分别持有，联合使用
- ◆ 结果：
  - ✓ A方有A模型
  - ✓ B方有B模型
  - ✓ A和B模型都比单独建模好

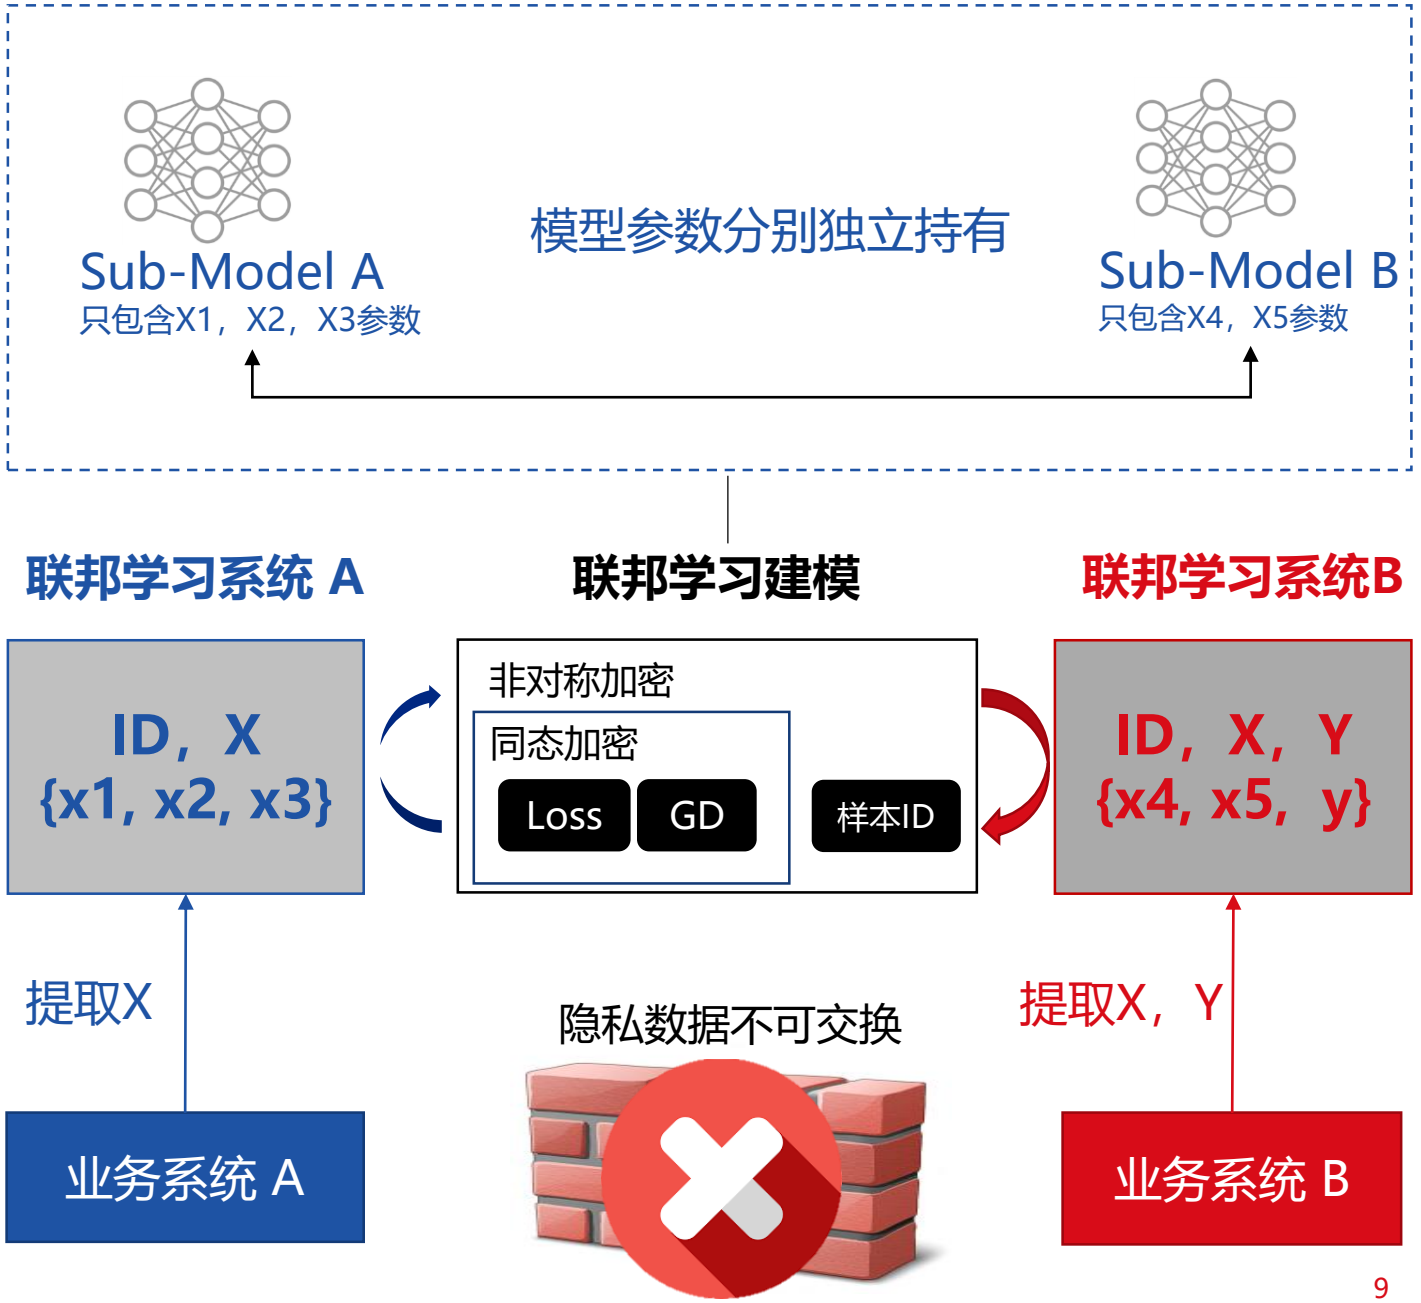

基于隐私保护的样本id匹配

How to find $X \cap Y$ = [u1, u2, u3] ?
Party A does not know Party B has u5
Party B does not know Party A has u4

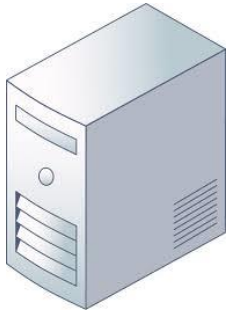

[u1, u2, u3, u4]

ID set X

Party A

[u1, u2, u3, u5]

ID set Y

Party B

基于隐私保护的样本id匹配

Party A

X_A: {u1, u2, u3, u4}

H(x): x的哈希

Party B

X_B: {u1, u2, u3, u5}

public key: (n, e)

RSA： n, e, d

Y_A = {ri^e*H(ui) | ui ∈ X_A $ri: rand$}

Y_A = { $r1^e$H($u1$), $r2^e$H($u2$), $r3^e$H($u3$), $r4^e$H($u4$)}

Z_A= $(ri^e \mathrm{H}(ui))^d$=ri*$(\mathrm{H}(ui))^d$ % n | $ri^e \mathrm{H}(ui) \in Y_A$}

D_A= {H(ri*$(\mathrm{H}(ui))^d$/ ri) =H($(\mathrm{H}(ui))^d$) | ri*$(\mathrm{H}(ui))^d \in Z_A$}

Z_A, Z_B

Z_B = { H($(\mathrm{H}(u))^d$) | u ∈ X_B}

I = $D_A \cap Z_B$ = {H($(\mathrm{H}(u1))^d$), H($(\mathrm{H}(u2))^d$), H($(\mathrm{H}(u3))^d$)}

I

I, D_A => {u1, u2, u3}

I, Z_B => {u1, u2, u3}

同态加密

- 全同态或者半同态 Full Homomorphic Encryption and Partial Homomorphic Encryption
- 数据层面的信息保护 Data-level information protection

Paillier 半同态加密 Partially homomorphic encryption

***Addition* :** **[[u]] + [[v]] = [[u+v]]**
Scalar multiplication: **n[[u]] = [[nu]]**

Rivest, R. L.; Adleman, L.; and Dertouzos, M. L. 1978. On data banks and privacy homomorphisms. Foundations of Secure Computation, Academia Press, 169–179.

联邦特征工程

特征IV值

特征	IV
x1	0.3
x2	0.2
x3	0.4
x4	0.01
x5	0.05

问题：在保护双方隐私下，A侧(含X)和B侧(含X, Y)特征如何计算WOE和IV?

难点：

- A 侧只有特征x，没有y; 计算Woe和IV得同时依赖x,y (B侧特征Woe &IV 可以本地计算)
- A侧不能对B侧暴露x，B侧不能对A侧暴露y
- 最终只能让B侧获得所有特征Woe & IV

联邦特征工程 Woe & IV – 方案

Encry(x): x的加法同态加密，
Encode(x): 本地编码

A: Xi (特征分箱)

id_set_1 (eg: id1, id2, id5,..)
id_set_2
****
id_set_i
****
id_set_k

1. {idi , Encry(yi), Encry(1-yi)}

2. {
Encode(id_set_i),
sum(Encry(yi)),
sum(Encry(1-yi))
}

B: (X,Y)

id1	y1
id2	y2
***	***
idi	yi
***	****
idn	yn

3.
npos_i = Decry(sum(Encry(yi)));
nneg_i = Decry(sum(Encry(1-yi)))

B 方本地计算

1. distpos_i = npos_i/pos_total; distneg_i =nneg_i/neg_total
2. Woe_i = 100 * log(distpos_i / distneg_i)
3. IV = $\sum_{i=1}^{k}(dispos\_i - disneg\_i) * \log(dispos\_i/disneg\_i)$

同态加密在机器学习上应用

多项式近似 Polynomial approximation for logarithm function

$$l(w) = \log(1+\exp(-yw^T x))$$
$$\approx \log 2 - \frac{1}{2} yw^T x + \frac{1}{8}(w^T x)^2$$
$$\nabla l(w) = (\frac{1}{1+\exp(-yw^T x)} - 1)yx$$
$$\approx (\frac{1}{2} yw^T x - 1)\frac{1}{2} yx$$

加密计算 Encrypted computation for each term in the polynomial function

$$loss = \log 2 - \frac{1}{2} yw^T x + \frac{1}{8}(w^T x)^2$$
$$[[loss]] = [[\log 2]] + (-\frac{1}{2}) * [[yw^T x]] + \frac{1}{8}[[(w^T x)^2]]$$

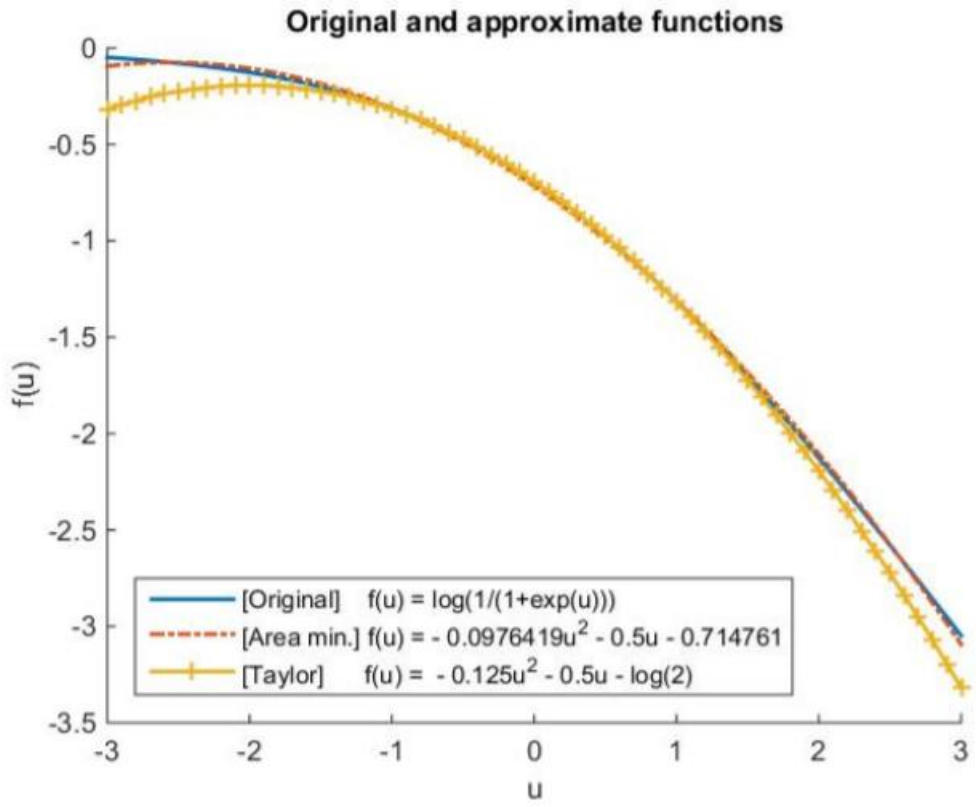

- Kim, M.; Song, Y.; Wang, S.; Xia, Y.; and Jiang, X. 2018. Secure logistic regression based on homomorphic encryption: Design and evaluation. JMIR Med Inform 6(2)
- Y. Aono, T. Hayashi, T. P. Le, L. Wang, Scalable and secure logistic regression via homomorphic encryption, CODASPY16

