中山大學 软件工程学院

SUN YAT-SEN UNIVERSITY SCHOOL OF SOFTWARE ENGINEERING

Lecture 03：云分布式计算

SSE316：云计算技术
Cloud Computing Technologies

陈壮彬

软件工程学院

chenzhb36@mail.sysu.edu.cn

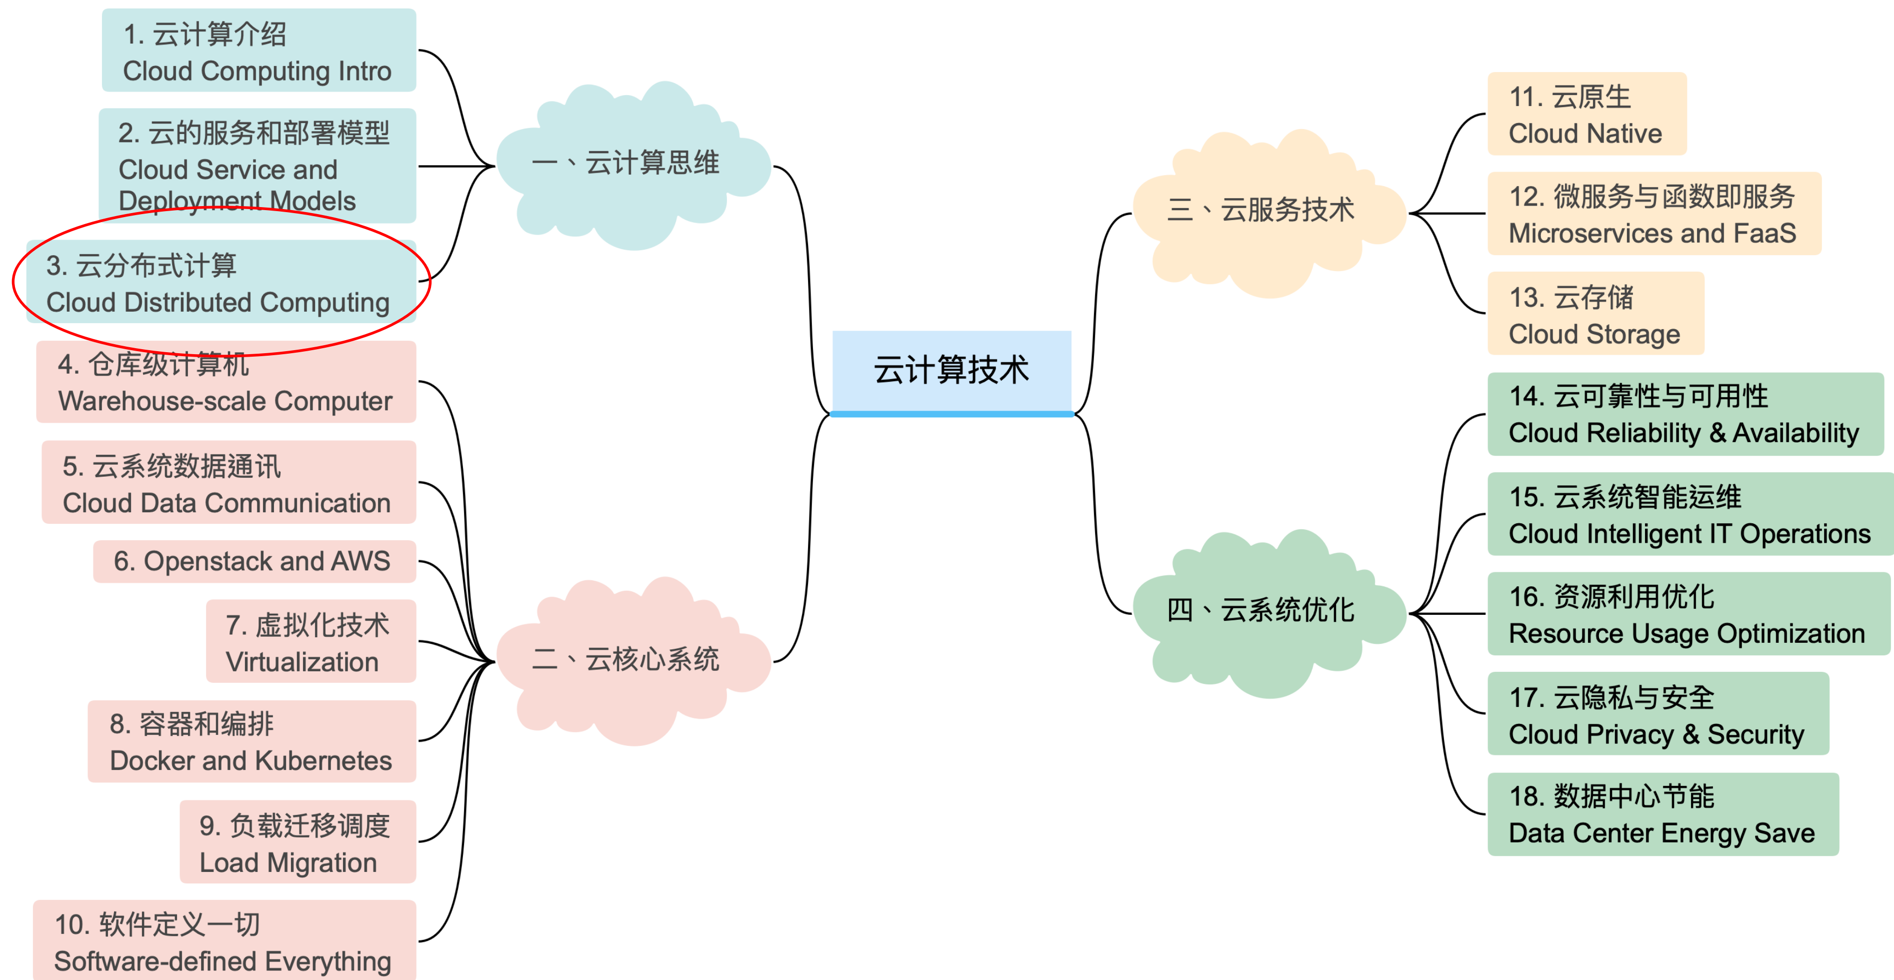
云计算技术
一、云计算思维
1. 云计算介绍
Cloud Computing Intro
2. 云的服务和部署模型
Cloud Service and
Deployment Models
3. 云分布式计算
Cloud Distributed Computing
二、云核心系统
4. 仓库级计算机
Warehouse-scale Computer
5. 云系统数据通讯
Cloud Data Communication
6. Openstack and AWS
7. 虚拟化技术
Virtualization
8. 容器和编排
Docker and Kubernetes
9. 负载迁移调度
Load Migration
10. 软件定义一切
Software-defined Everything
三、云服务技术
11. 云原生
Cloud Native
12. 微服务与函数即服务
Microservices and FaaS
13. 云存储
Cloud Storage
四、云系统优化
14. 云可靠性与可用性
Cloud Reliability & Availability
15. 云系统智能运维
Cloud Intelligent IT Operations
16. 资源利用优化
Resource Usage Optimization
17. 云隐私与安全
Cloud Privacy & Security
18. 数据中心节能
Data Center Energy Save

