



# 人工智能系统 System for AI

## 深度学习中的分布式训练 ——算法

Distributed training algorithms



# 课程概要

分布式计算简介

深度学习并行训练简介

分布式训练算法分类

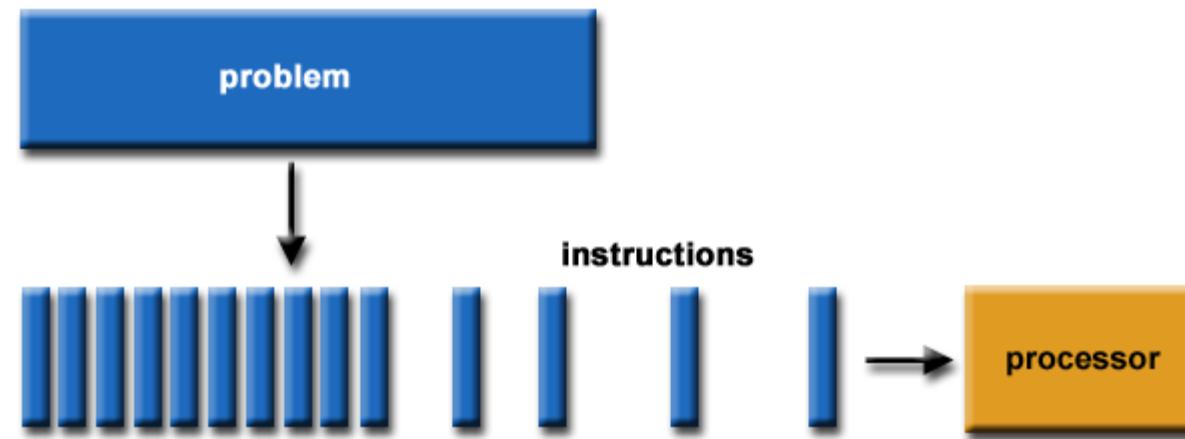
深度学习并行训练实例

# 分布式计算



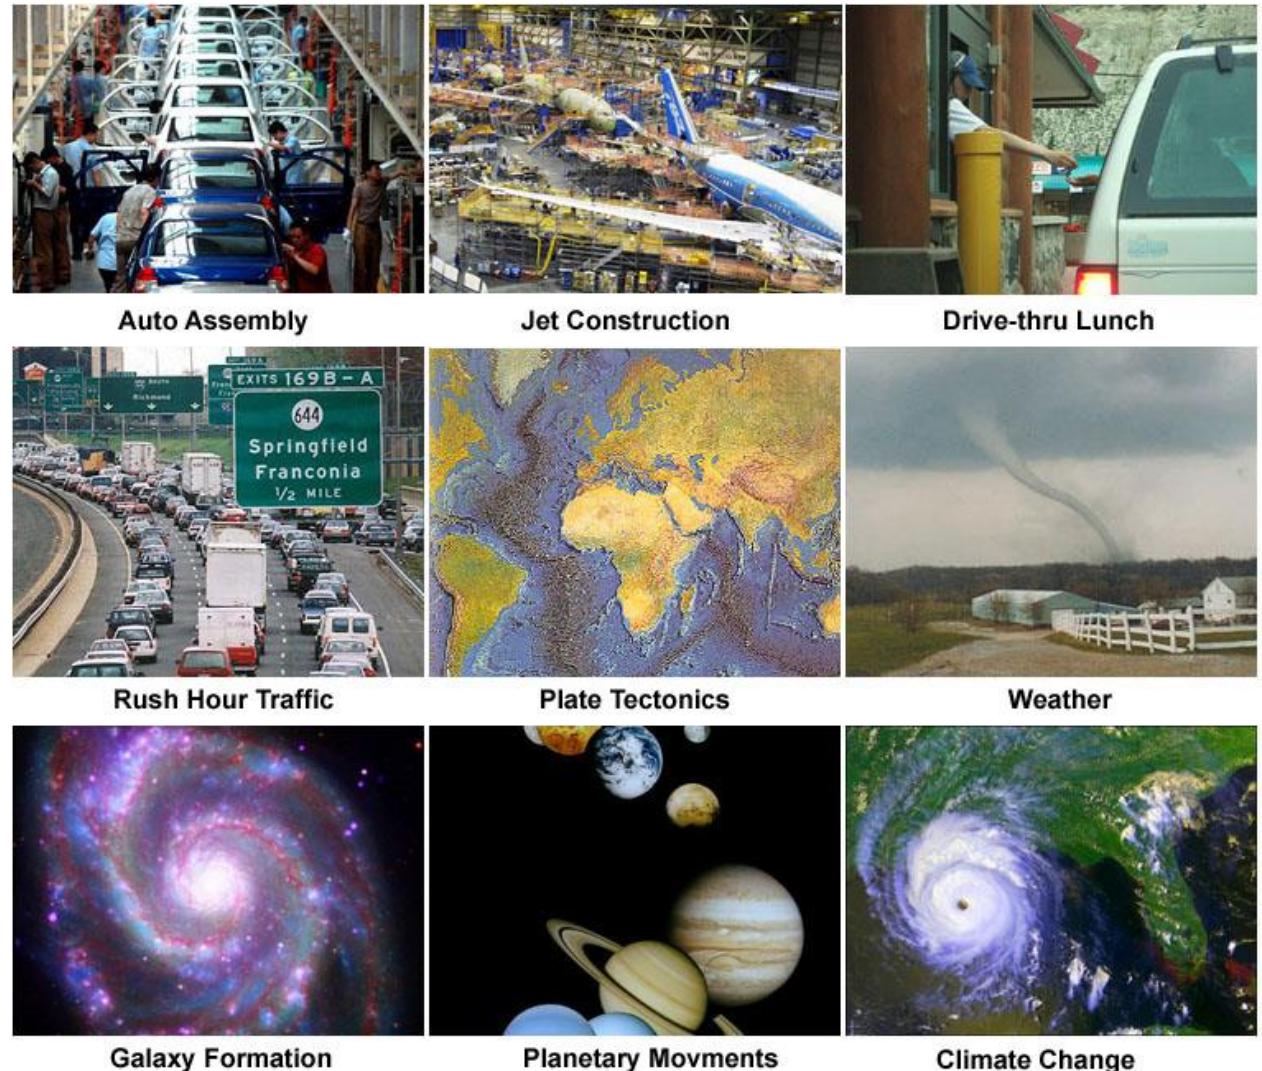
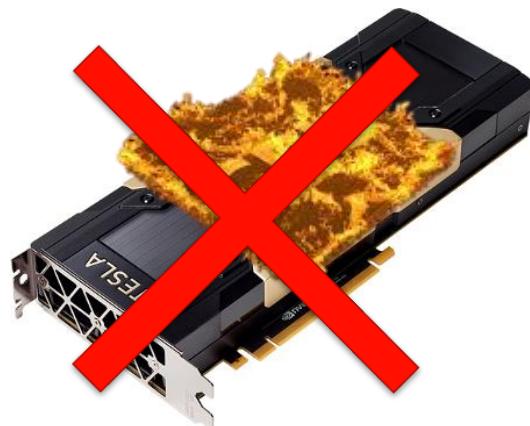
# 从串行计算到并行计算