SecureBoost

- Collaboratively learn a shared gradient-tree boosting model
- Lossless meanwhile secure

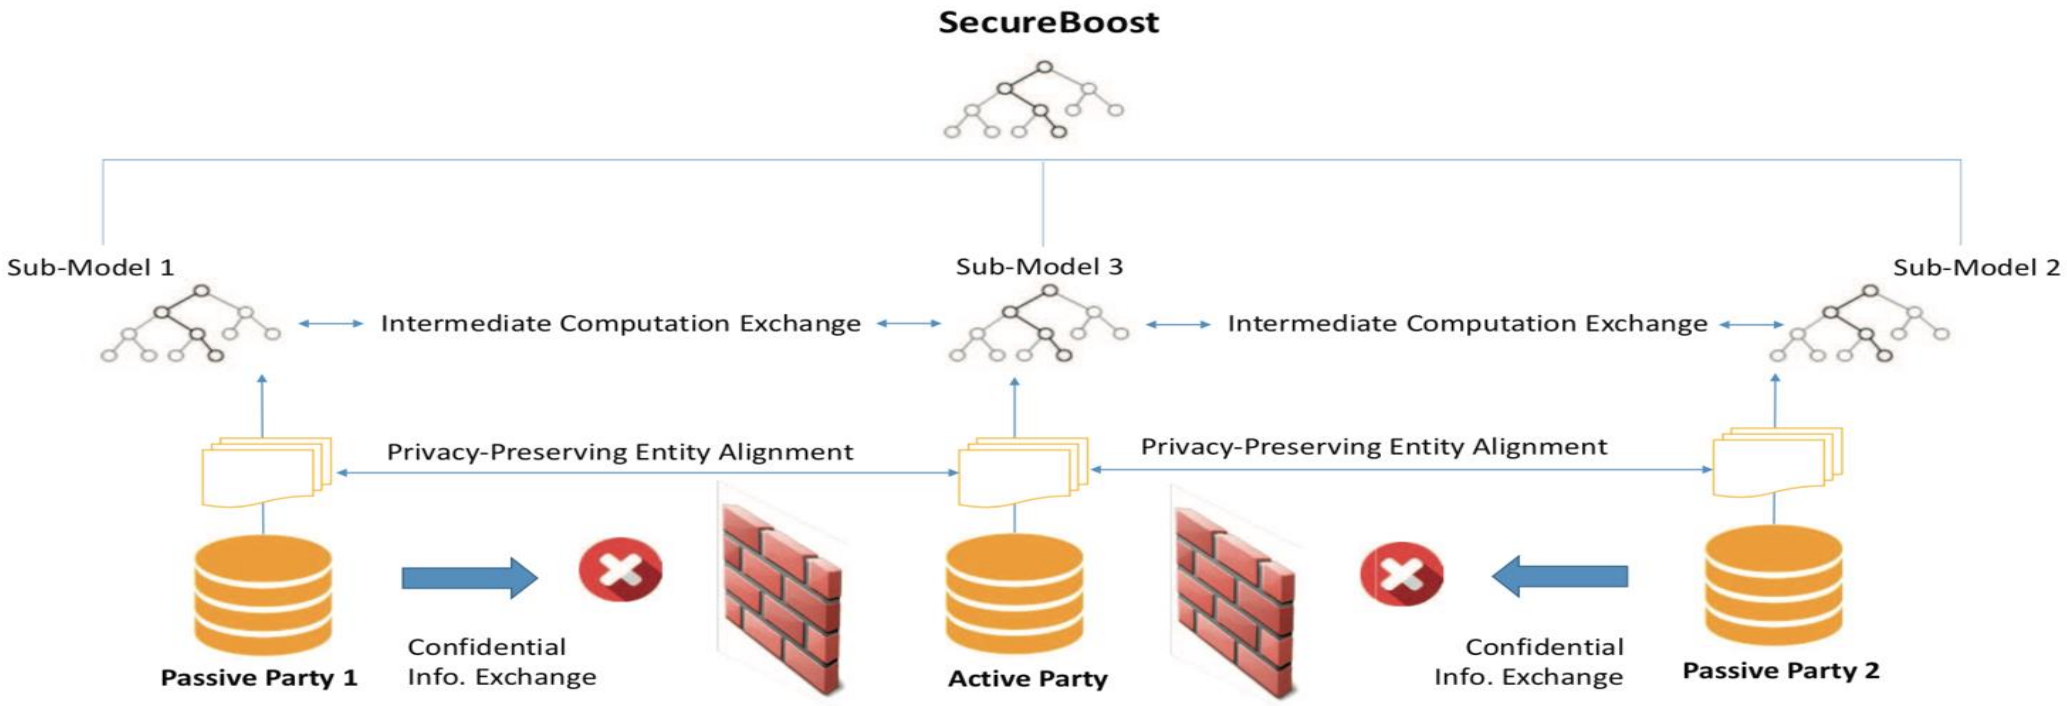

Cheng, K., Fan, T., Jin, Y., Liu, Y., Chen, T., & Yang, Q. (2019). SecureBoost: A Lossless Federated Learning Framework. *arXiv preprint arXiv:1901.08755*.

SecureBoost

Xgboost单棵树预测实例

Xgboost预测树作用：
训练阶段：生成样本gi，hi
预测阶段：生成样本预测结果

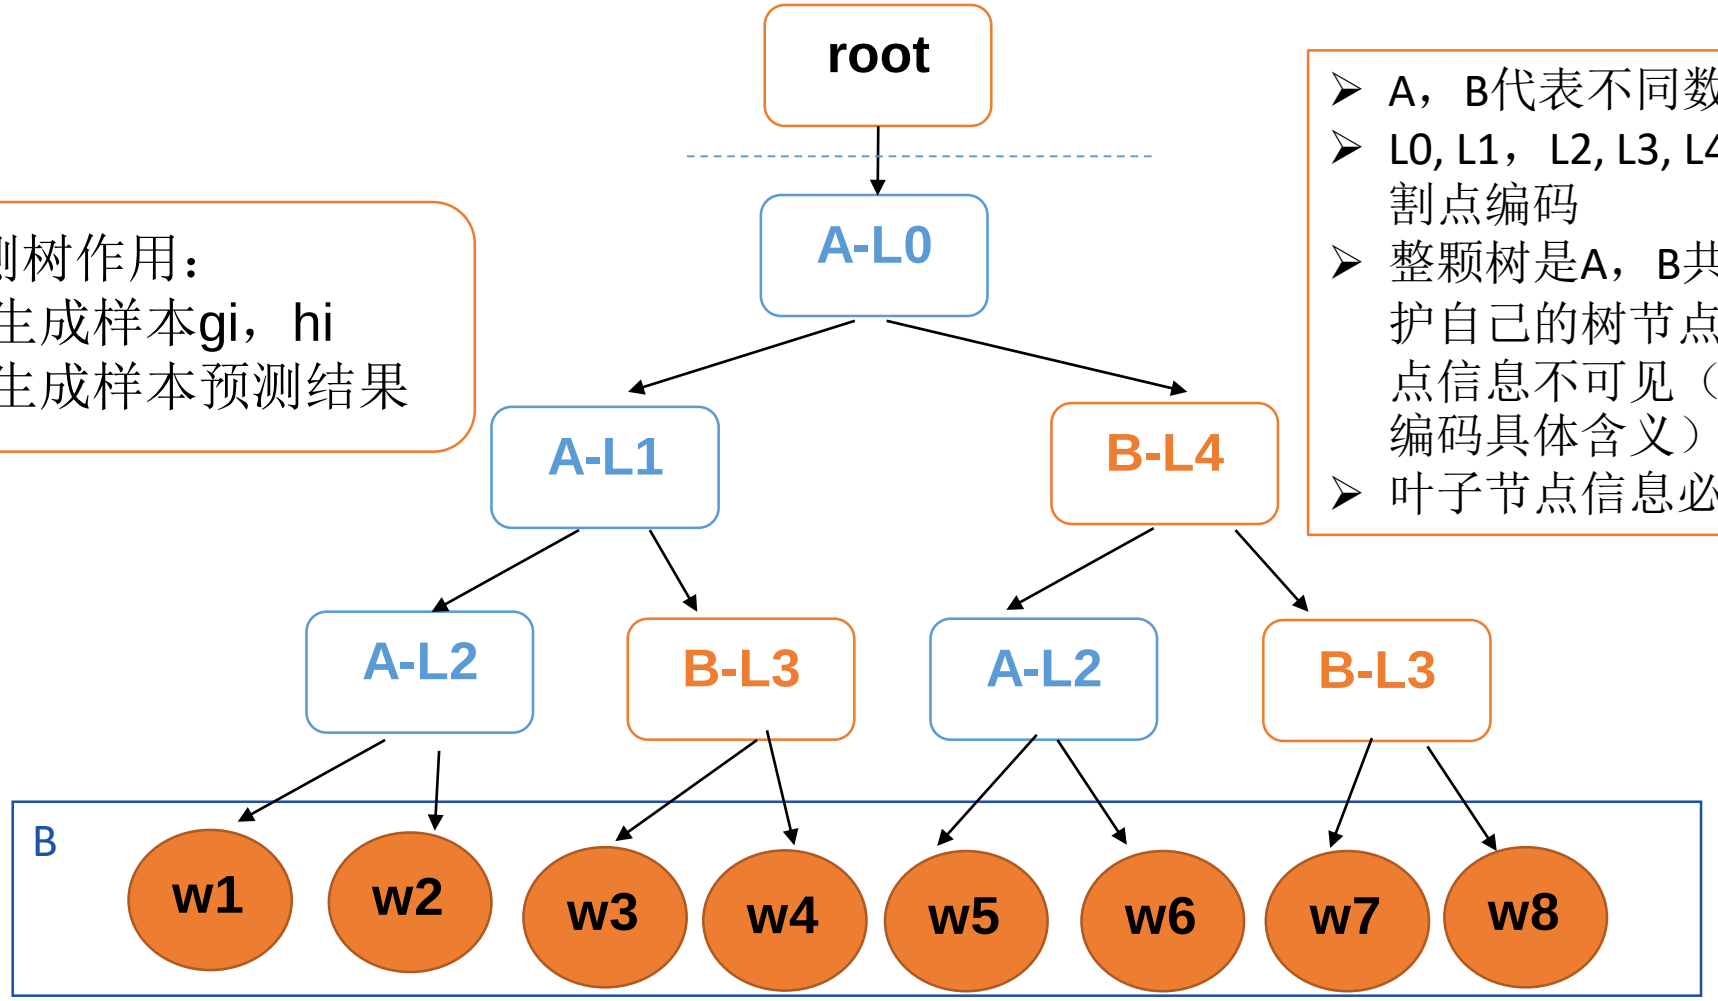

- A，B代表不同数据owner
- L0, L1，L2, L3, L4 代表不同feature的分割点编码
- 整颗树是A，B共同维护，每一方只维护自己的树节点，对另外一方的树节点信息不可见（只知道编码，不知道编码具体含义）
- 叶子节点信息必须存在B