Today’s topics

- 分布式计算概要
- MapReduce
- MapReduce 深度优化
  - 任务延迟问题
  - 长尾问题

Google Books Ngram Viewer

Graph these comma-separated phrases: Albert Einstein,Harry Potter,Bill Gates ☐ case-insensitive

between 1800 and 2008 from the corpus English with smoothing of 1 . Search lots of books

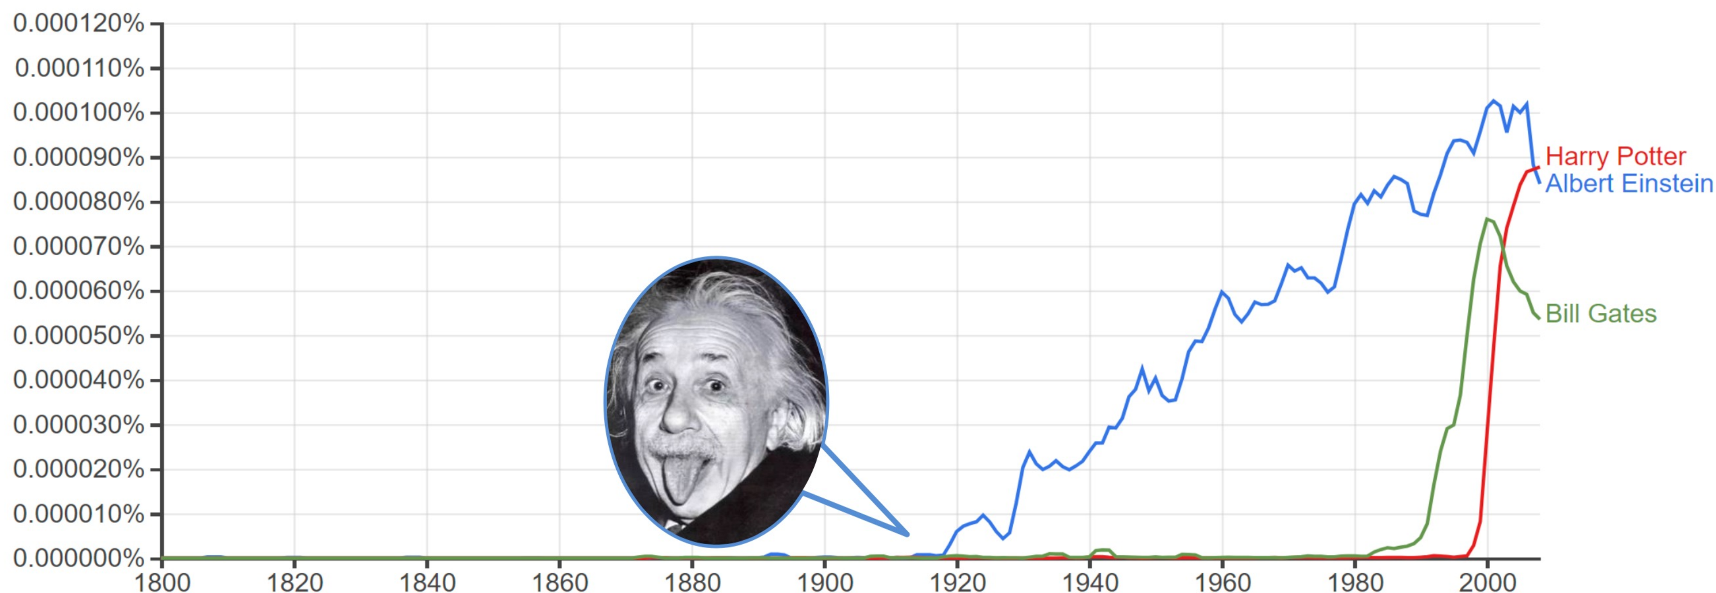

1800年 -- 2000年	超过 5 亿个词汇
约全世界 4% 图书	中英等多国语言

Google Books Ngram Viewer

Graph these comma-separated phrases: 金庸,琼瑶 case-insensitive

between 1980 and 2008 from the corpus Chinese (simplified) with smoothing of 1. Search lots of books