## 单处理器串行执行



# 从串行计算到并行计算

问题规模 (数据量+计算量)  
逐渐增大, **单一设备**处理速  
度无法满足



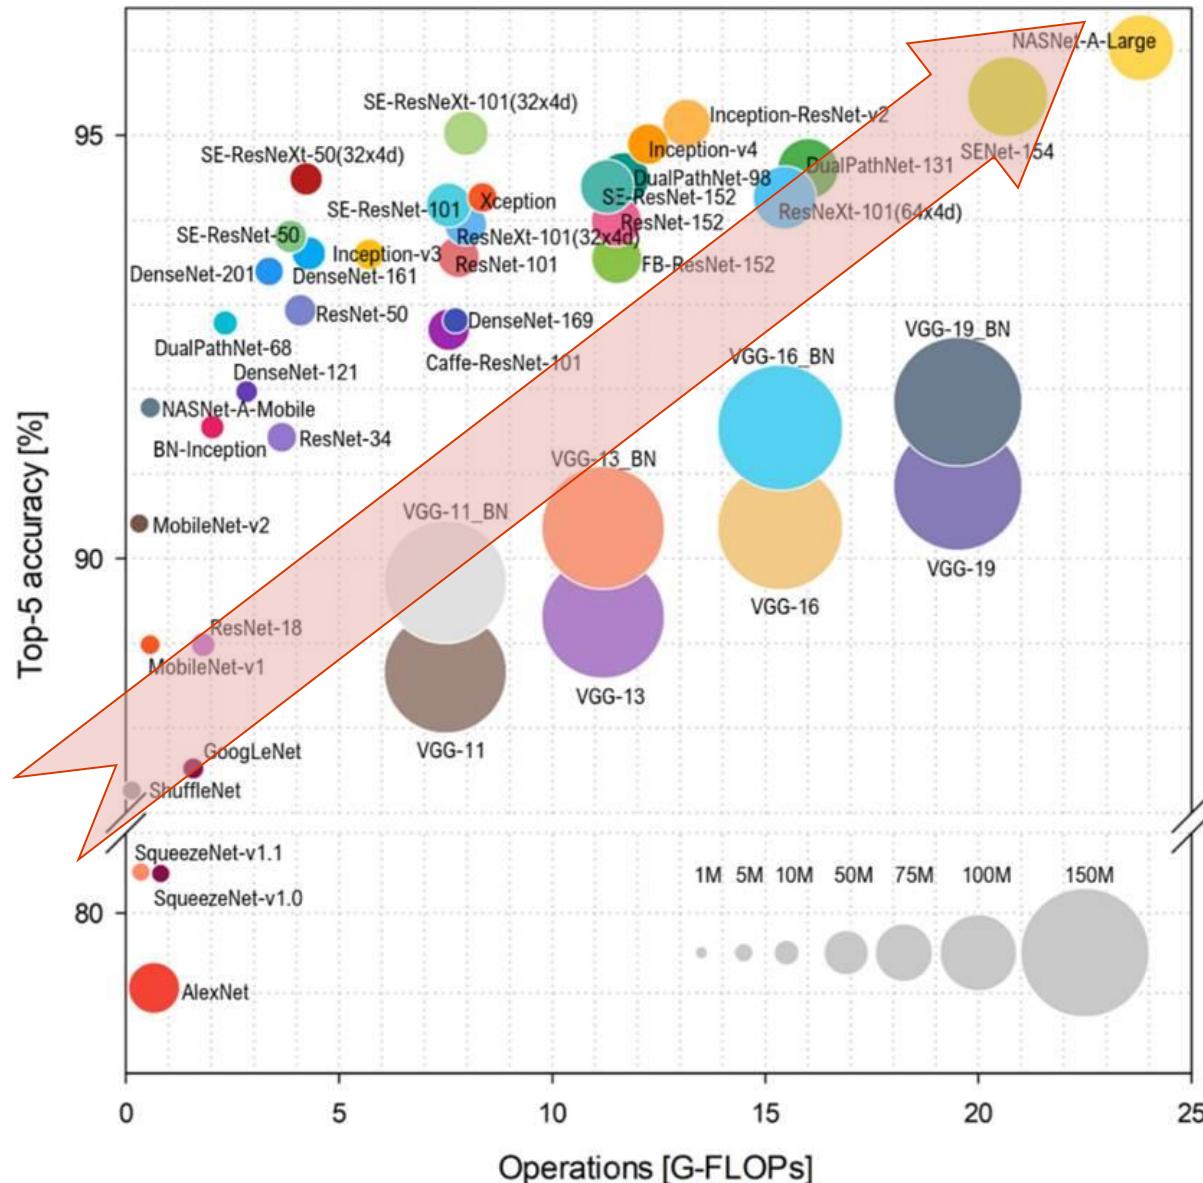
# 深度学习的计算复杂度

深度学习训练的趋势

更优的模型 -> 更大的计算复杂度

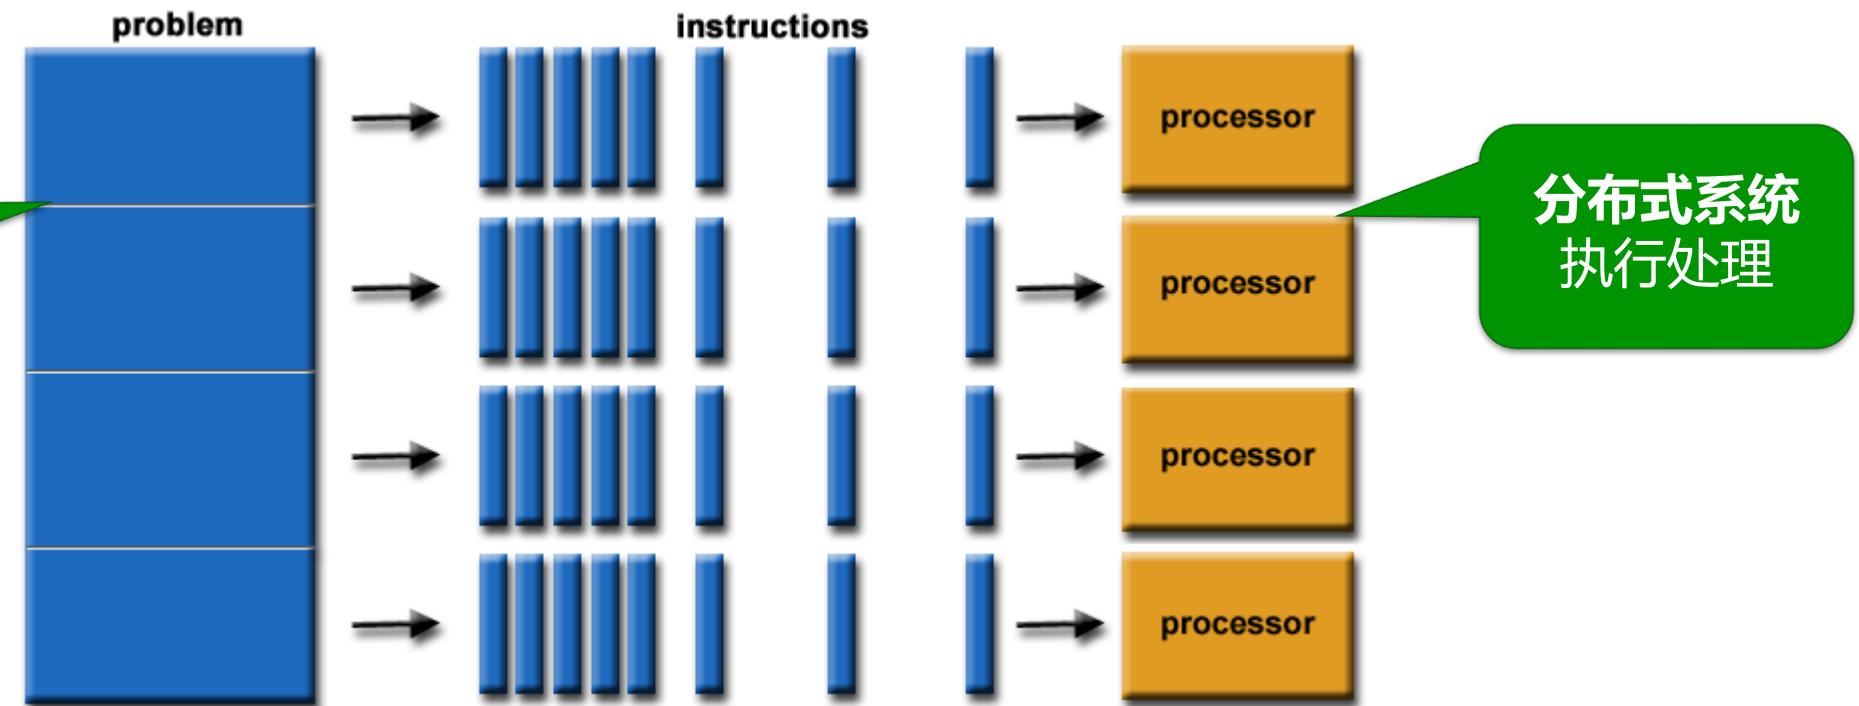
深度学习训练巨大的训练耗时

e.g. 语言模型 BERT(Large) 用 V100 GPU 训练需时 >1个月



# 从串行计算到并行计算

## 多处理器并行执行



# 分布式深度学习的意义

深度学习训练耗时：

$$\text{训练数据规模} \times \text{单步计算量} / \text{计算速率}$$

模型相关，相对固定

可变因素

计算速率：

$$\text{单设备计算速率} \times \text{设备数} \times \text{并行效率}$$

Moore定律，  
相对有限

可变因素

工作重点

# 分布式算法与系统

## 分布式算法

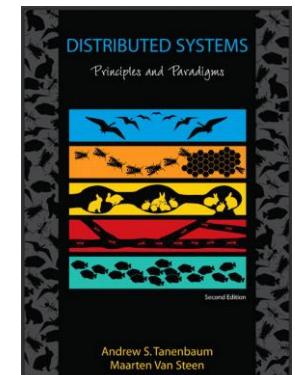
本章内容

*"Distributed algorithms are algorithms designed to run on multiple processors, without tight centralized control." -- 《MIT 6.852J/18.437J》*

## 分布式系统

下章内容

*"A distributed system is a collection of independent computers that appears to its users as a single coherent system." -- 《Distributed Systems: Principles and Paradigms》*