SecureBoost 联邦计算信息增益

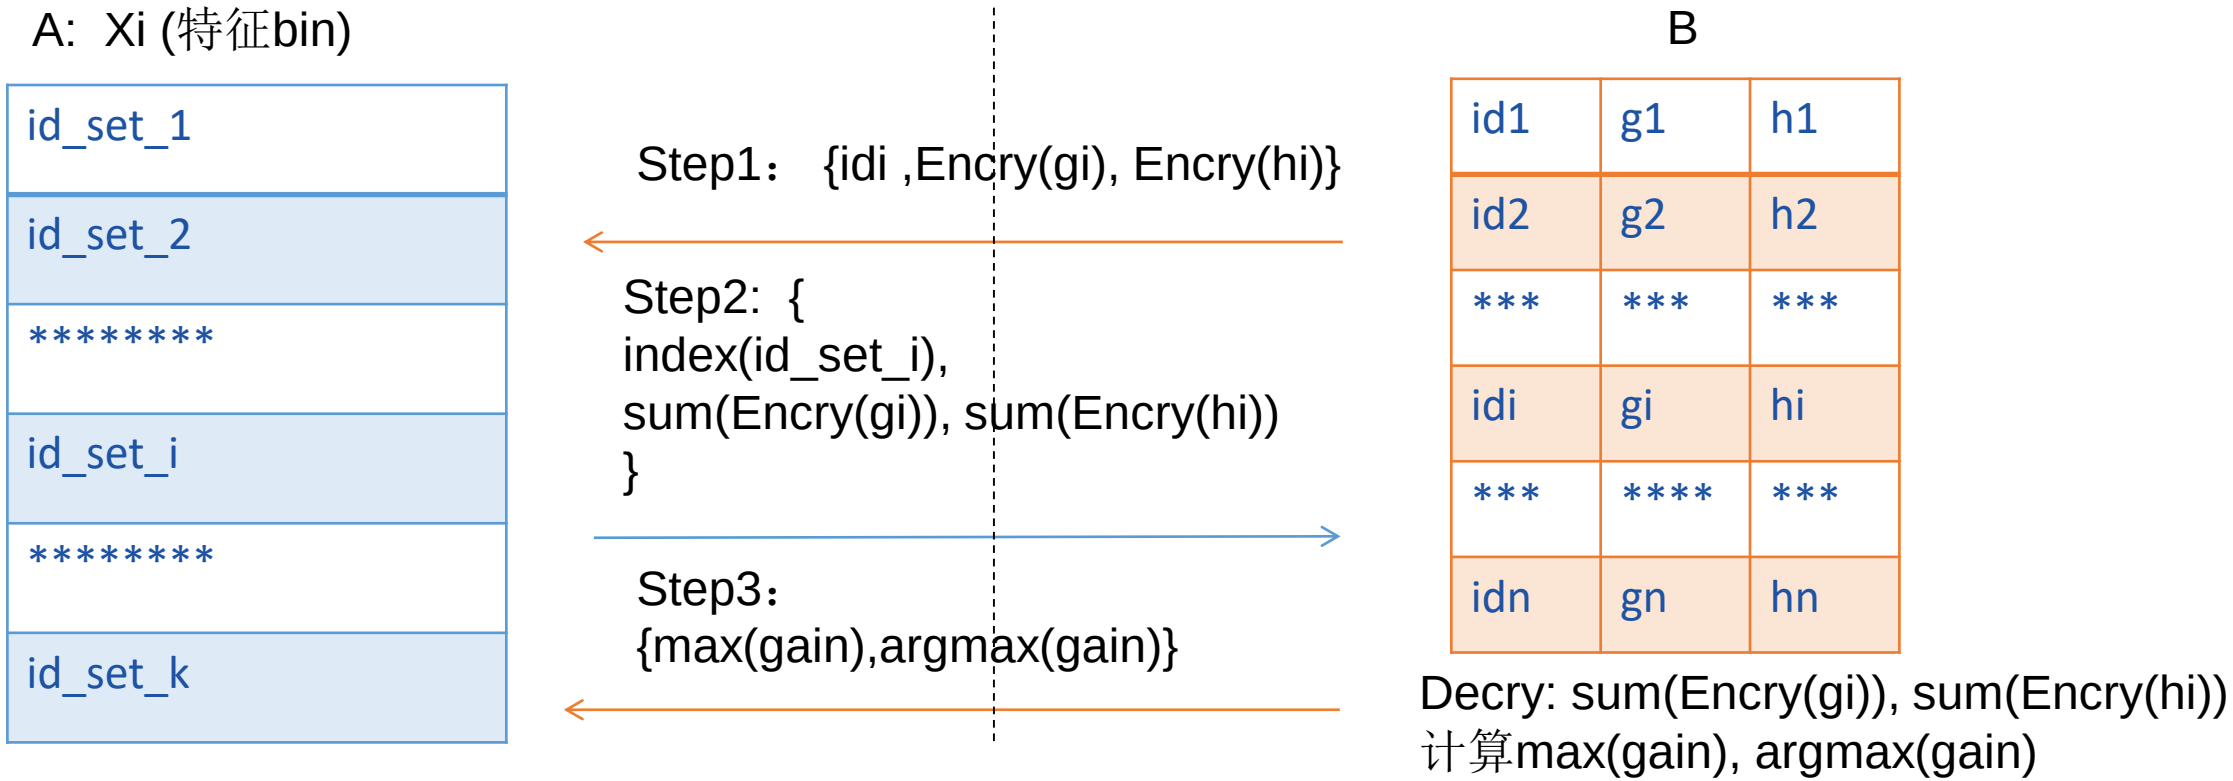

隐私保护：

- 信息增益是在B侧本地计算，B侧没有样本信息泄露
- A本地计算加密后的梯度直方图，B解密梯度直方图，但是不知道具体对应的id集合，保护了A侧id集合隐私信息

03

横向联邦学习

横向联邦学习-联合建模需求场景

举例：微众和合作行共建反洗钱模型，期望优化反洗钱模型

◆ 设定：

✓ Y 表示“是否存在洗钱行为”

✓ 合作行和微众都有（X,Y）

✓ 双方不暴露自己的（X,Y）

◆ 传统建模方法问题：

✓ 微众和合作行各自样本不够多

◆ 期望结果：

✓ 保护隐私条件下，建立联合模型

✓ 联合模型效果超过单边数据建模

微众银行

ID 证件号 电话号	X1 资金来源和经营范围不符笔数	X2 大额交易笔数	Y 表现数据
U1	5	15	有
U2	8	20	有
U3	0	5	无
U4	0	0	无
U5	2	1	无
U6	50	50	有
U7	60	6	有

业务系统A 数据

合作行

ID 证件号 电话号	X1 资金来源和经营范围不符笔数	X2 大额交易笔数	Y 表现数据
U8	5	10	有
U9	10	2	有
U10	2	30	有
U11	0	10	有
U12	8	7	有

业务系统B 数据

同态加密技术保护隐私

- ◆ 数据隐私保护：
  - ✓ 任何底层X，Y数据不向对方泄露
- ◆ 结果：
  - ✓ 联合模型比单独建模好

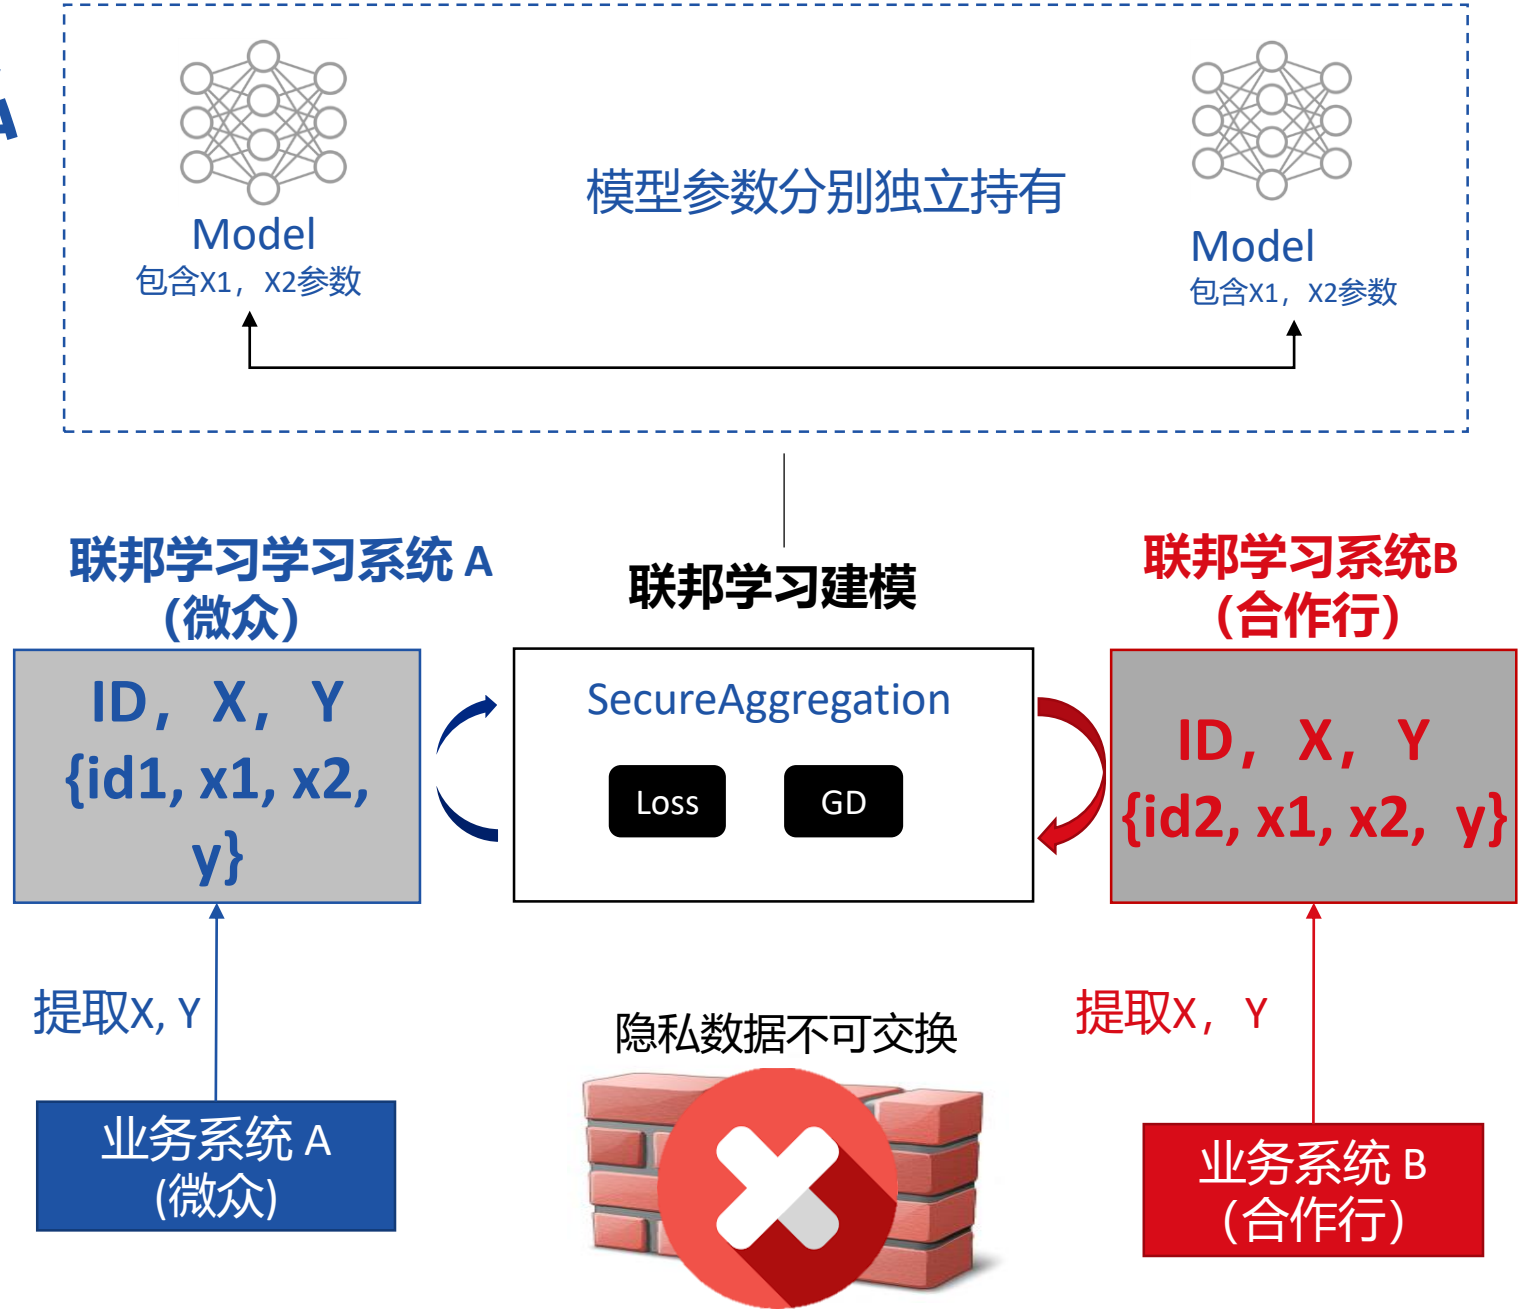

横向联邦核心技术点

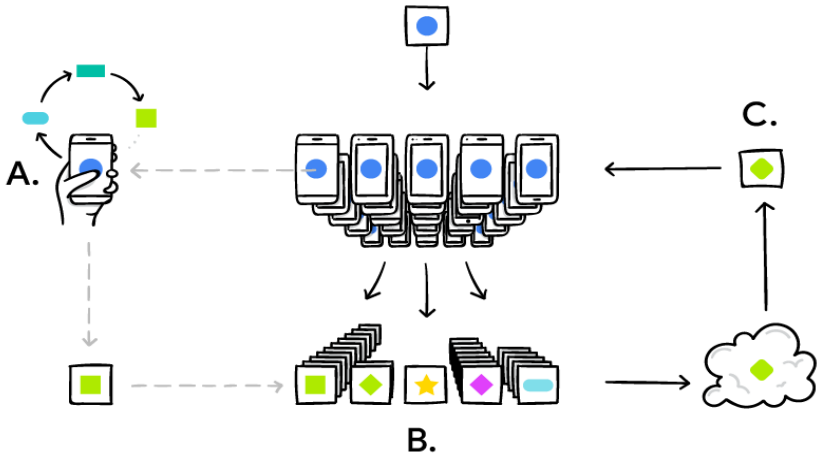

H. Brendan McMahan et al, *Communication-Efficient Learning of Deep Networks from Decentralized Data*, Google, 2017

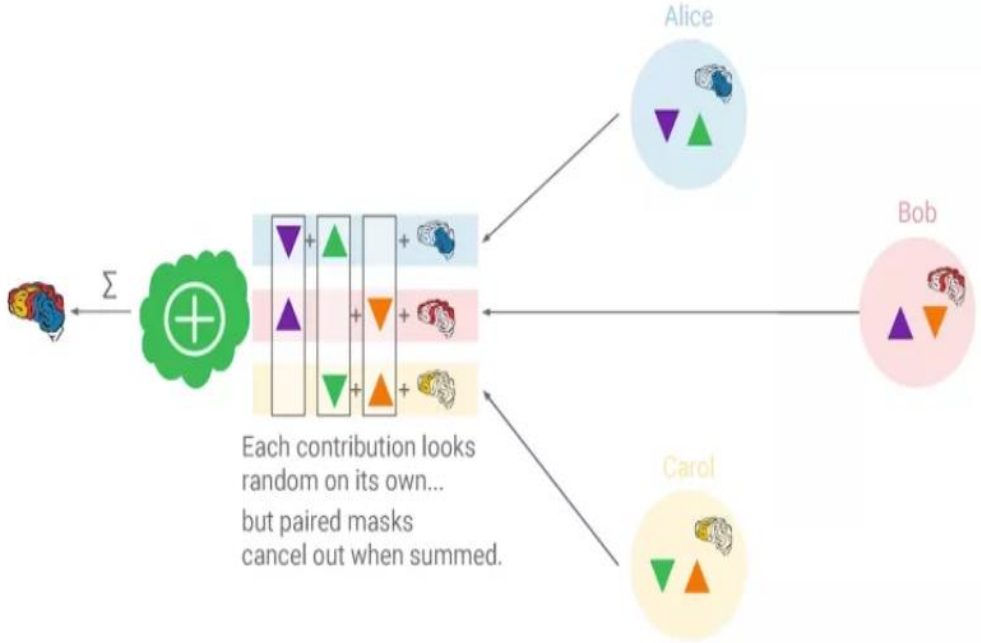

Bonawitz K, Ivanov V, Kreuter B, et al. Practical secure aggregation for privacy-preserving machine learning, Google, 2017