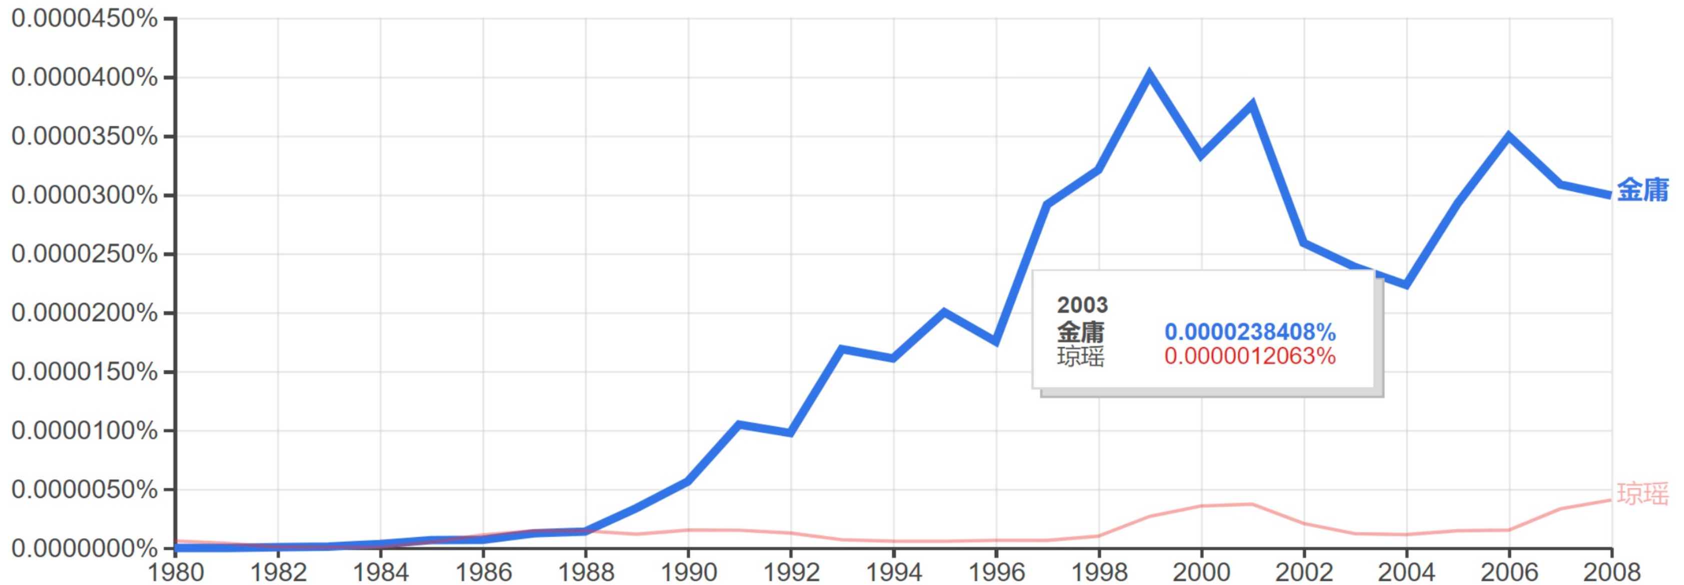

1800年 -- 2000年	超过 5 亿个词汇
约全世界 4% 图书	中英等多国语言

怎么统计文献中单词出现的次数?