# 从串行训练 到并行训练



# 回顾：深度学习串行训练

## TensorFlow

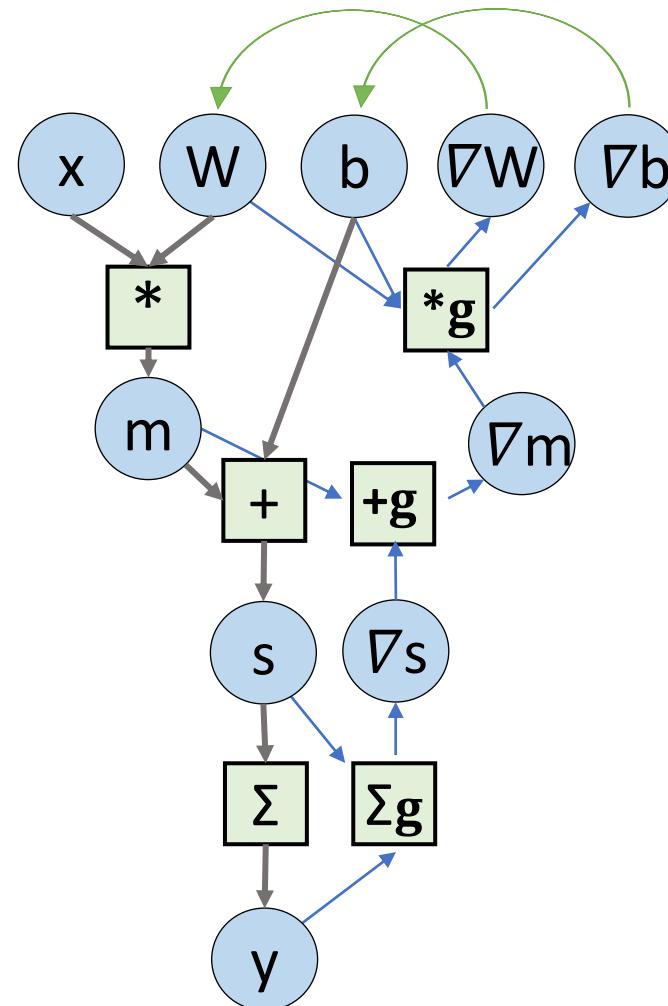
```
x = tf.placeholder(tf.float32)
W = tf.Variable(tf.float32)
b = tf.Variable(tf.float32)

m = W * x
s = m + b
y = tf.reduce_sum(s)

grad_W, grad_b = tf.gradients(y, [W, b])

update = optimizer.apply_gradients({[W, grad_W],
                                    [b, grad_b]})
```

## Data-Flow Graph (DFG)



# 回顾：深度学习训练可并行潜力

## TensorFlow

```
x = tf.placeholder(tf.float32)
W = tf.Variable(tf.float32)
b = tf.Variable(tf.float32)
```

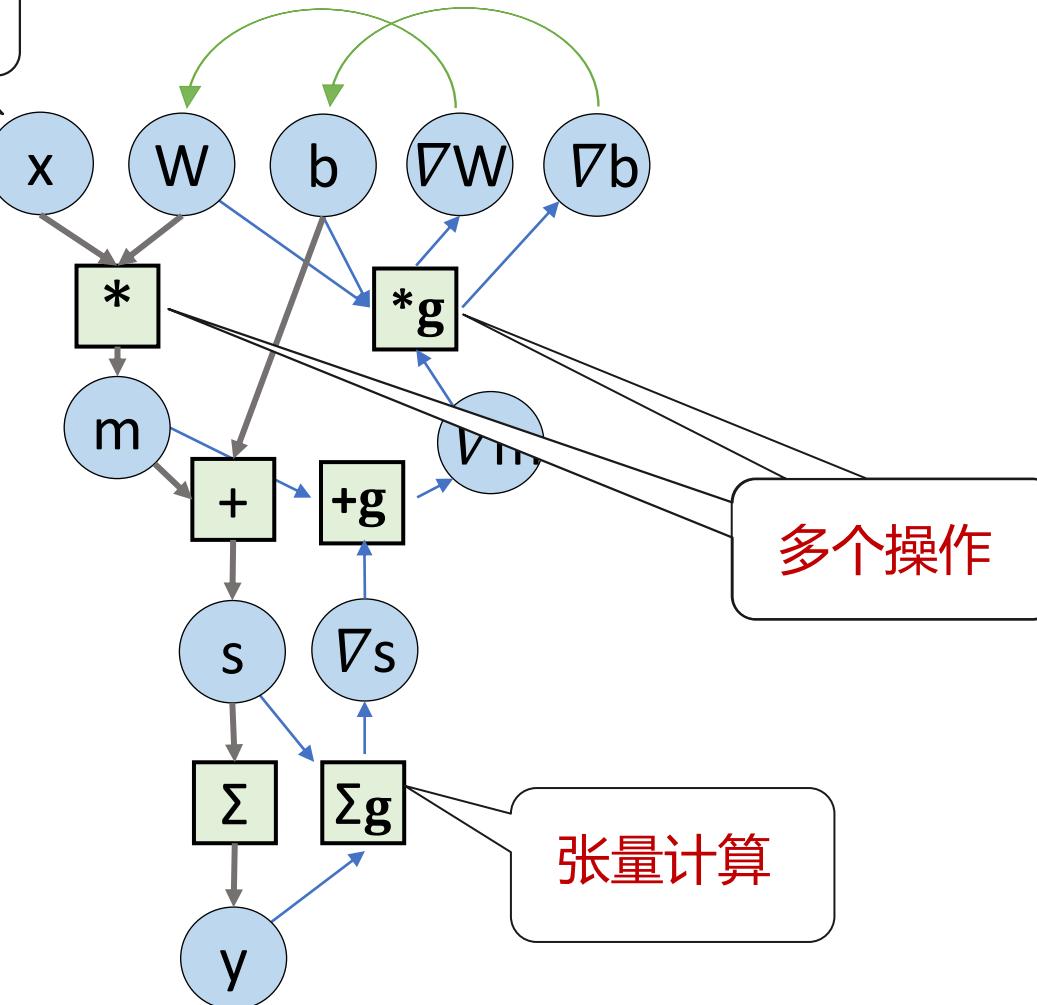
```
m = W * x
s = m + b
y = tf.reduce_sum(s)
```

```
grad_W, grad_b = tf.gradients(y, [W, b])

update = optimizer.apply_gradients({[W, grad_W],
                                    [b, grad_b]})
```