04

联邦学习开源平台-FATE

遇见FATE

愿景

- 工业级别联邦学习系统
- 有效帮助多个机构在符合数据安全和政府法规前提下，进行数据使用和联合建模

设计原则

- 支持多种主流算法：为机器学习、深度学习、迁移学习提供高性能联邦学习机制
- 支持多种多方安全计算协议：同态加密、秘密共享、哈希散列等
- 友好的跨域交互信息管理方案，解决了联邦学习信息安全审计难的问题

首次发布

2019年1月份，FATE宣布对外开源

Github：https://github.com/WeBankFinTech/FATE

里程碑

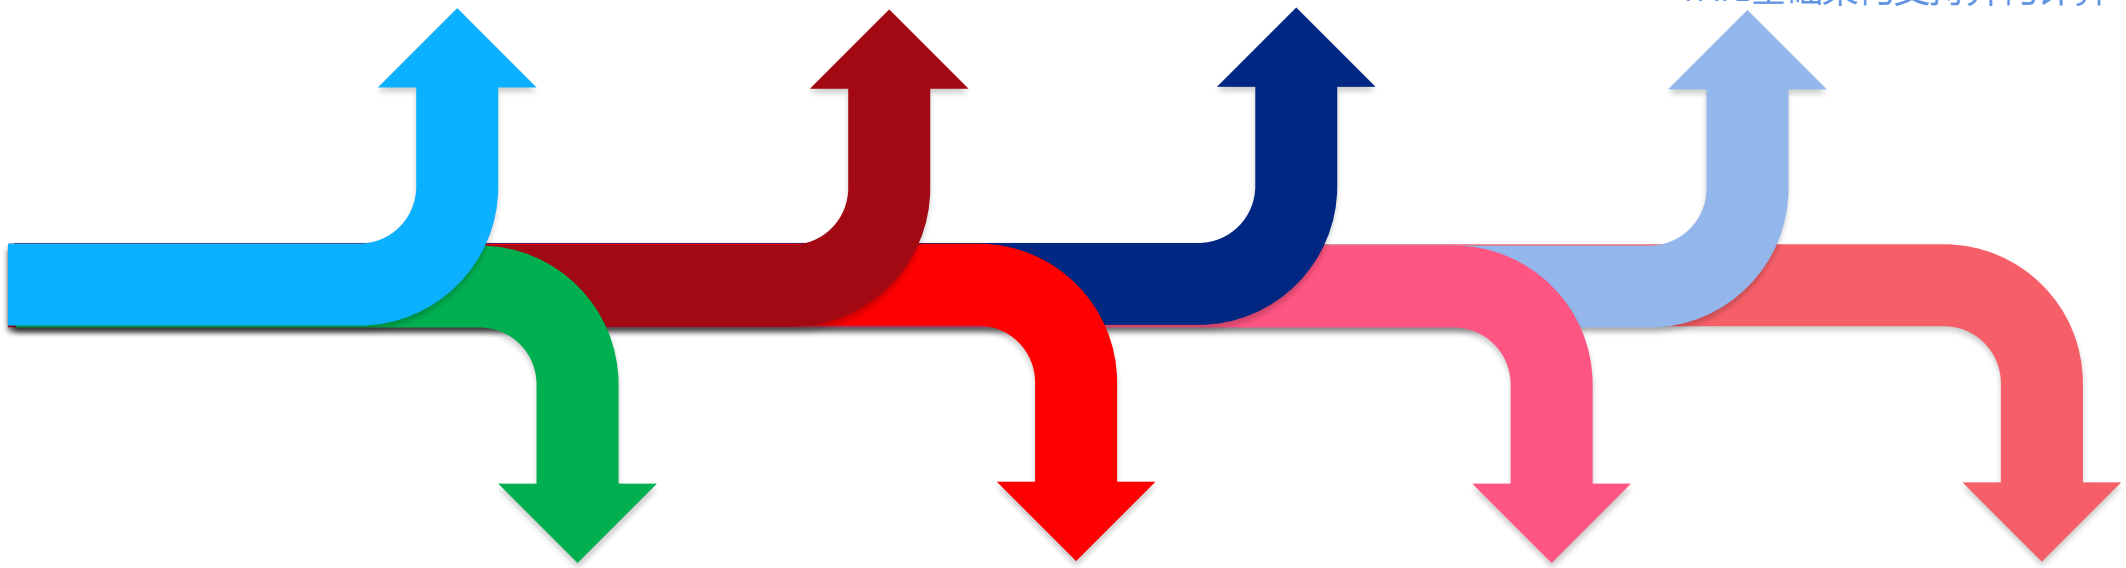

2019.02

FATEv0.1 首发

201903

GitHubStar 突破100

诞生第一位外部Contributor

201905

发布FATEv0.2版本

发布FATE-Serving

201906

发布FATEv0.3版本

FDN主要合作伙伴升级到FATE

FATE捐献Linux Fundation

201908

发布FATEv1.0版本

发布FATE-FLOW | FATEBoard

201909

发布FATE-v1.1版本

支持SecretShare协议

支持联邦深度学习

支持联邦统计计算

201911

发布FATE-v1.2版本

发布FATE-Script

FATE基础架构支持异构计算

201912

发布FATE-v1.3版本

支持深度学习模型加密

Inference

挑战 Challenges in developing a real-world Federated AI

- 一站式建模过程的联邦化
- MPC协议下分布式算法（on WAN）易理解和易维护
- 跨站点数据传输安全性和可管理性
- 异构基础架构自适应

技术架构总览

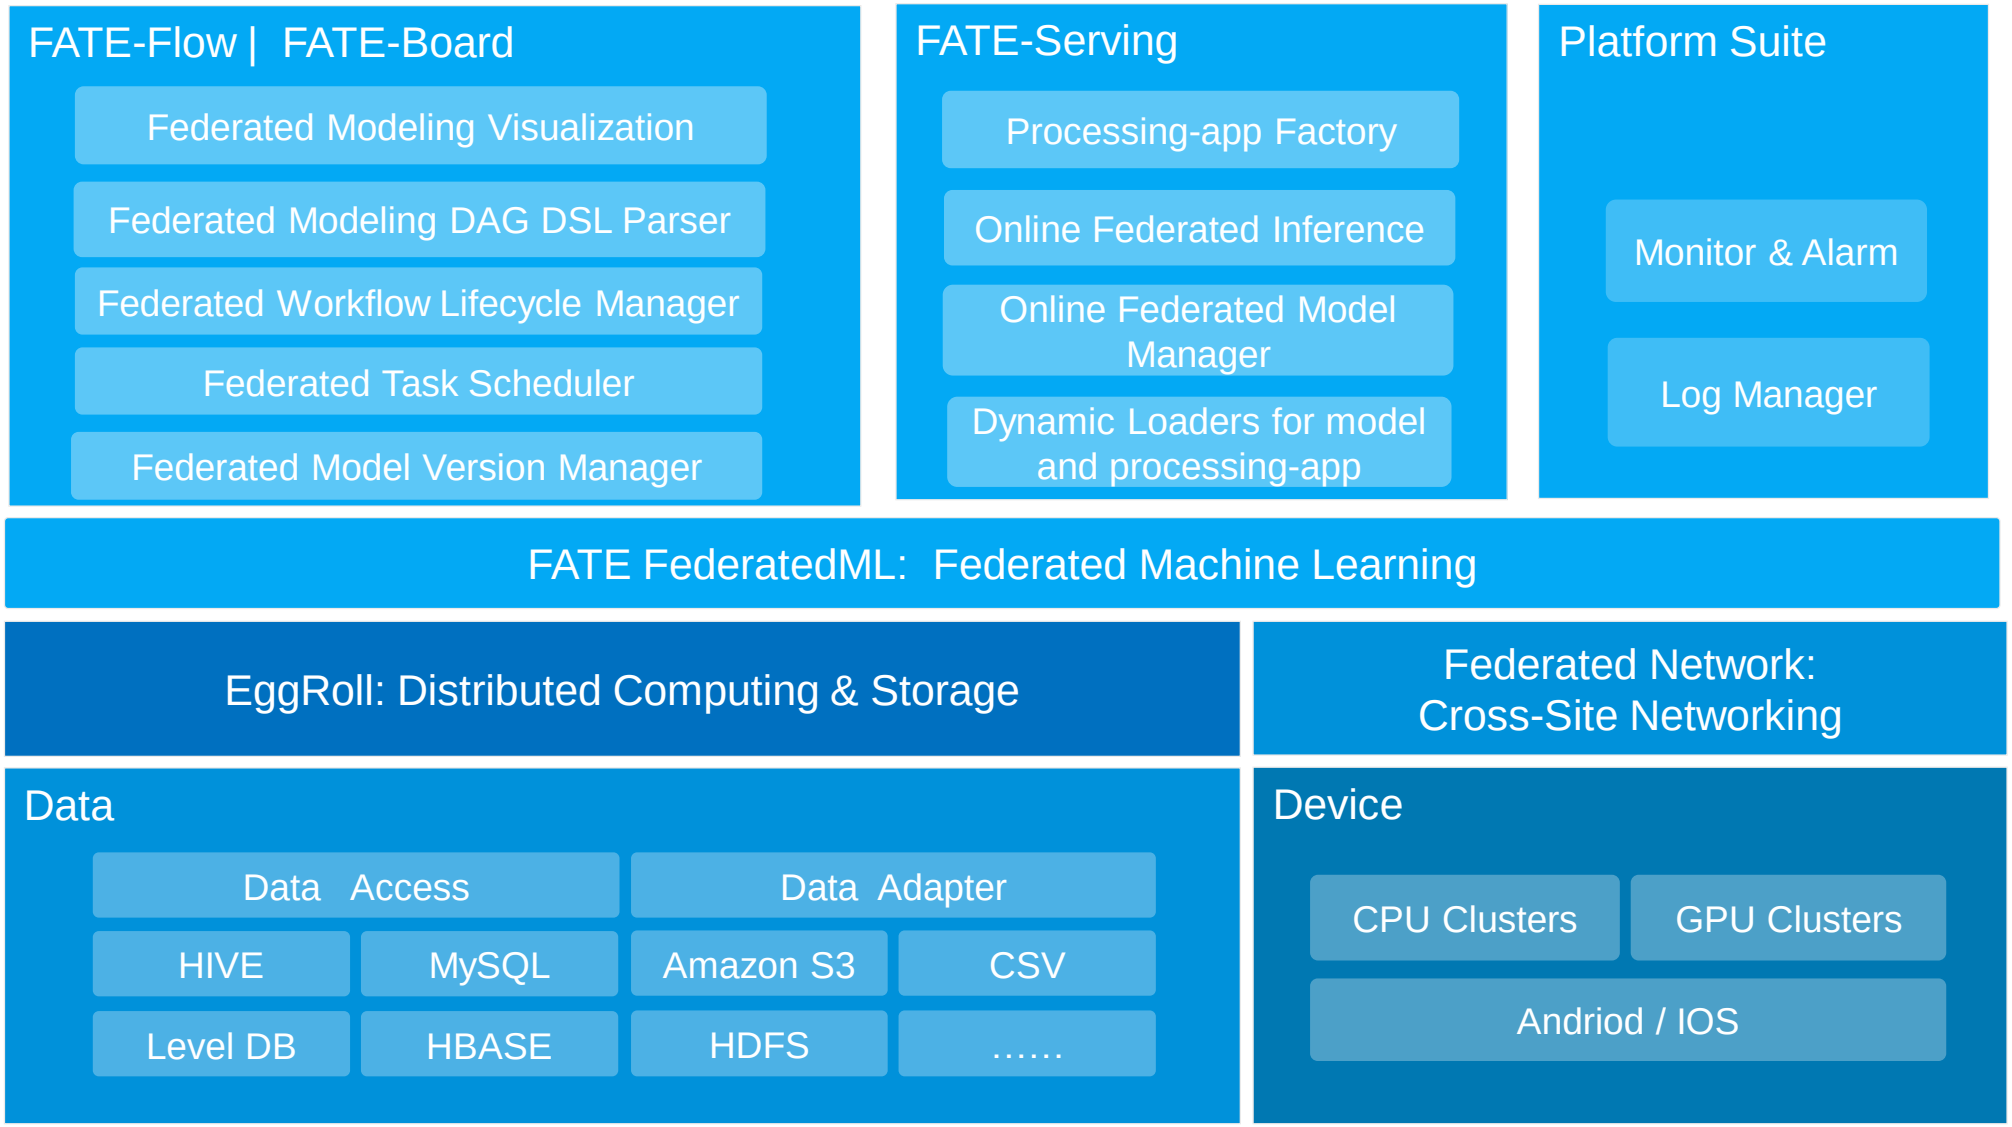
FATE-Flow | FATE-Board
Federated Modeling Visualization
Federated Modeling DAG DSL Parser
Federated Workflow Lifecycle Manager
Federated Task Scheduler
Federated Model Version Manager
FATE-Serving
Processing-app Factory
Online Federated Inference
Online Federated Model Manager
Dynamic Loaders for model and processing-app
Platform Suite
Monitor & Alarm
Log Manager
FATE FederatedML: Federated Machine Learning
EggRoll: Distributed Computing & Storage
Federated Network: Cross-Site Networking
Data
Data Access
Data Adapter
HIVE
MySQL
Amazon S3
CSV
Level DB
HBASE
HDFS
……
Device
CPU Clusters
GPU Clusters
Andriod / IOS