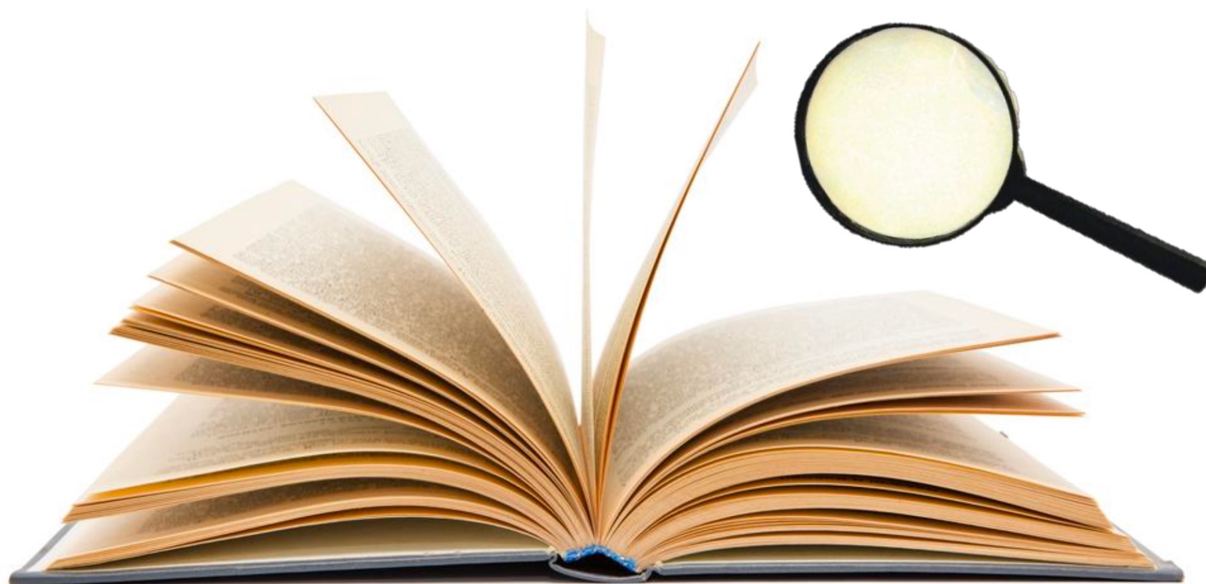

计数问题

Hello World Bye World
Hello SYSU Bye SYSU
Bye SYSU Hello SYSU

挨个计数

Hello (1) Hello (1) Hello (1)
World (1) World (1)
Bye (1) Bye (1) Bye (1)
SYSU (1) SYSU (1) SYSU (1) SYSU (1)

计数问题

Hello (1) Hello (1) Hello (1)
World (1) World (1)
Bye (1) Bye (1) Bye (1)
SYSU (1) SYSU (1) SYSU (1) SYSU (1)

求和输出

Hello： (1+1+1=3)
World： (1+1=2)
Bye： (1+1+1=3)
SYSU： (1+1+1+1=4)

如何提高计数的效率?

并行计算!
Parallel Computing!

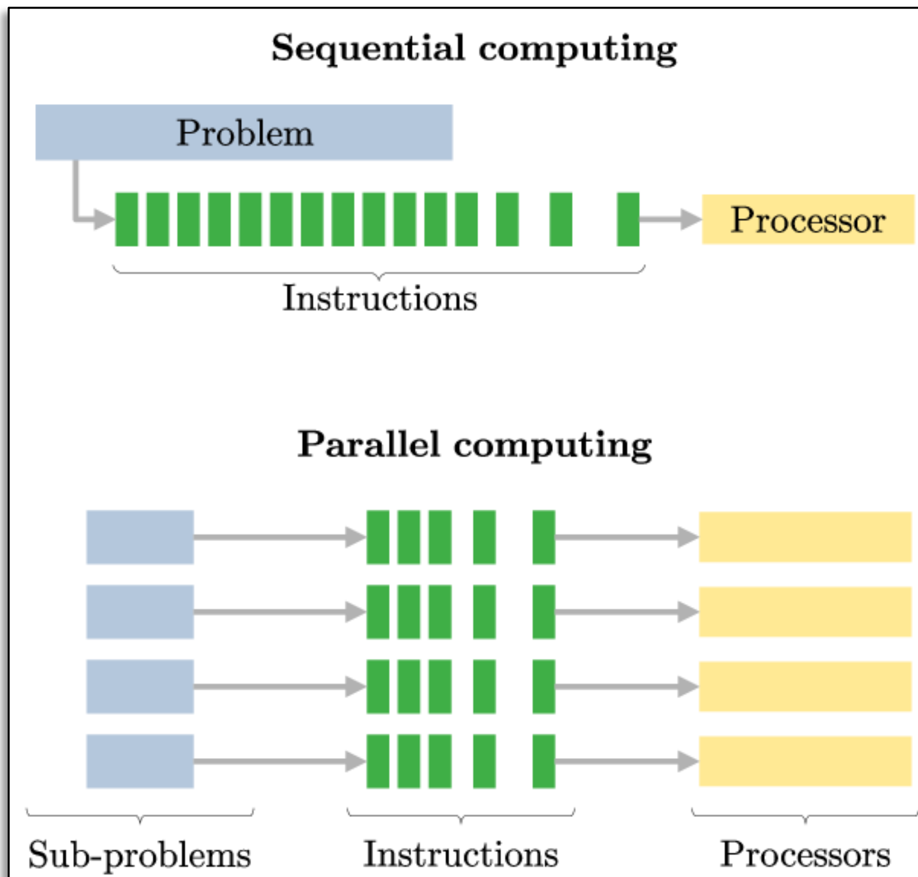

并行计算是一种**计算模型**，指**同时使用多种计算资源解决计算问题**，以提高计算速度和效率

计数问题

Hello World Bye World
Hello SYSU Bye SYSU
Bye SYSU Hello SYSU

多个人一起数

Hello (1)
World (1)
Bye (1)
World (1)