多个样本

## Data-Flow Graph (DFG)



# 并行化的基本方案

## 算子内并行

算子并行：并行单个张量计算子内的计算（GPU多处理单元并行）

## 算子间并行

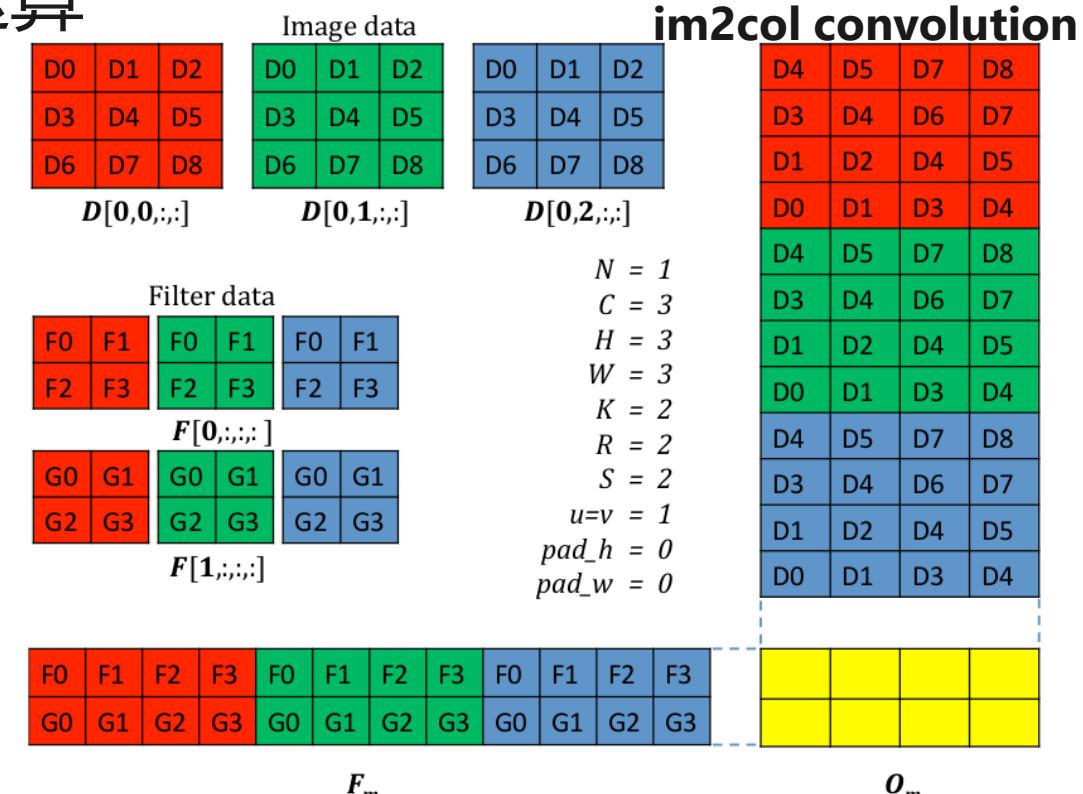
数据并行：多个样本并行执行

模型并行：多个算子并行执行

组合并行：多种并行方案组合叠加

# 运算子内并行

- 利用线性计算和卷积等操作内部的并行性
- 多个并行维度
  - Batch, 空间维度, 时间维度, ...
- 利用SIMD架构等多执行单元, 同时运算



# 并行化的基本方案

## 算子内并行

算子并行：并行单个张量计算子内的计算（GPU多处理单元并行）

## 算子间并行

数据并行：多个样本并行执行