一站式联合建模Pipeline

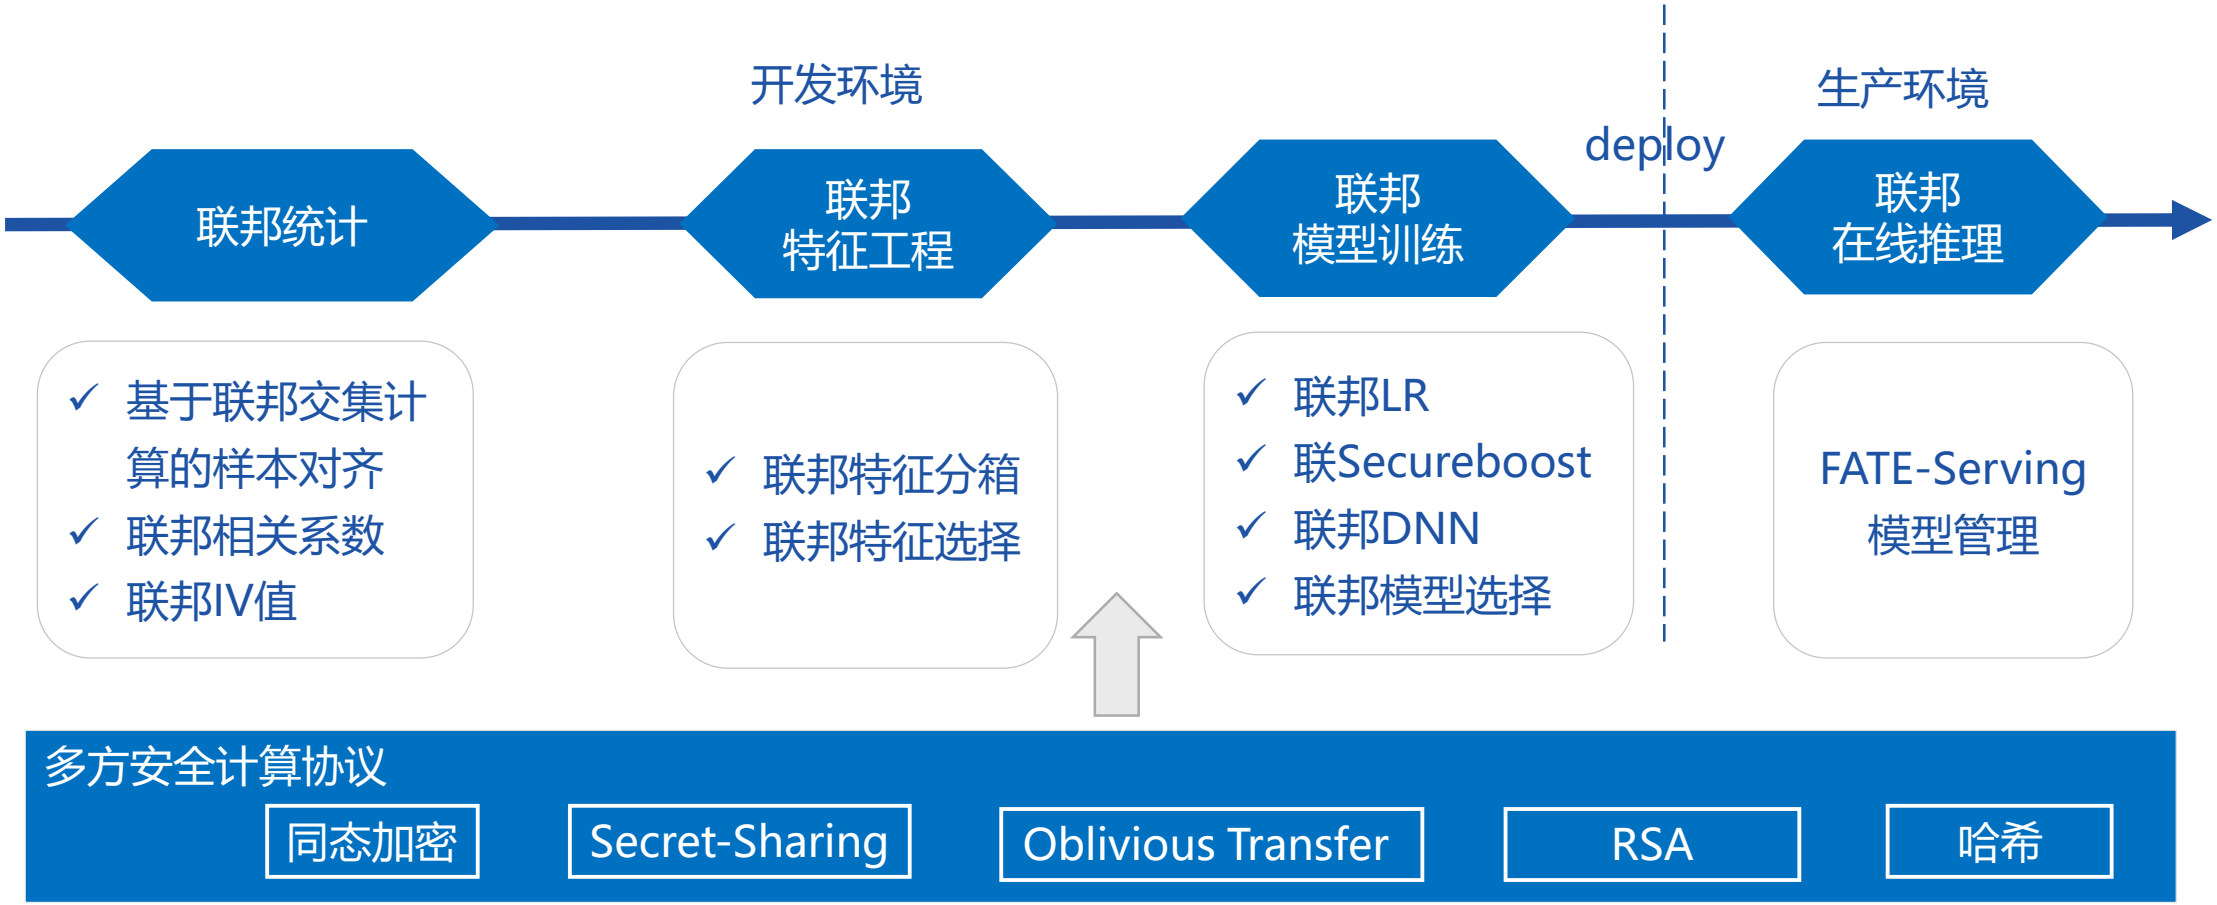

核心功能

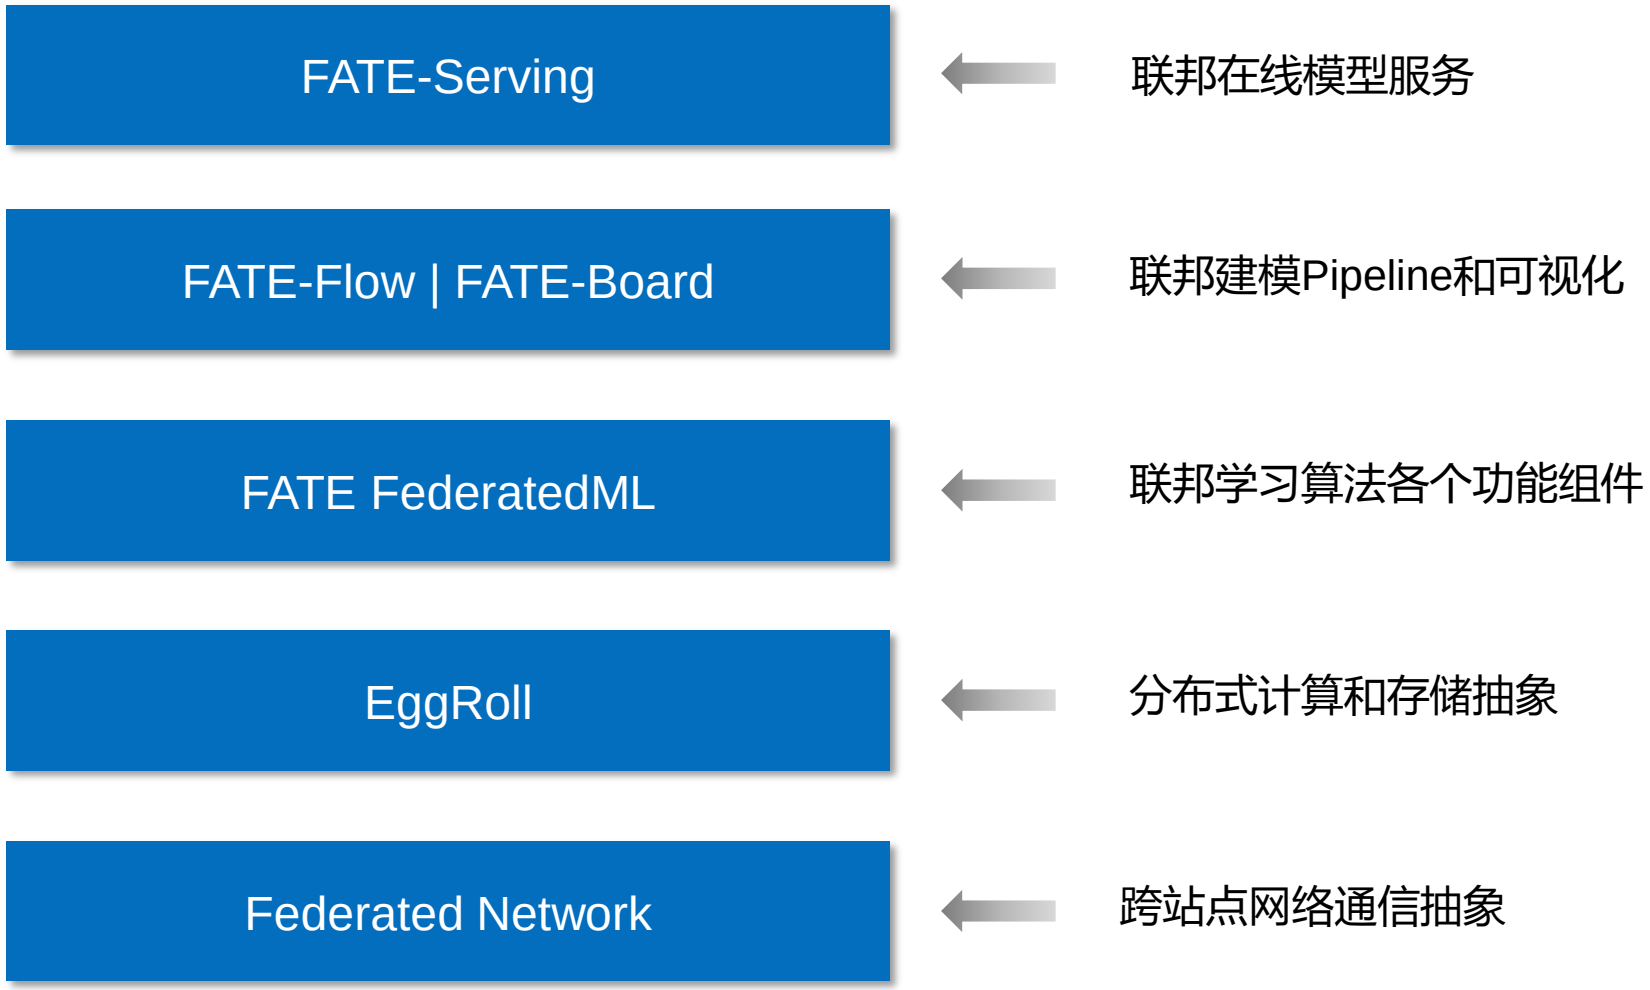
FATE-Serving
联邦在线模型服务
FATE-Flow | FATE-Board
联邦建模Pipeline和可视化
FATE FederatedML
联邦学习算法各个功能组件
EggRoll
分布式计算和存储抽象
Federated Network
跨站点网络通信抽象