Hello (1)
SYSU (1)
Bye (1)
SYSU (1)

Bye (1)
SYSU (1)
Hello (1)
SYSU (1)

阿姆达尔定律 Amdahl’s Law

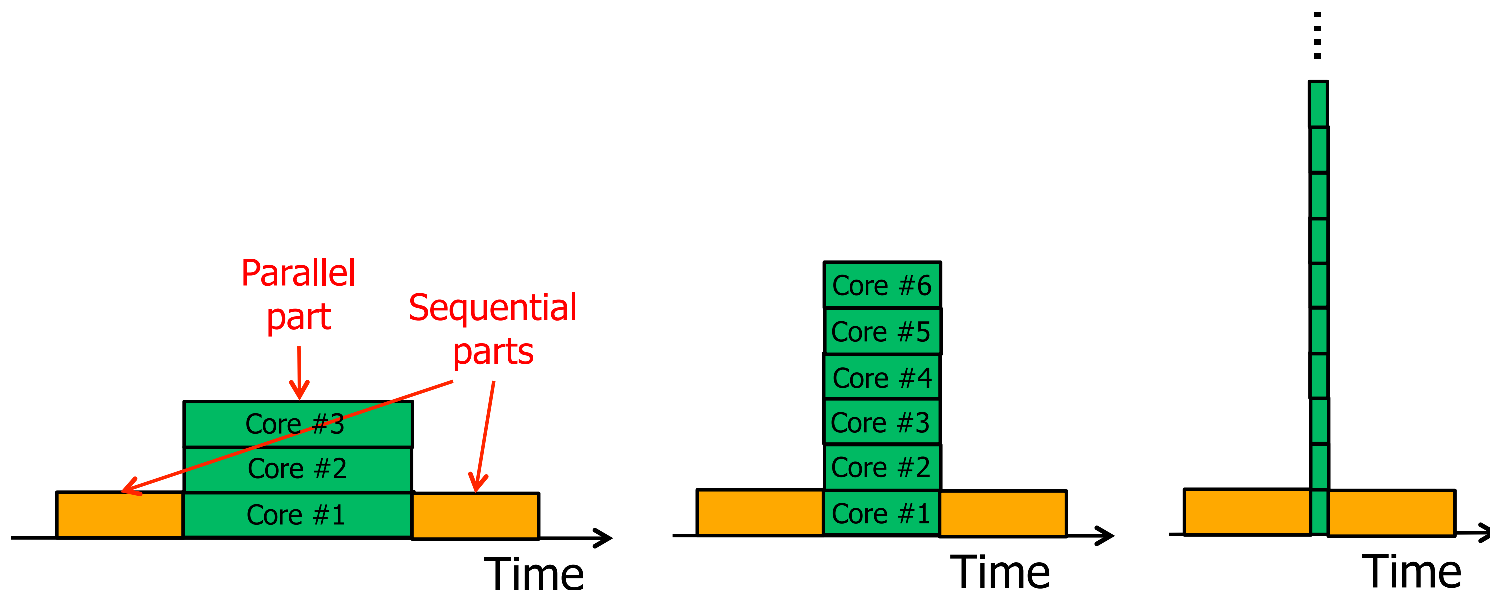

- 通常，一个程序并不是所有部分都可以并行化处理
- 假设某程序可并行处理的部分占比为 f，并行处理的节点个数为 p，则并行的加速比 S 为：

$$S_{overall} = \frac{1}{(1-f) + \frac{f}{S_{part}}}$$

$$S = \frac{1}{(1-f) + \frac{f}{p}}$$

计数问题哪些部分可以并行?