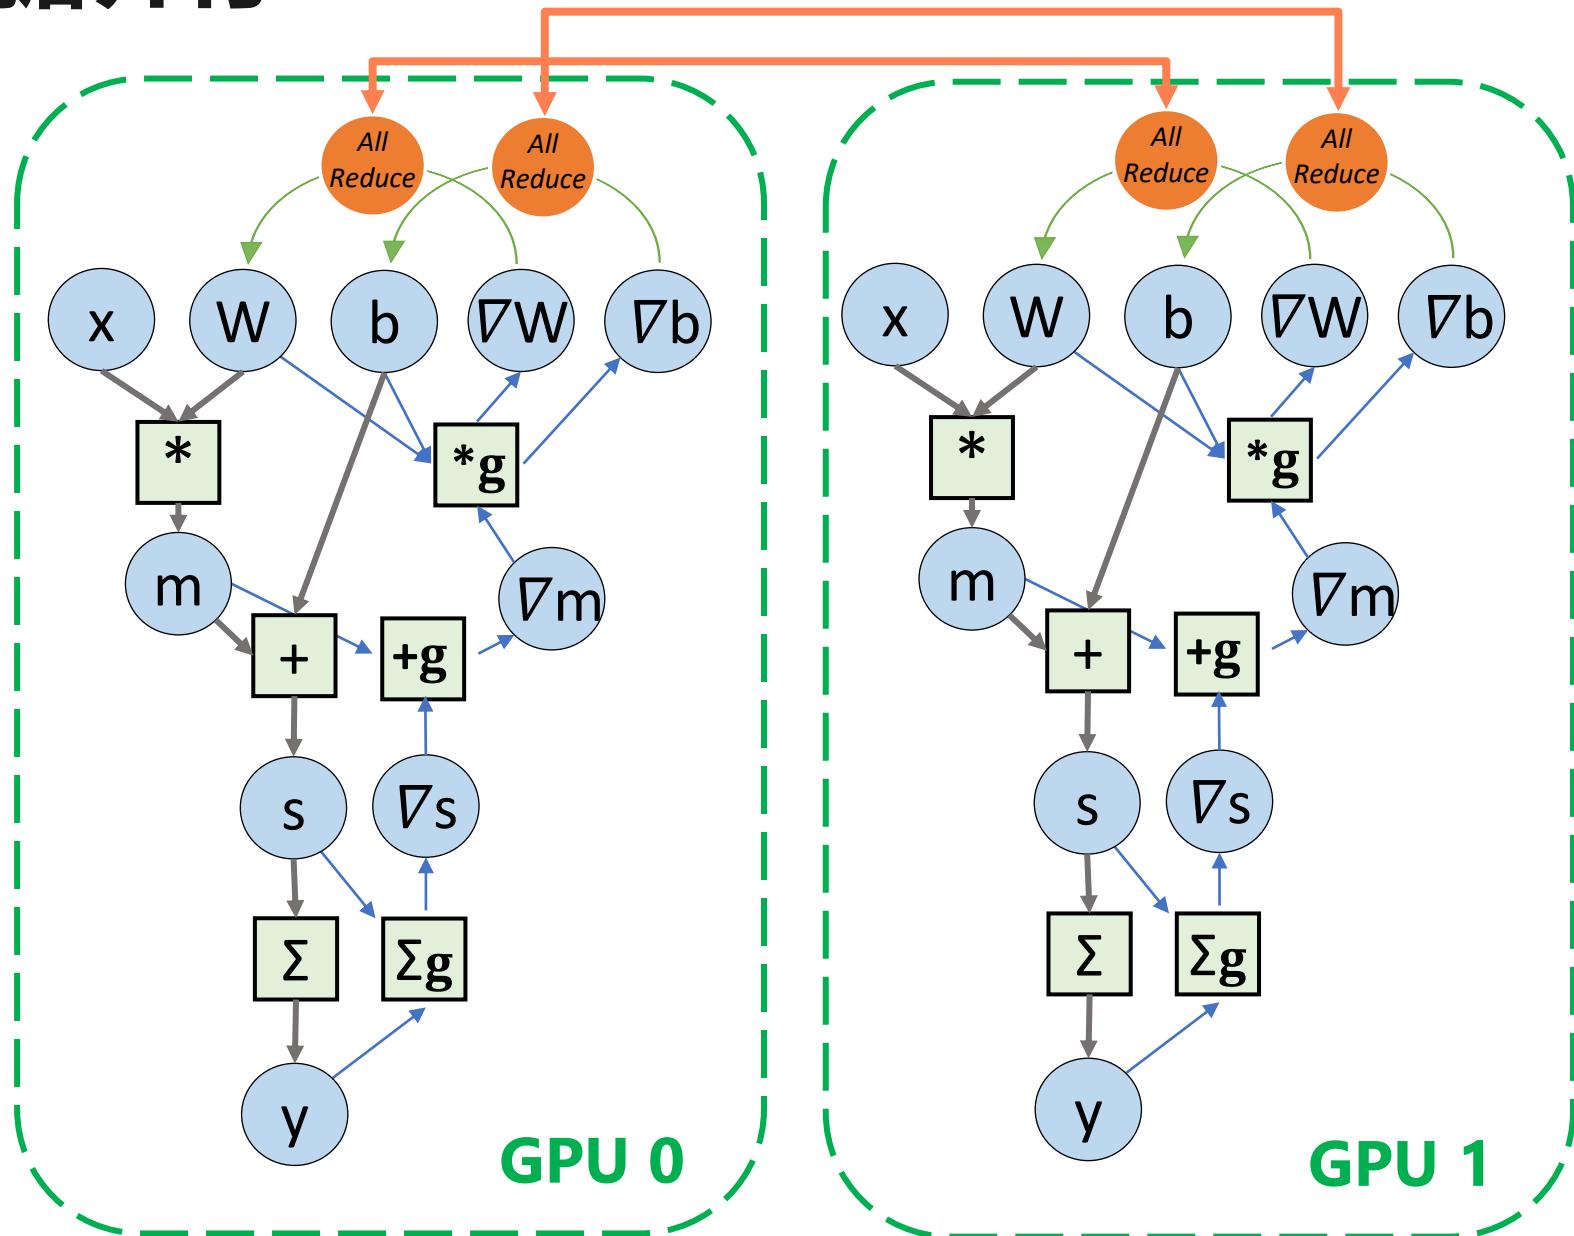
模型并行：多个算子并行执行

组合并行：多种并行方案组合叠加

# 并行化方案——数据并行

## 步骤

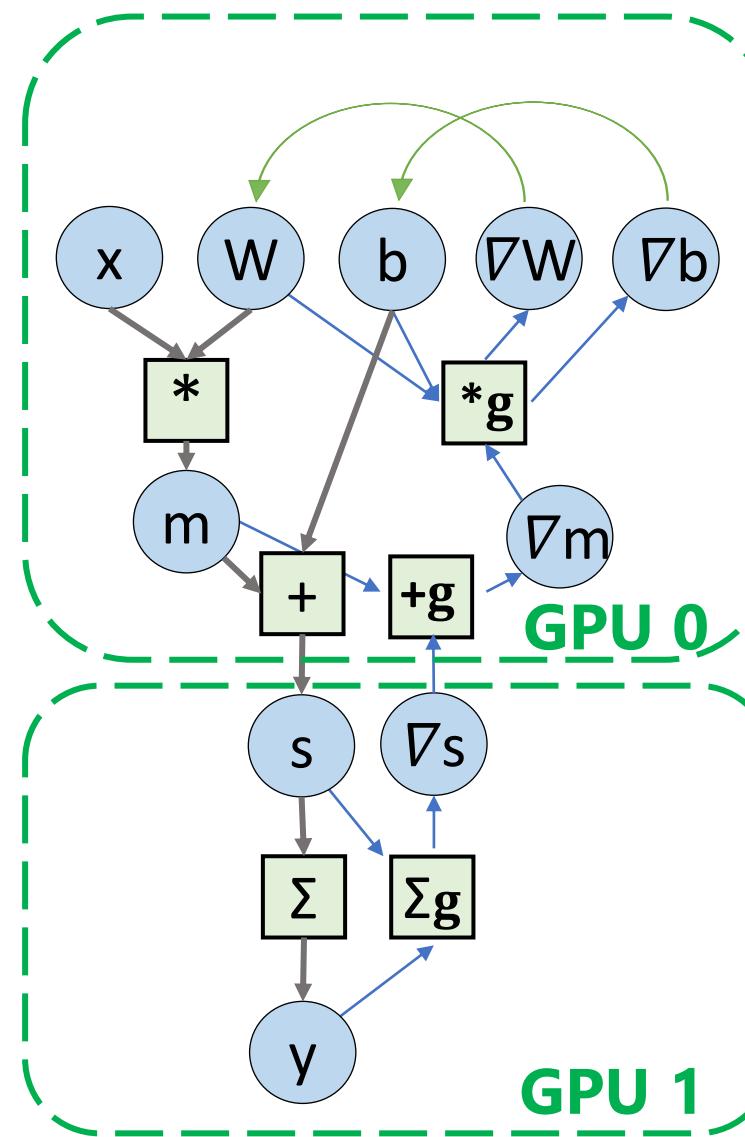
- 不同设备上执行相同计算图
- 跨设备聚合梯度
- 利用聚合后梯度更新模型



# 并行化方案——模型并行

## 步骤

- 计算图划分至不同设备上执行
- 跨设备传递激活
- 设备分别利用梯度更新模型的本地部分



# 数据/模型并行对比

	非并行	数据并行	模型并行
样本数据量	1	$1/N$	1
传输数据量	0	模型大小	激活大小
存储占用	1	N	1
负载平衡度	-	强	弱
并行限制	-	单步样本量	算子数量