FATE-Flow

- 联邦机制下多方非对称DAG图Paser
- 联邦建模生命周期管理
- 联邦建模实验管理
- 联邦建模模型管理
- 联邦多方任务调度

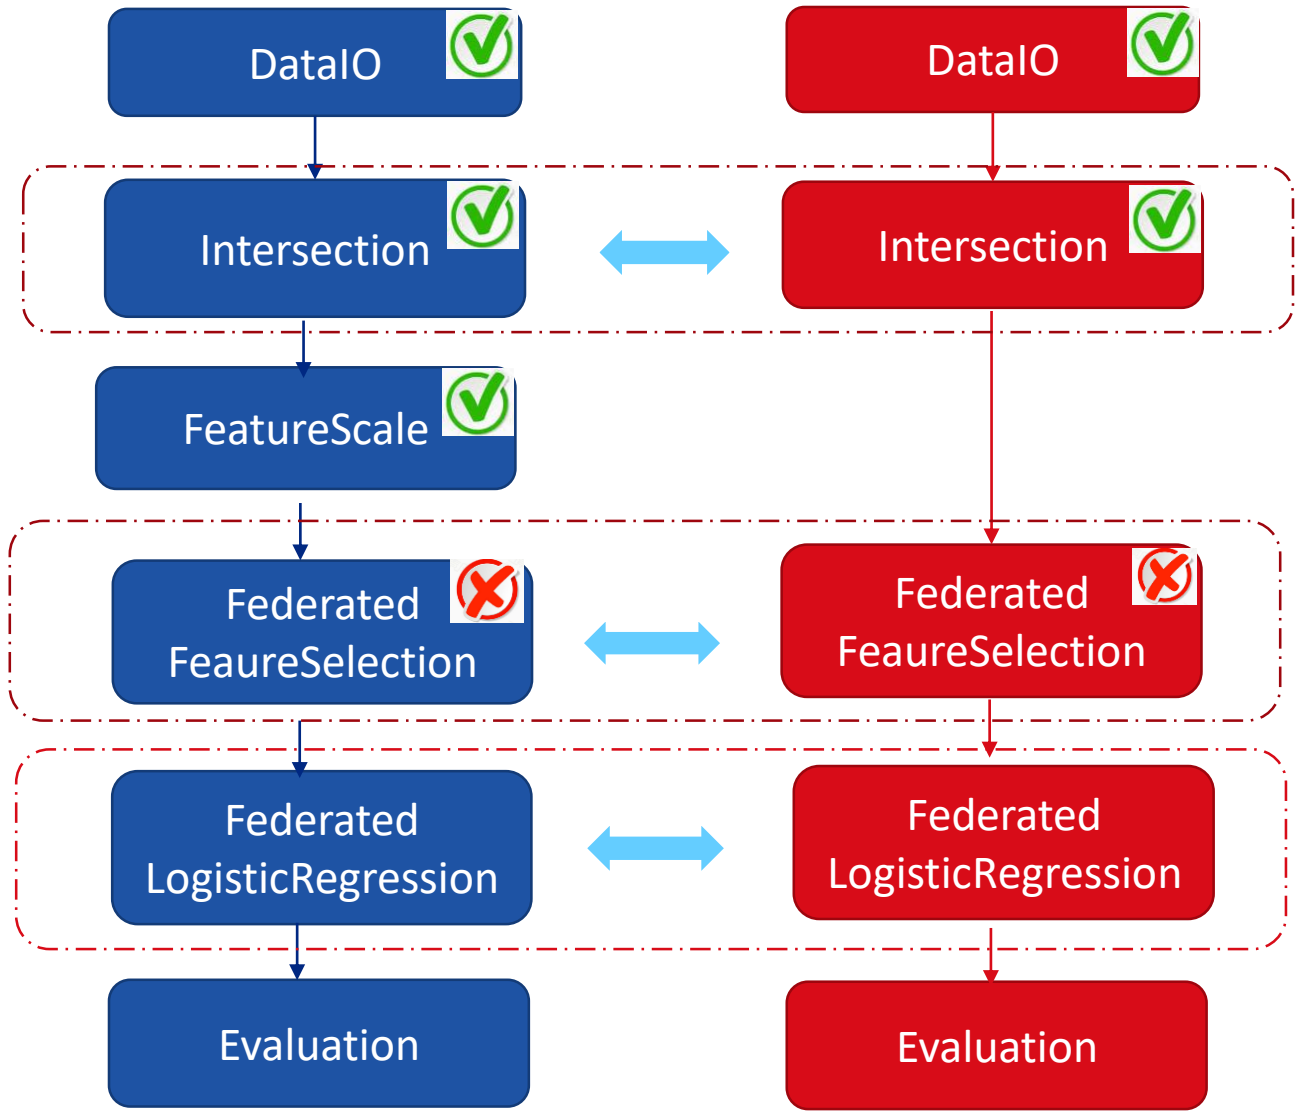

FATE-Board

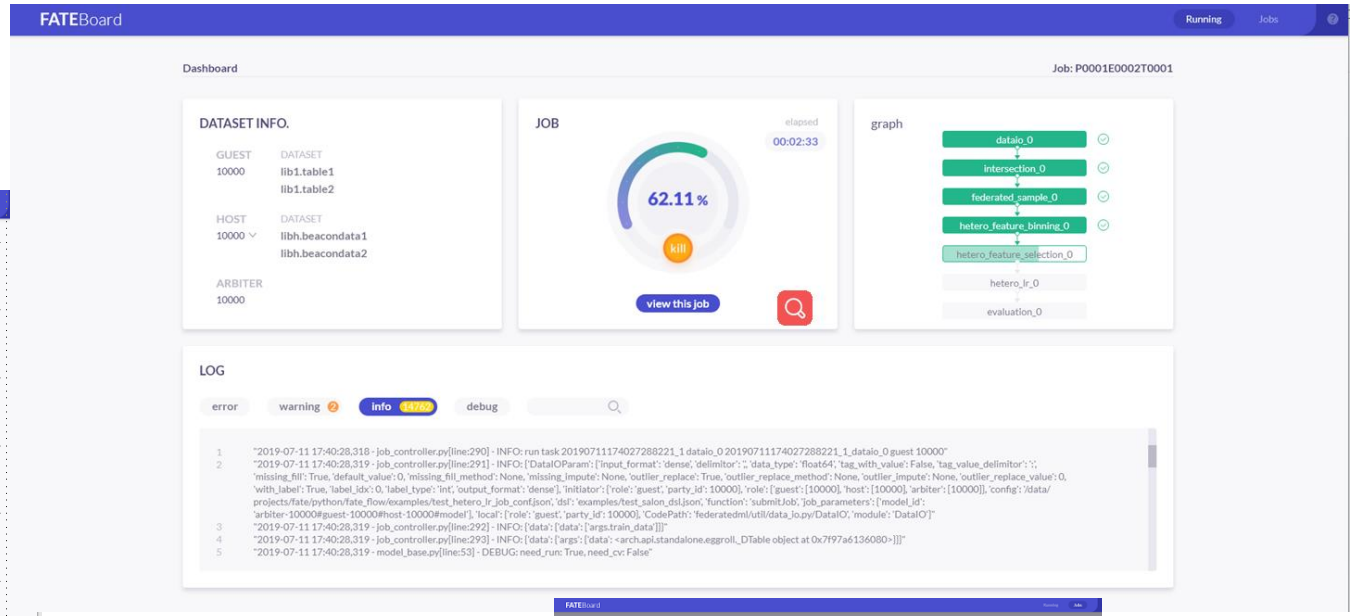

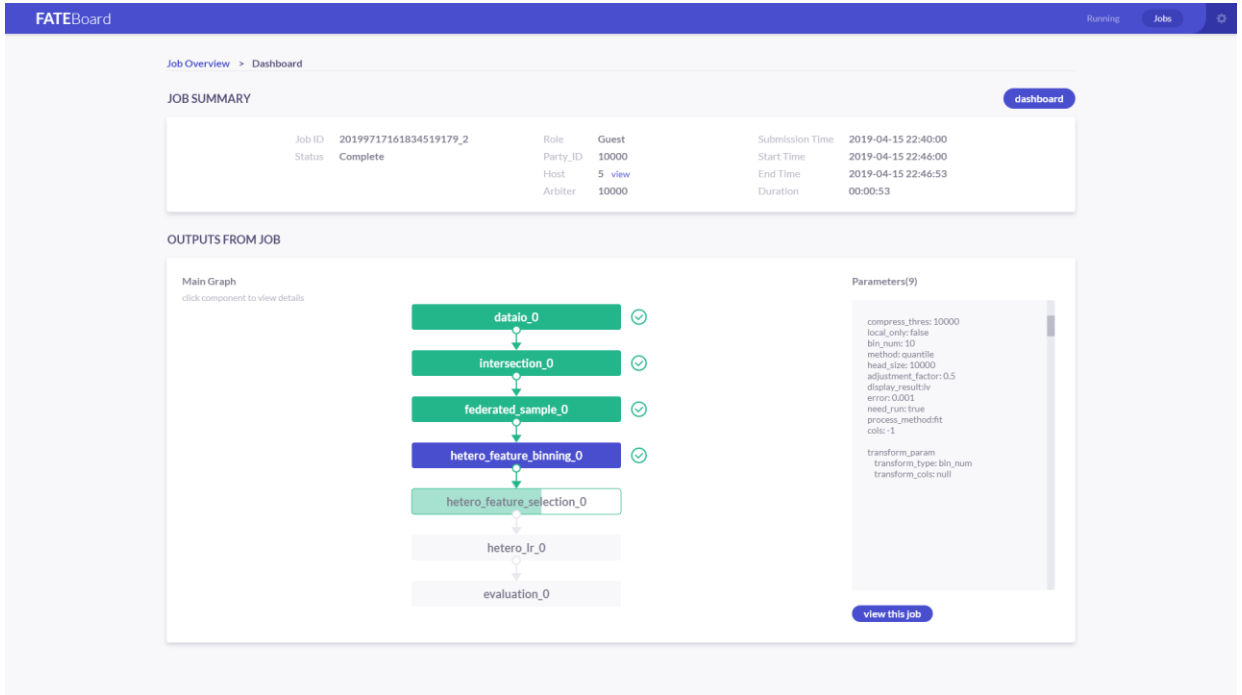

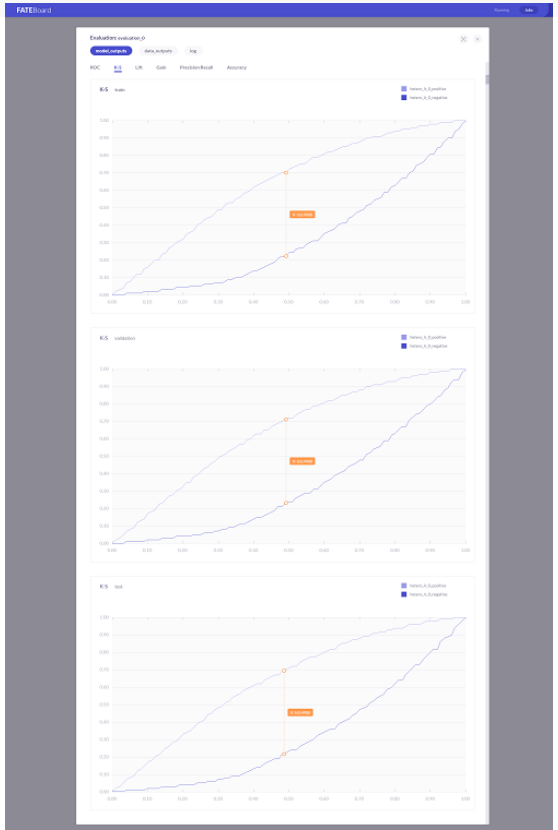

WeBank

FATE FederatedML

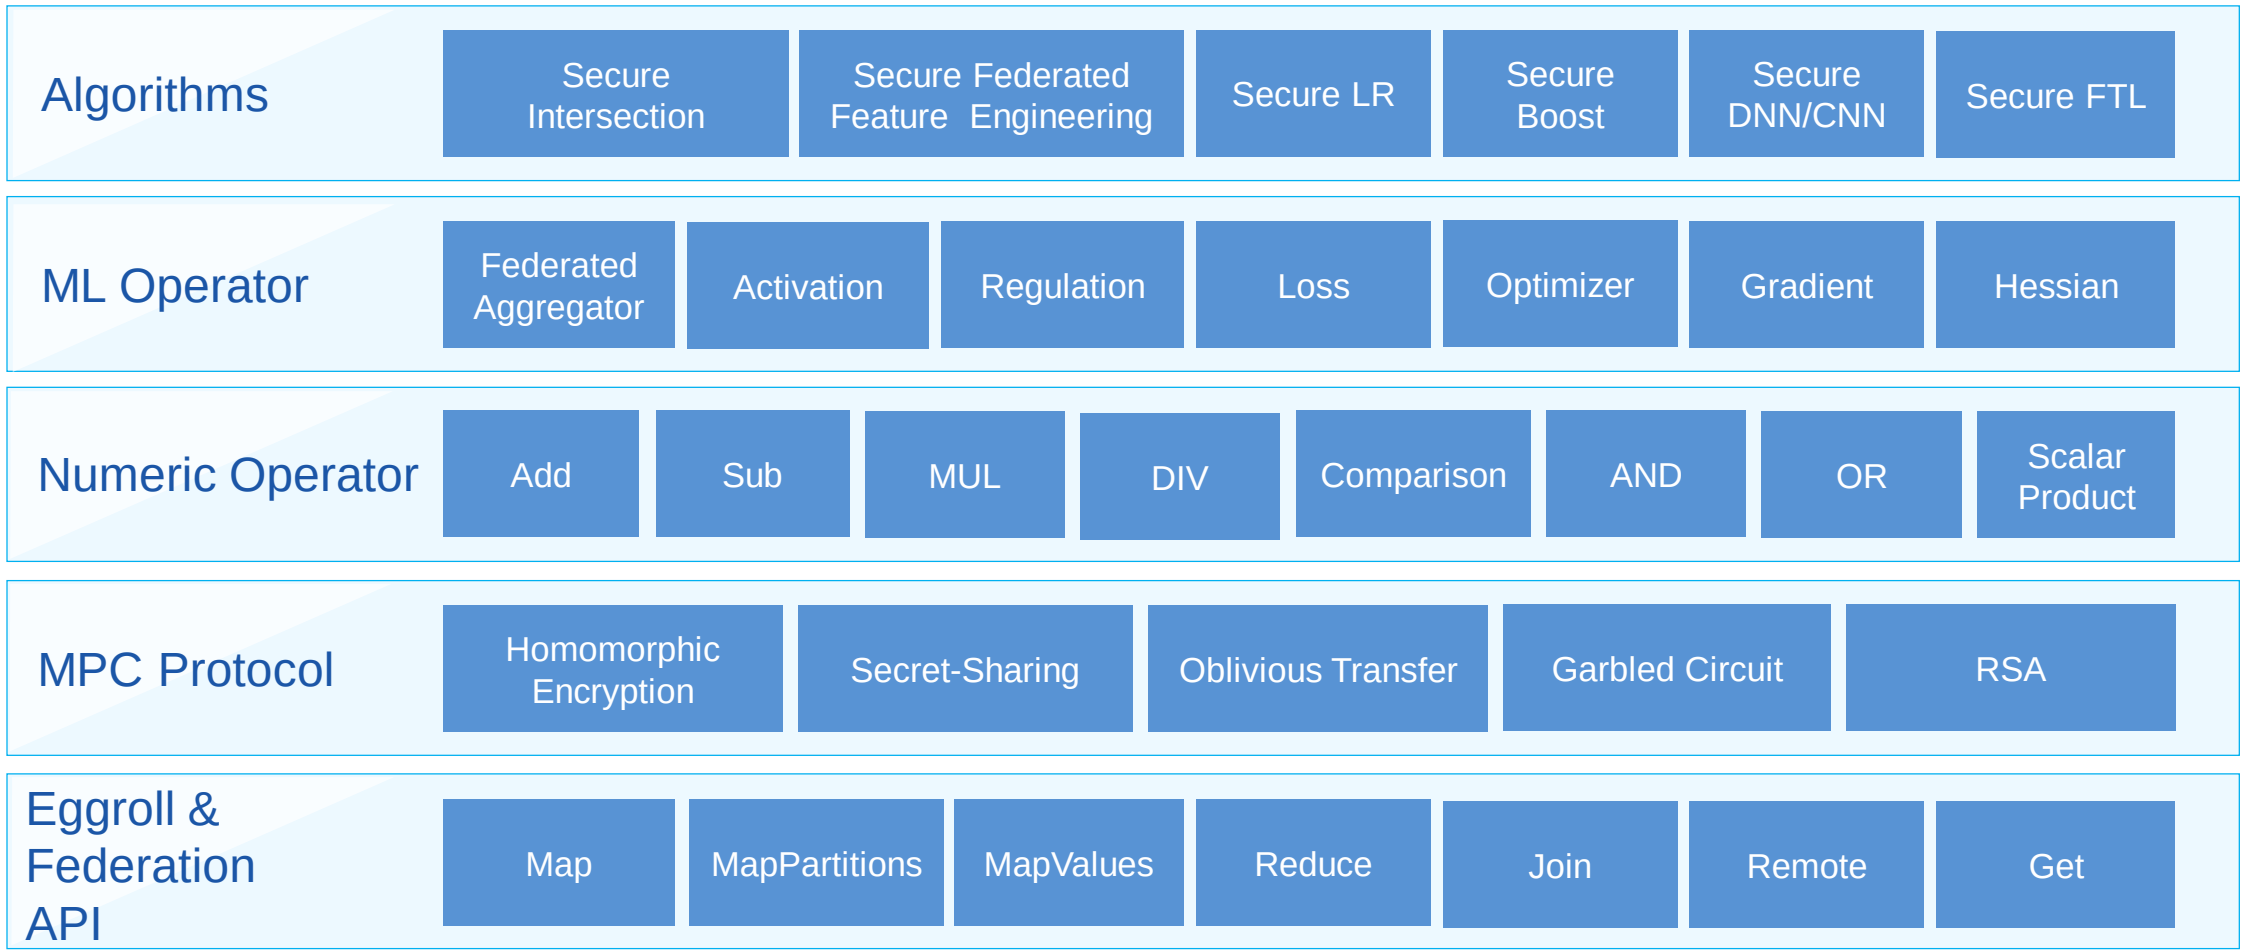

EggRoll

- **编程框架**
  - EggRoll API：面向算法开发者，通过API实现分布式计算.
- **计算/存储架构**
  - 联邦学习一方分布式计算和存储
  - 模块
    - Meta-Service: 元信息管理
    - Roll: 数据 / 计算 调度 (to eggs), 聚合操作等
    - Egg: 计算、存储引擎

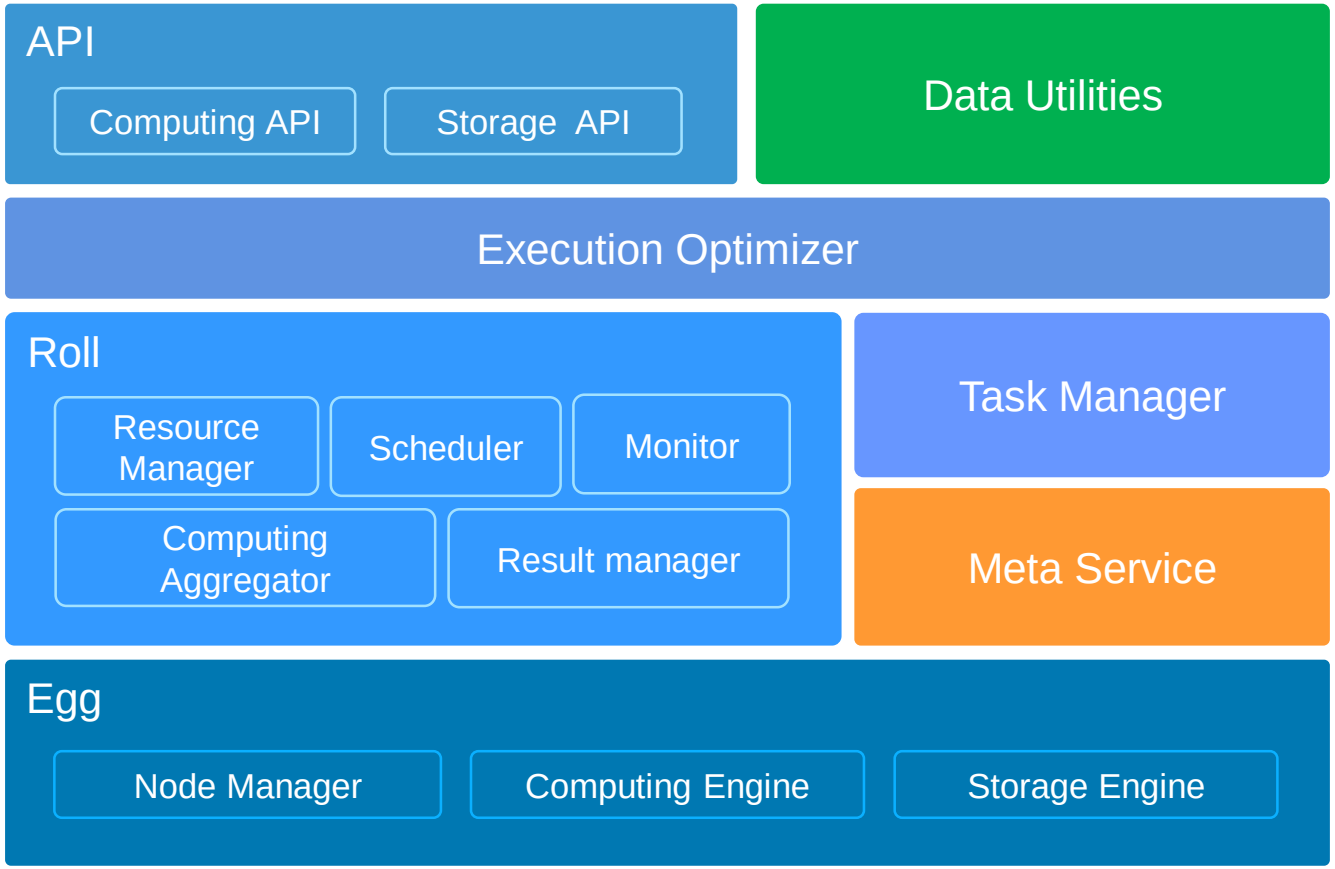

Federated Network

- **编程框架**
  - Federation API：面向算法开发者，通过API实现跨站点通信和交互.
- **通信架构**
  - 联邦学习多个参与方跨站点通信
  - 模块
    - Meta-Service: 元信息管理
    - Proxy: 应用层联邦学习路由
    - Federation: Global Object（i.e. data to be ‘federated’ among parties）抽象和实现
    - FATE-Exchange