设备数量：N

# 深度学习的分布式 训练算法分类



# 并行化算法通信类别

## 同步并行

采用**具有同步障**的通信协调并行

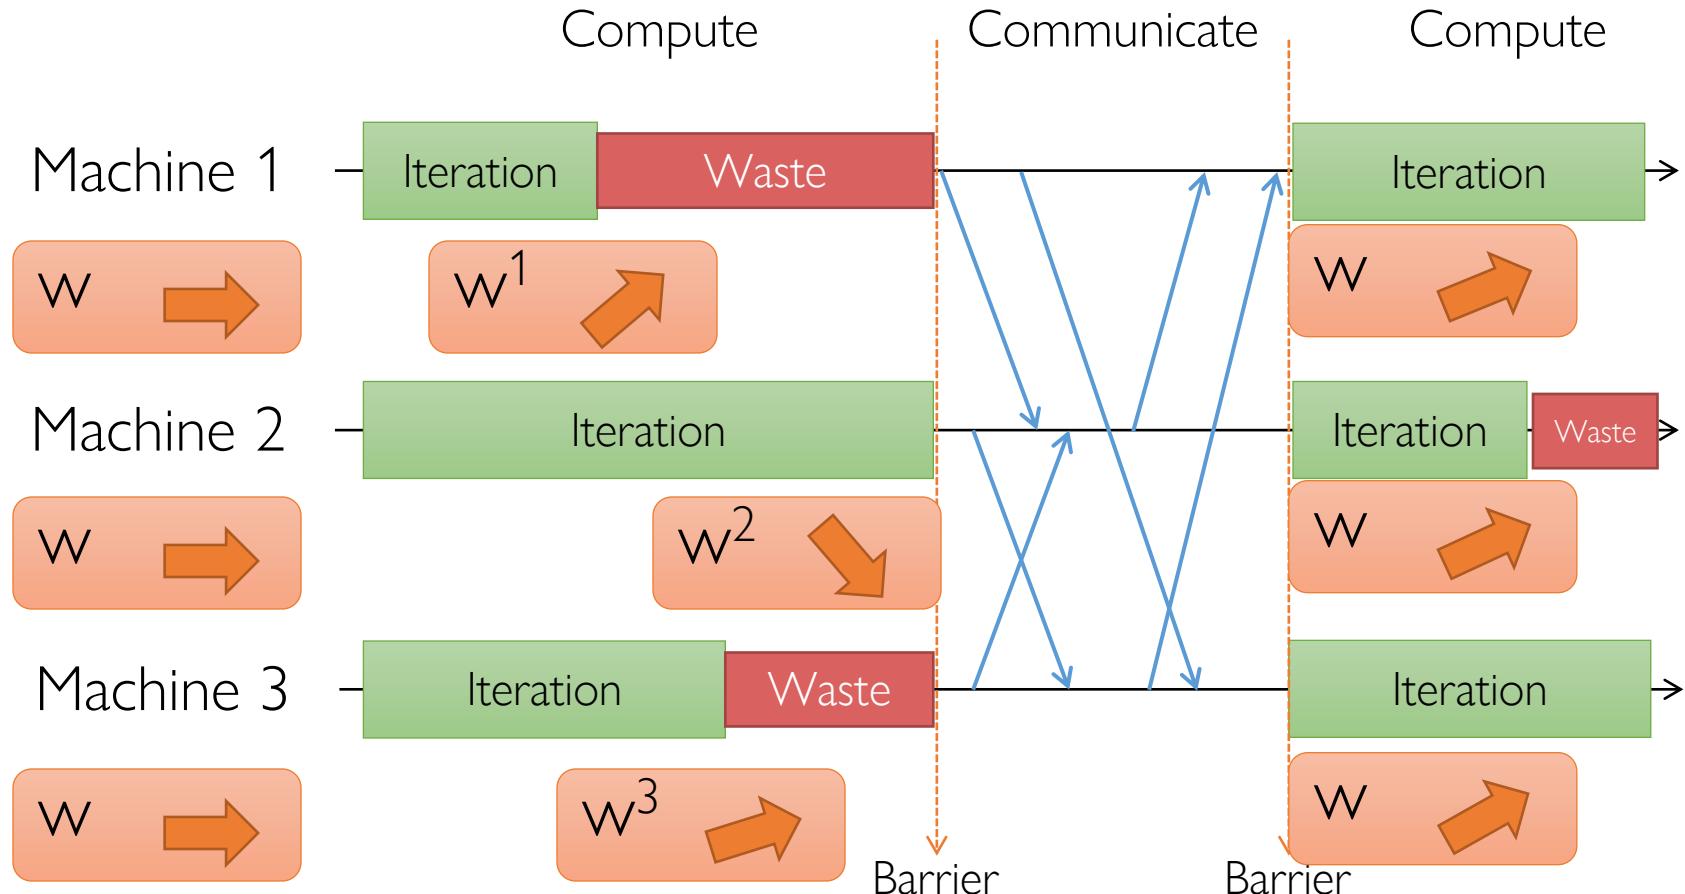
## 异步并行

采用**不合同步障**的通信协调并行

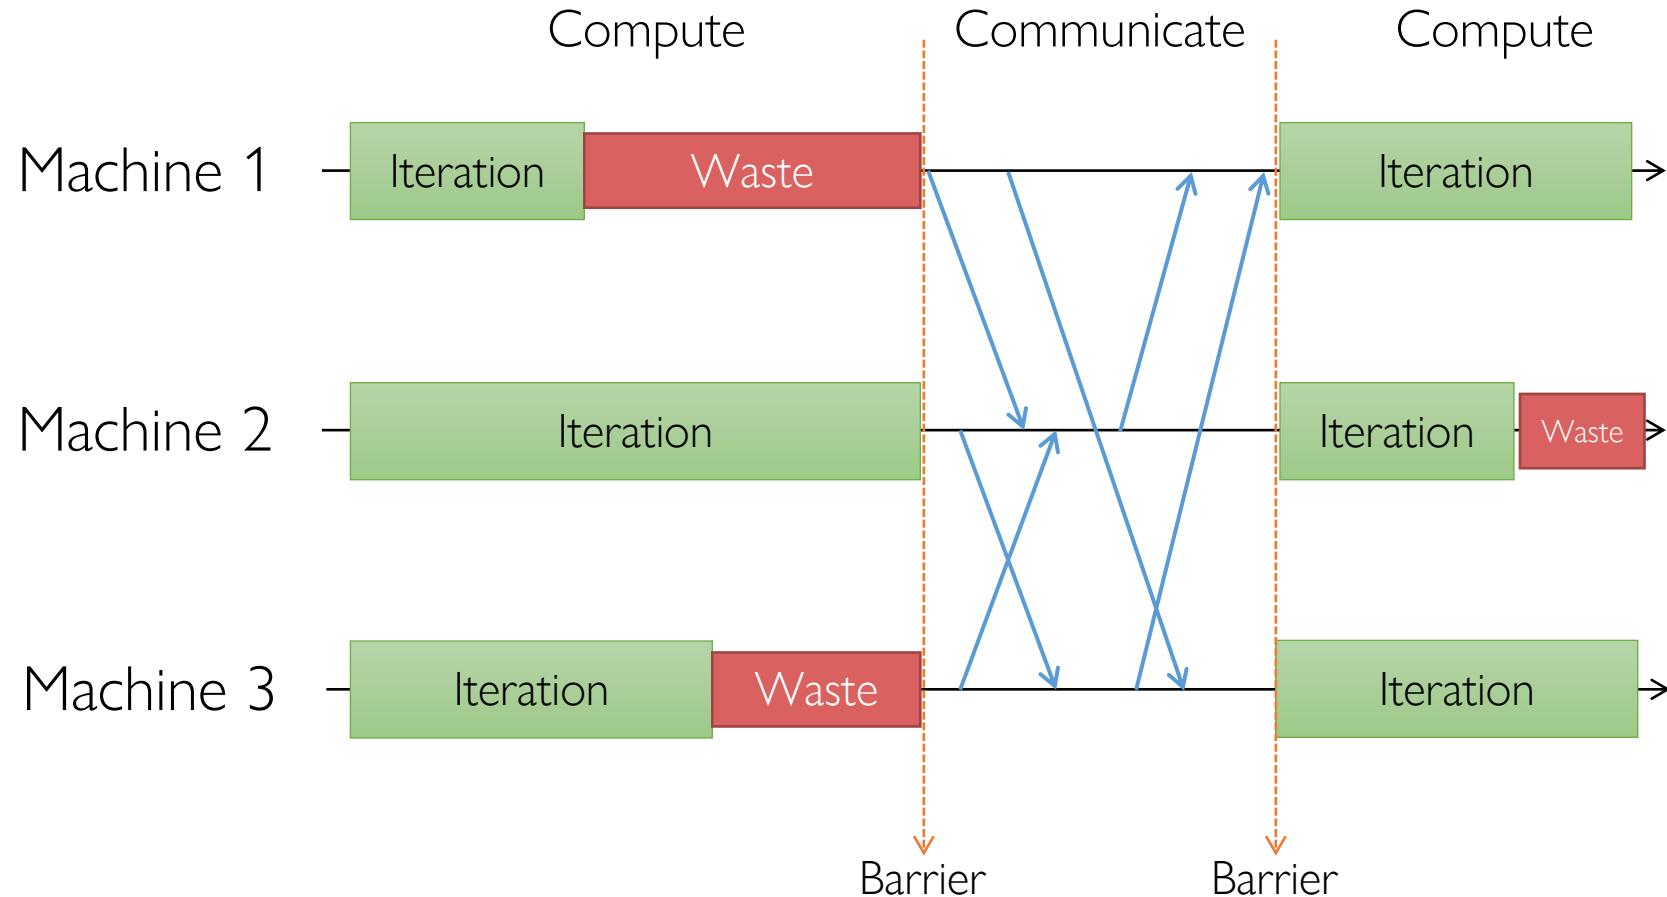
## 半同步并行

采用**具有有限定的宽松同步障**的通信协调并行

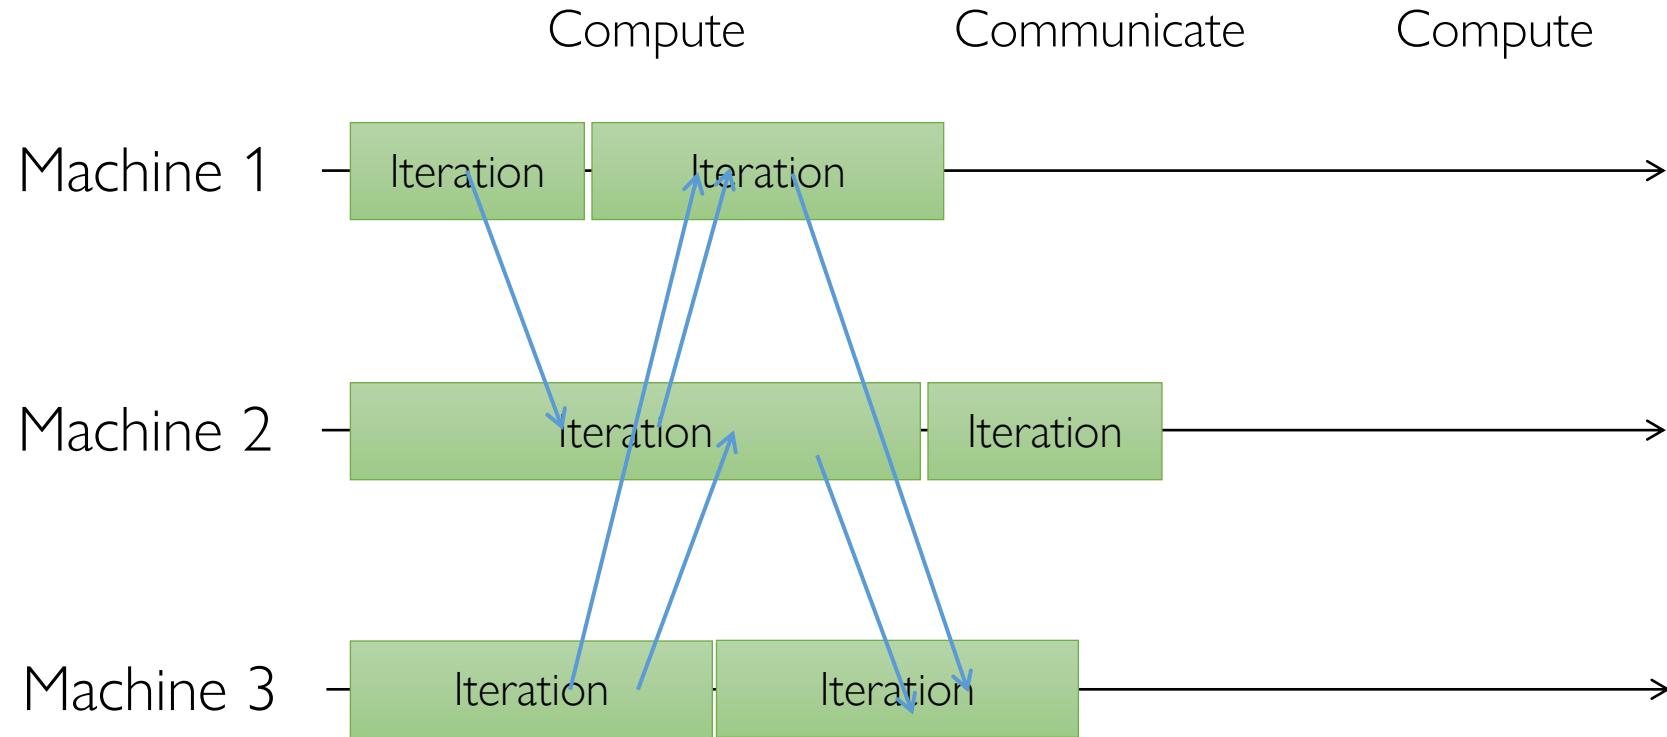
# 同步算法



# 异步算法



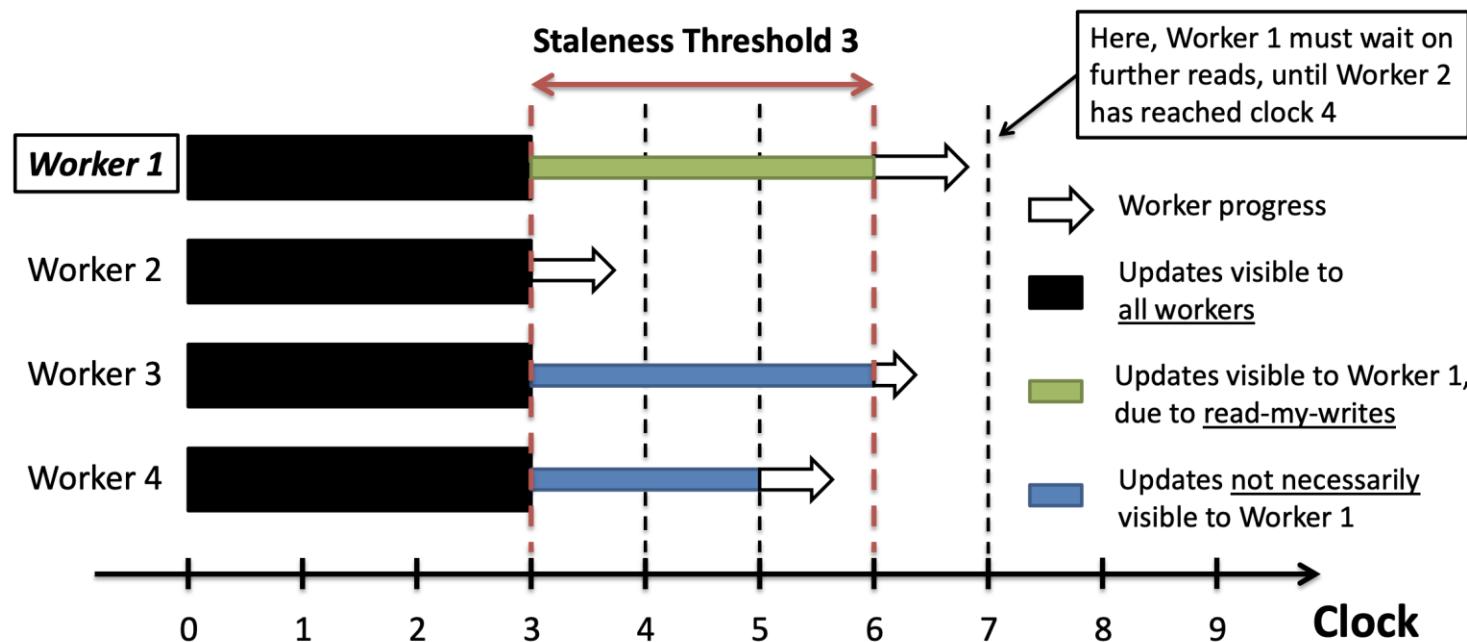
# 异步算法



# 半同步算法

e.g., Stale Synchronous Parallel (SSP)