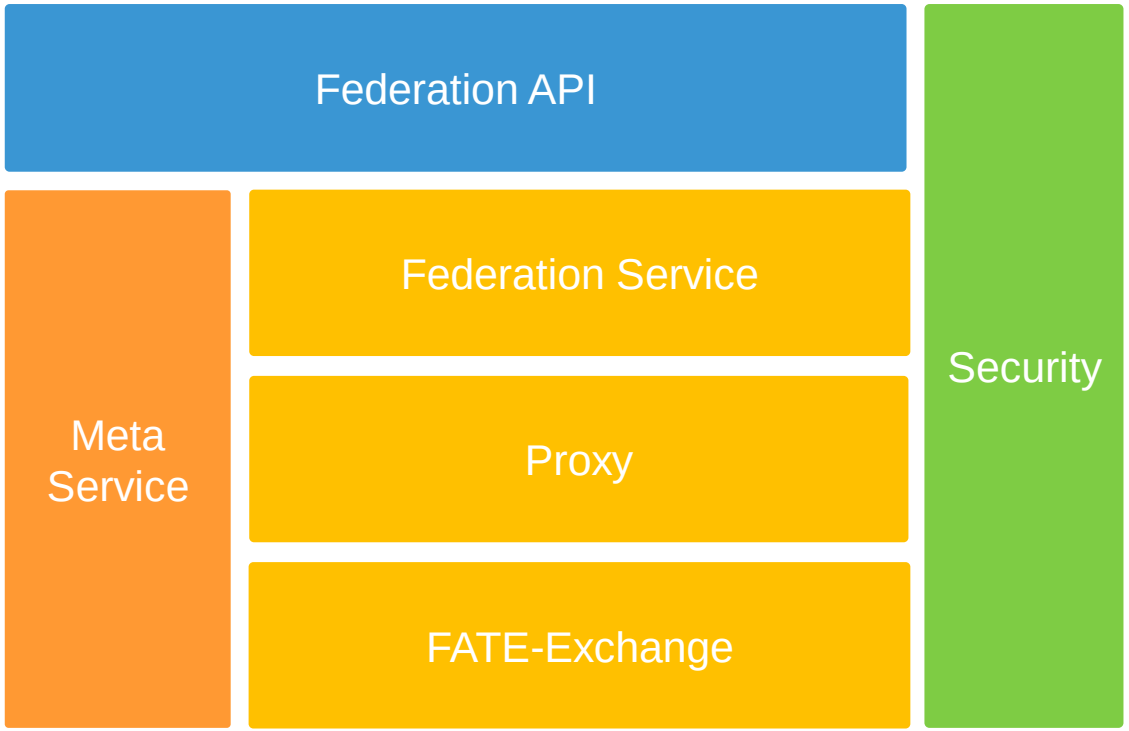

一方部署网络拓扑-示例

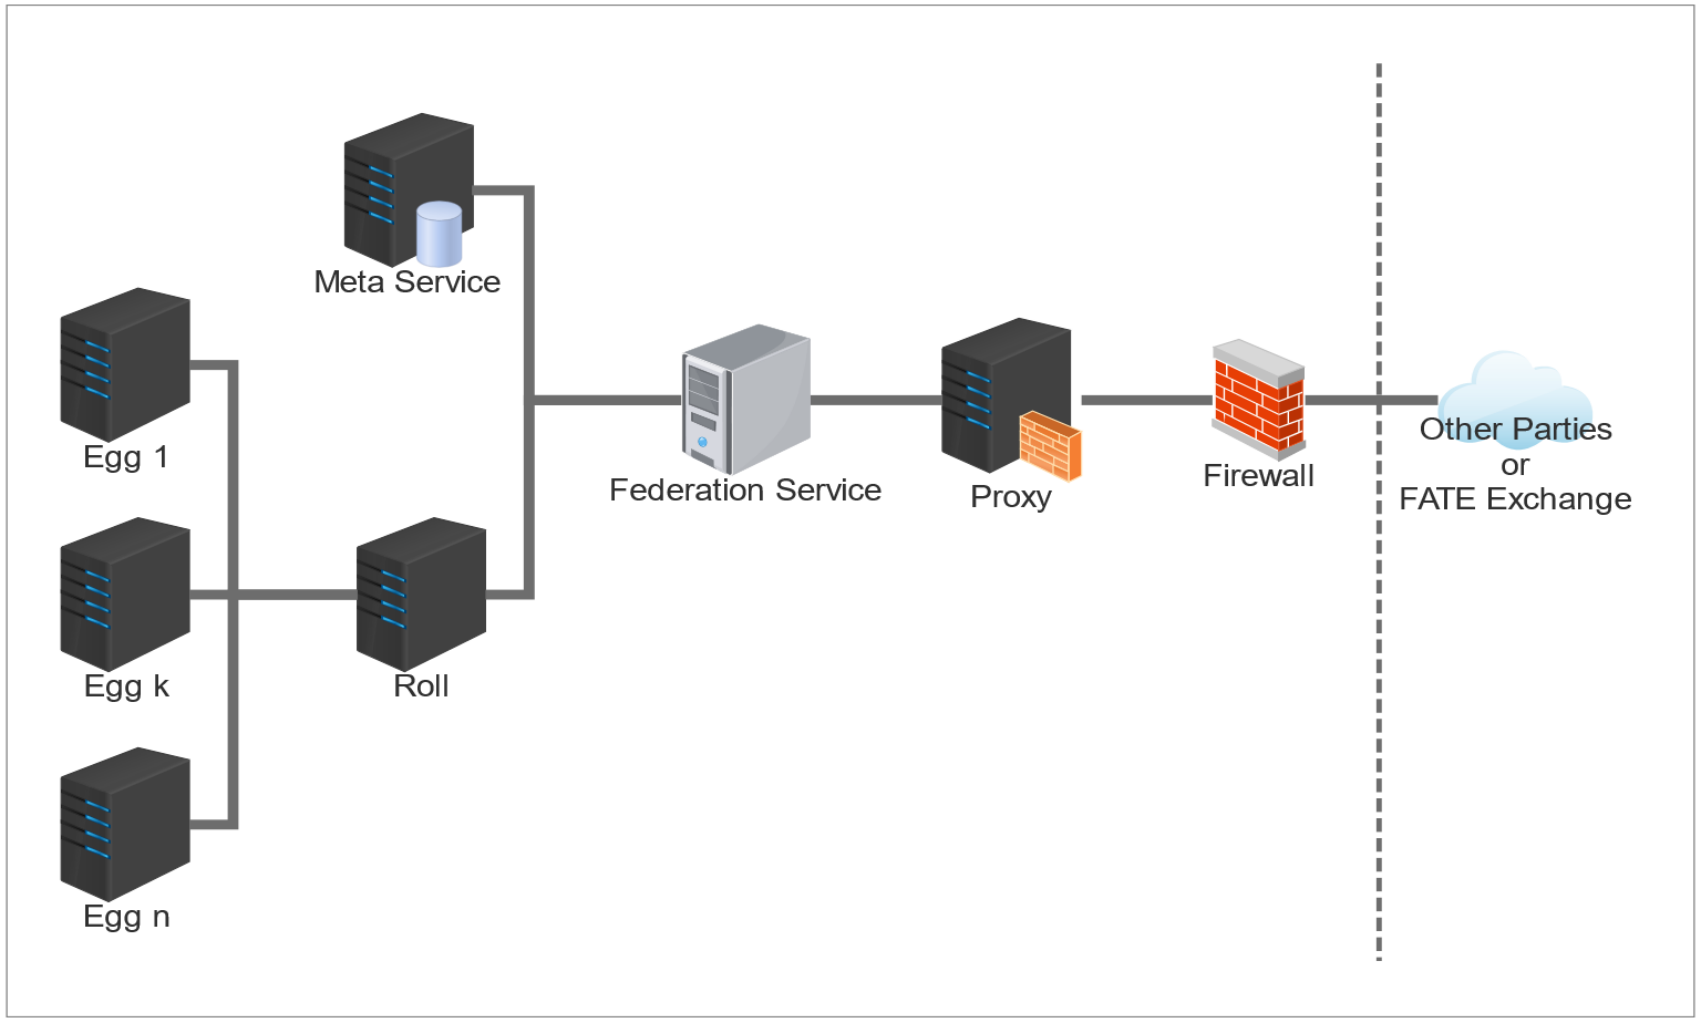
Meta Service
Egg 1
Egg k
Egg n
Roll
Federation Service
Proxy
Firewall
Other Parties
or
FATE Exchange

基于FATE的联合建模

联合建模、预测示意图 —— 安全合规的数据合作过程

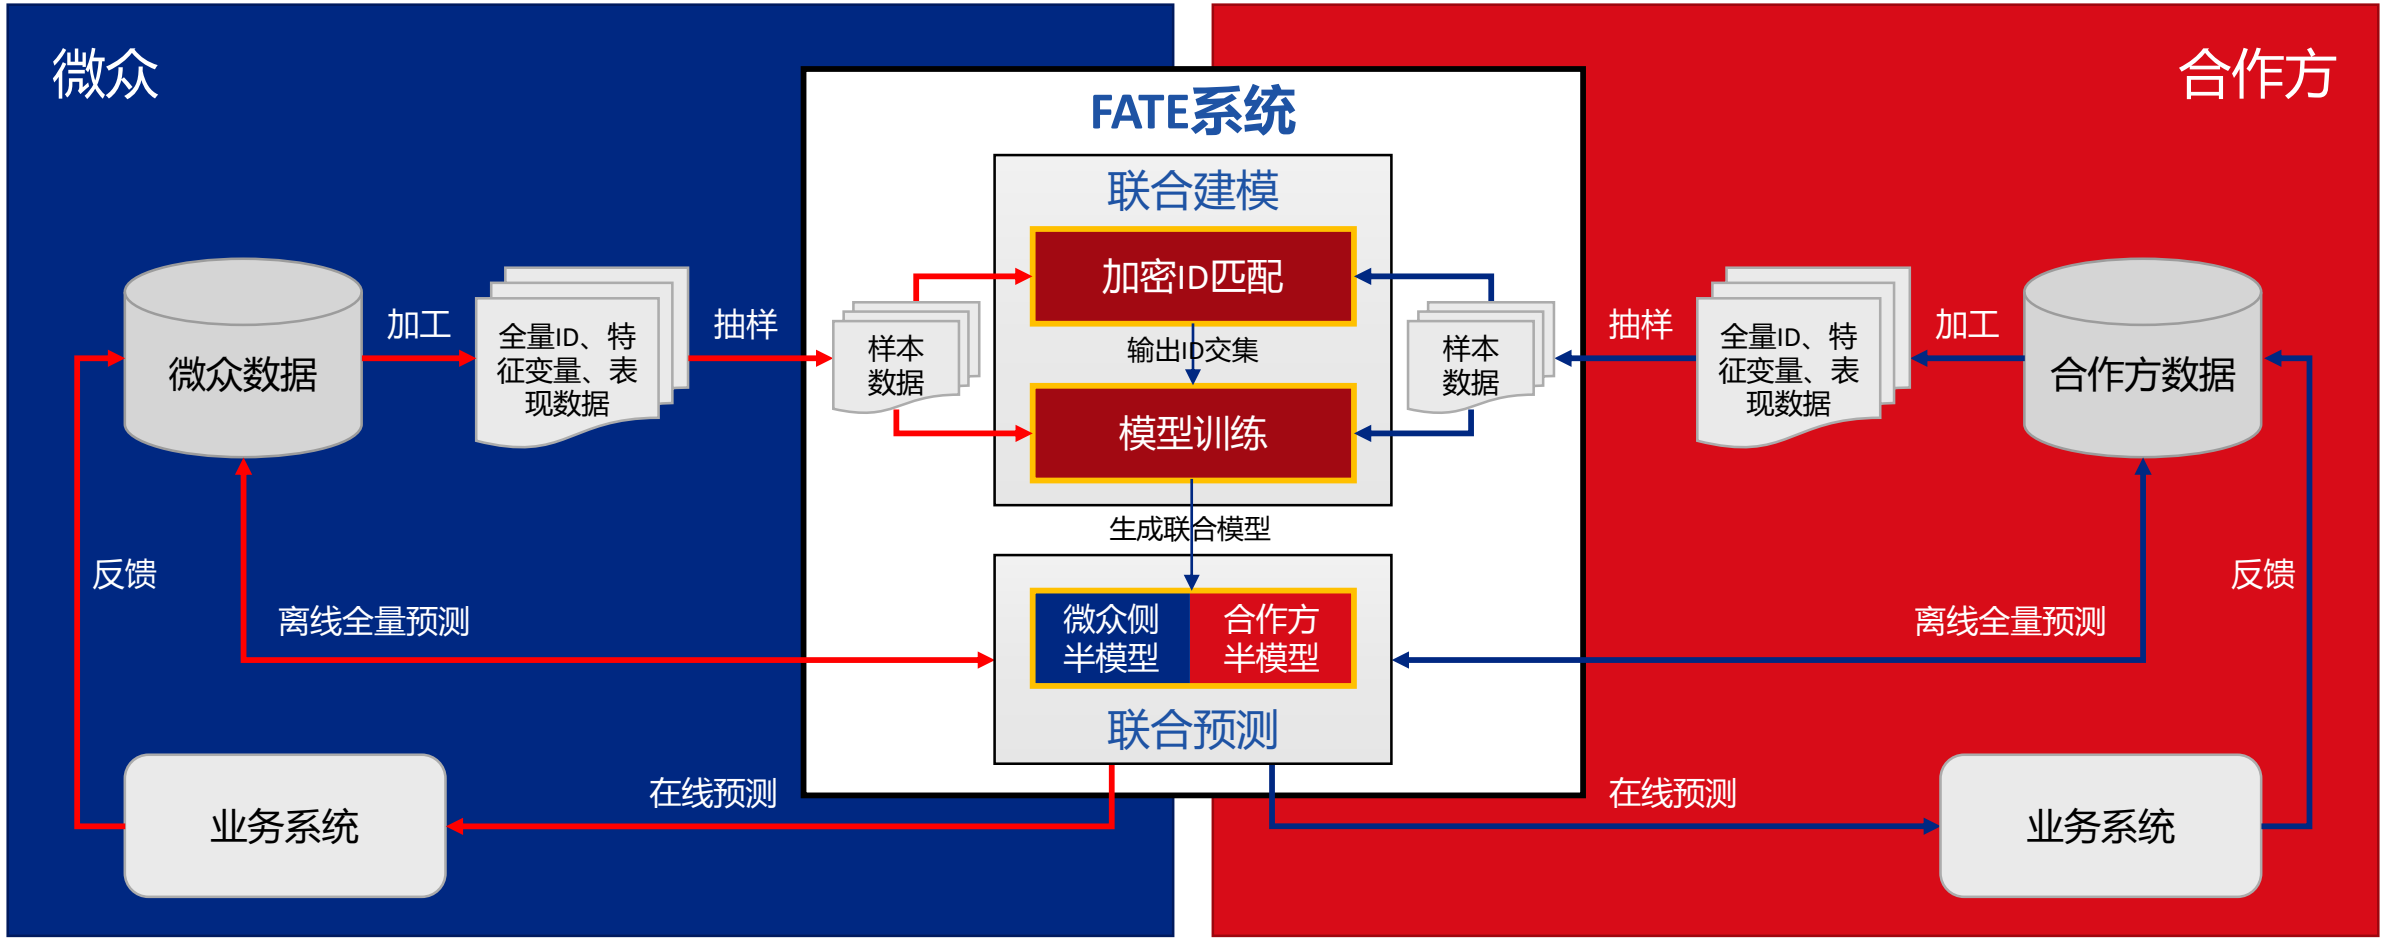

注：客户ID包括但不限于客户身份证号码、手机号、设备ID（imei）等； 联合建模过程由拥有Y（表现数据）的一方发起；

开发流程

1. 选择一个机器学习算法，设计多方安全计算协议
2. 定义多方交互的数据变量
3. 构建算法执行工作流
4. 基于EggRoll & Federation Api 实现算法工作流中各个功能组件

目前 FATE 项目中算法&案例

- Secure Intersection for Sample Alignment
- Vertical-Split Feature Space Federated Feature Engineering
  - Secure Feature Binning
  - Secure Feature Selection
  - Secure Feature Correlation（Coming Soon）
- Vertical-Split Feature Space Federated Learning
  - Secure Logistic Regression
  - Secure Boosting Tree
  - Secure DNN/CNN（Coming Soon）
- Horizontal-Split Sample Space Federated Learning
  - Secure Logistic Regression
  - Secure Boosting Tree（Coming Soon）
  - Secure DNN/CNN（Coming Soon）
- Secure Federated Transfer Learning

关注FATE

FATE GitHub主页

FATE 微信小助手

Join FATE，Let’s Federated Everything!

官网：**https://www.fedai.org/**

邮箱：**contact@fedai.org**