## SSP: Bounded Staleness and Clocks



# 并行化算法通信类别

## 同步并行

采用**具有同步障**的通信协调并行

收敛性**AAA**

## 异步并行

采用**不含有同步障**的通信协调并行

收敛性**A**

## 半同步并行

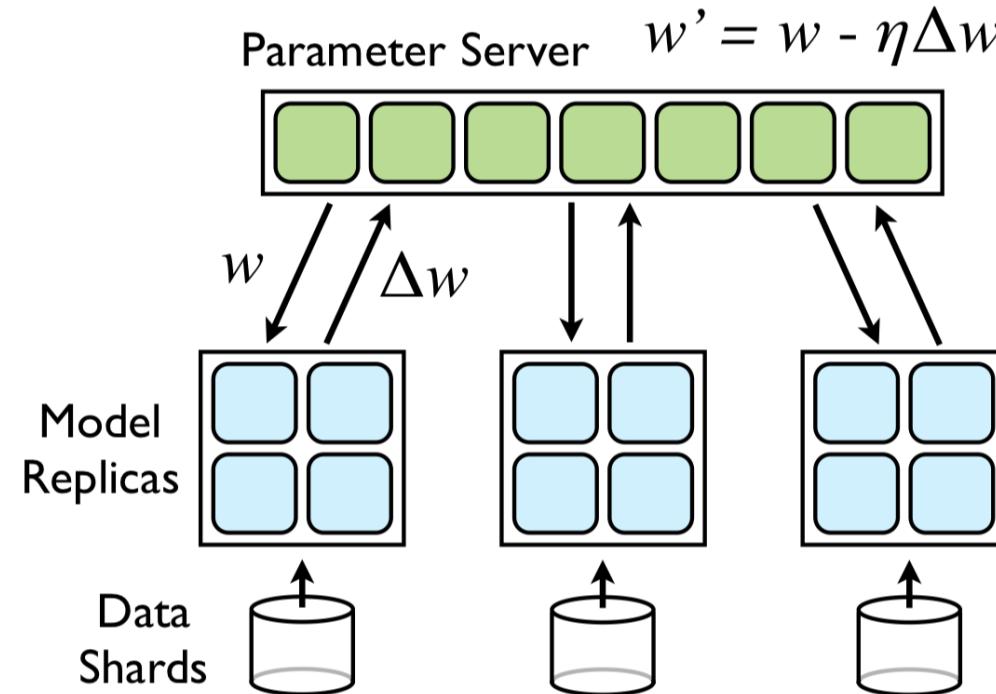
采用**具有有限定的宽松同步障**的通信协调并行

收敛性**AA**

# 深度学习并行训练 实例

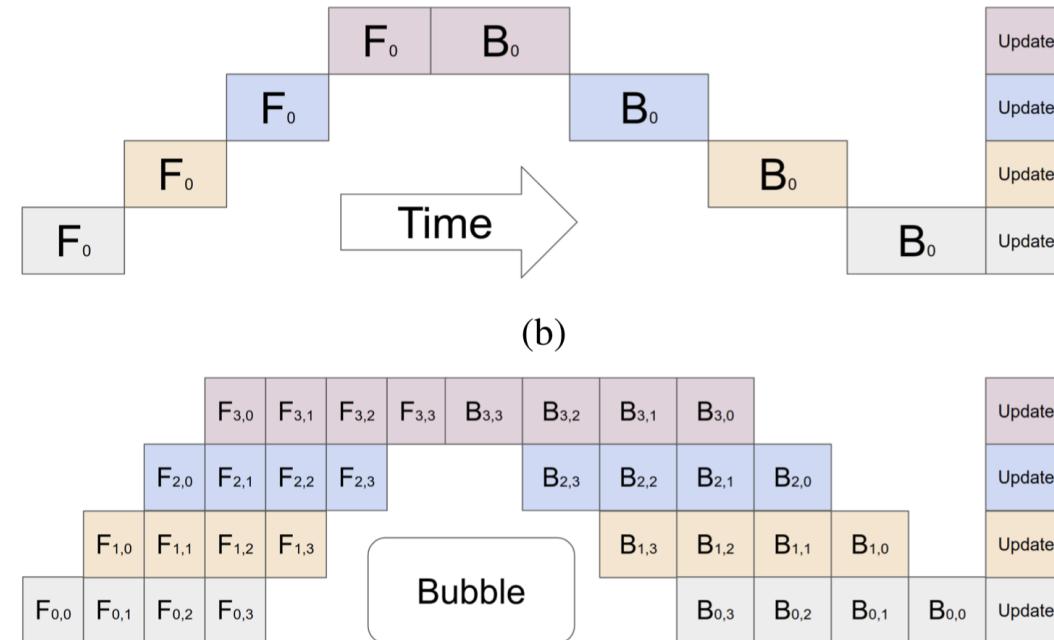
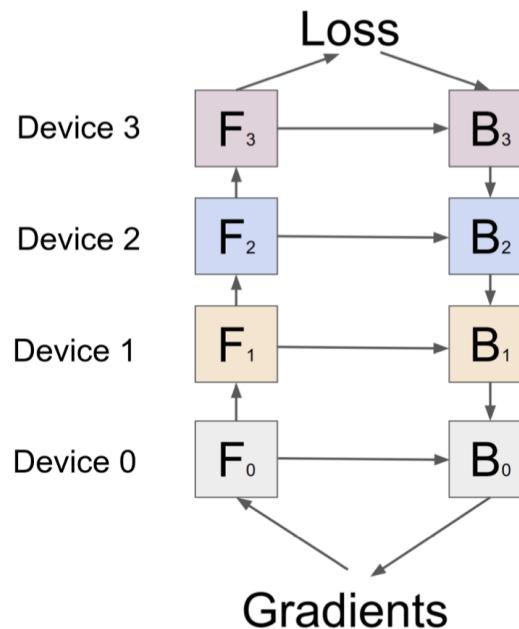


# Downpour SGD



# GPipe

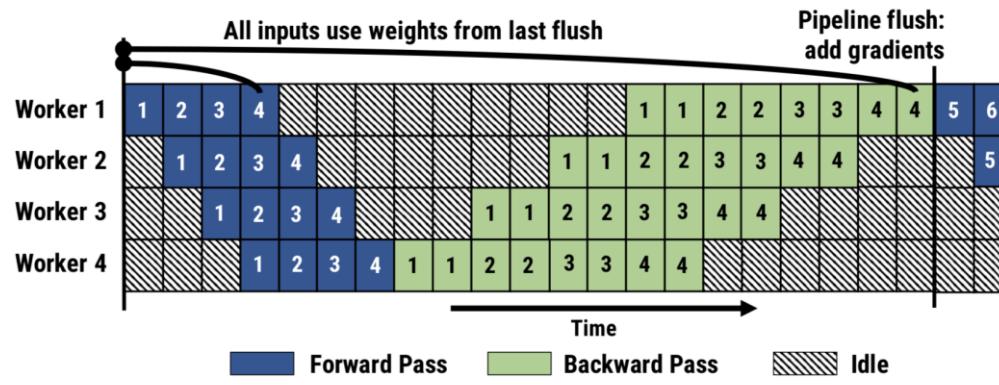
通过对minibatch进行拆分，减少设备空闲(Bubble)，从而更好地利用多设备进行流水化并行



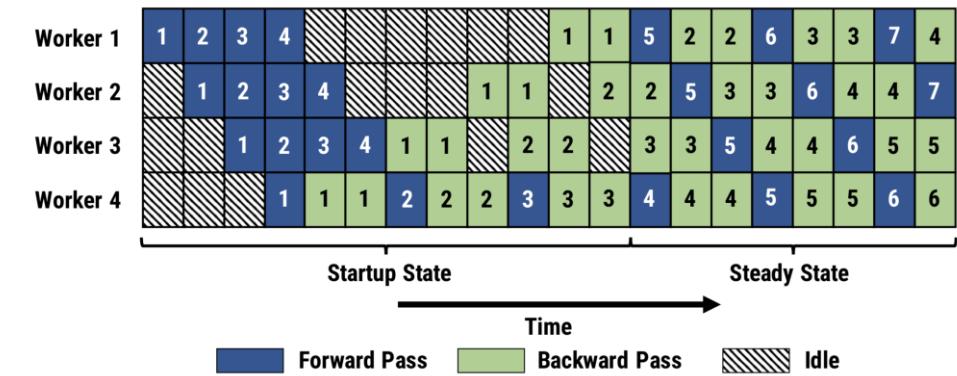
# PipeDream

采用非同步机制，在Gpipe基础上进一步减少设备空闲

GPipe



PipeDream



# 本章小节

分布式是解决大计算量深度学习训练的有效方法

分布式深度学习算法按照并行维度可分为：

运算子/数据/模型/混合并行

分布式深度学习算法按照通讯协调方式包括：

同步并行/异步并行/半同步并行

# 阅读列表

- [Scaling Distributed Machine Learning with the Parameter Server](#) (OSDI'14)
  - Paper describing the parameter server system
- [PipeDream: Generalized Pipeline Parallelism for DNN Training](#) (SOSP'19)
  - Latest paper exploring pipeline parallel training
- [Adaptive Communication Strategies to Achieve the Best Error-Runtime Trade-off in Local-Update SGD](#) (SysML'19)
  - Dynamic averaging approach to distributed training

# 参考文献