Hello World Bye World
Hello SYSU Bye SYSU
Bye SYSU Hello SYSU

Hello (1)
World (1)
Bye (1)
World (1)

Hello (1)
SYSU (1)
Bye (1)
SYSU (1)

Bye (1)
SYSU (1)
Hello (1)
SYSU (1)

阿姆达尔定律

- 理想与真实的情况
  - 阿尔达姆定律太过简单了，无法被应用到实际中
  - 当我们运行一个并行程序时，一般来说，进程之间存在**通信开销**、**同步开销**和**负载不平衡**

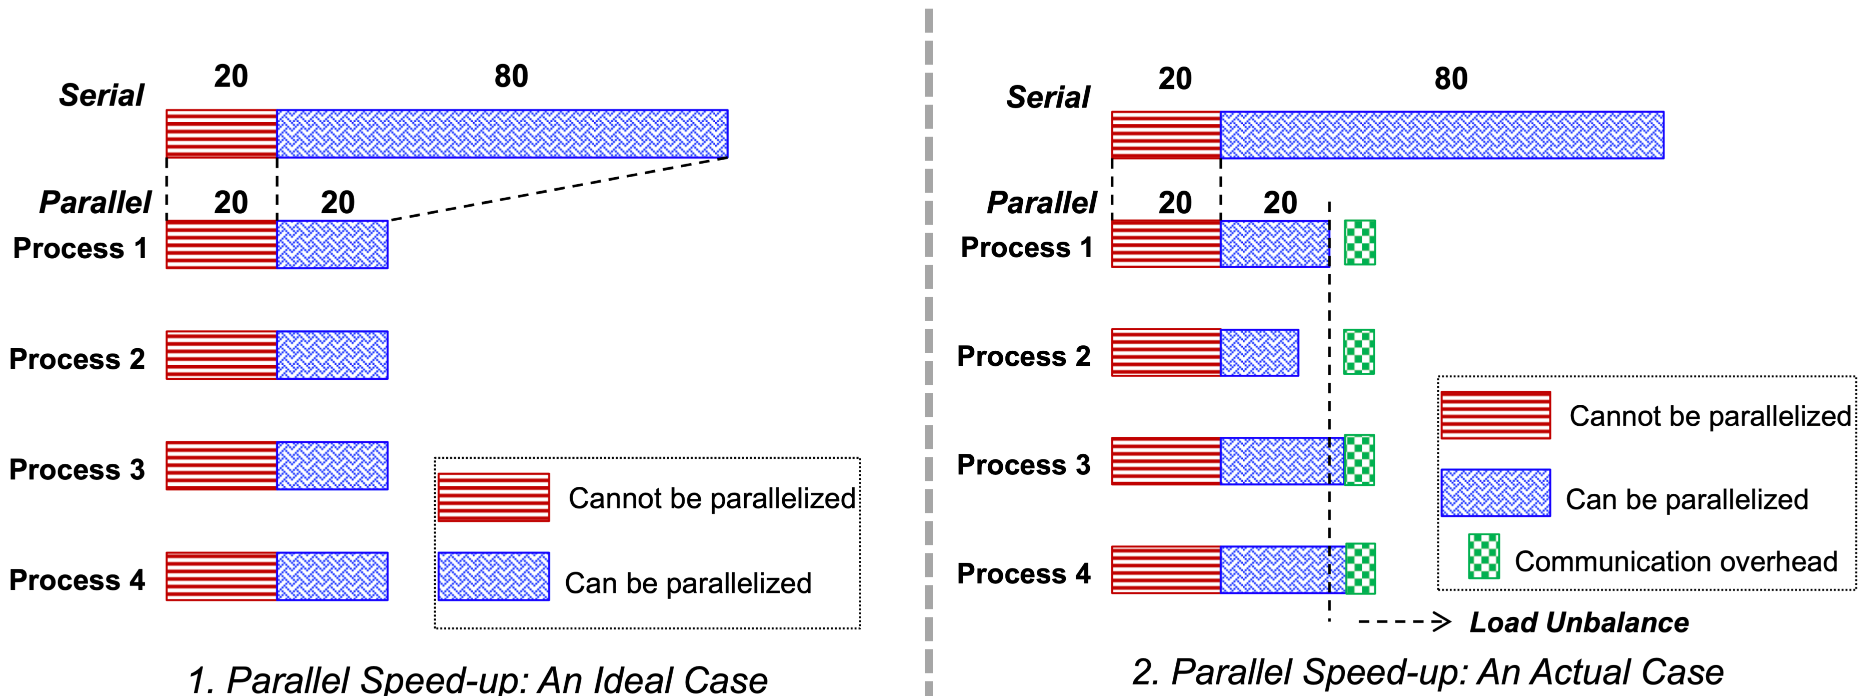

因此，当并行超过一定程度时，性能可能会下降！

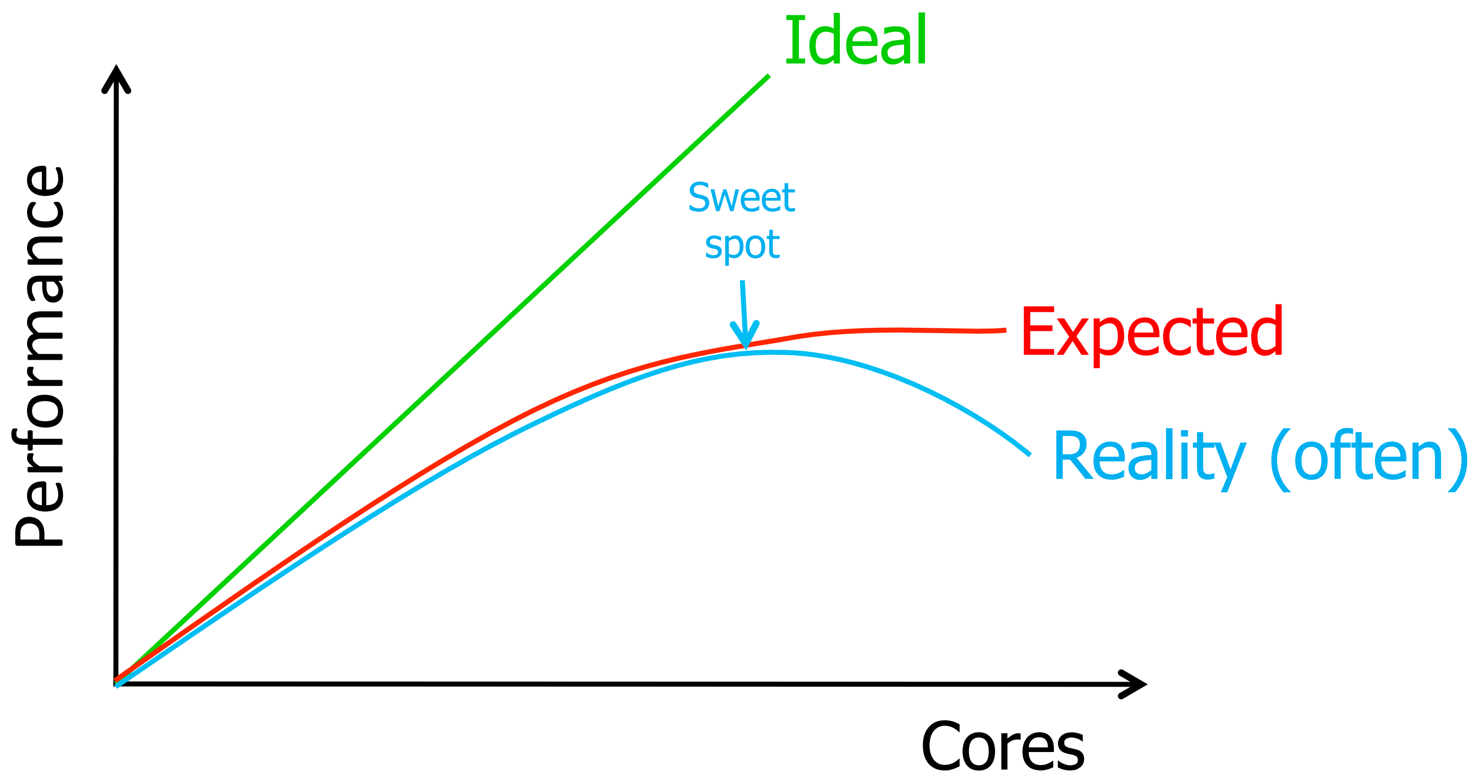

How do we scale-up for Web-Scale Information Analytics?

分治 Divide and Conquer

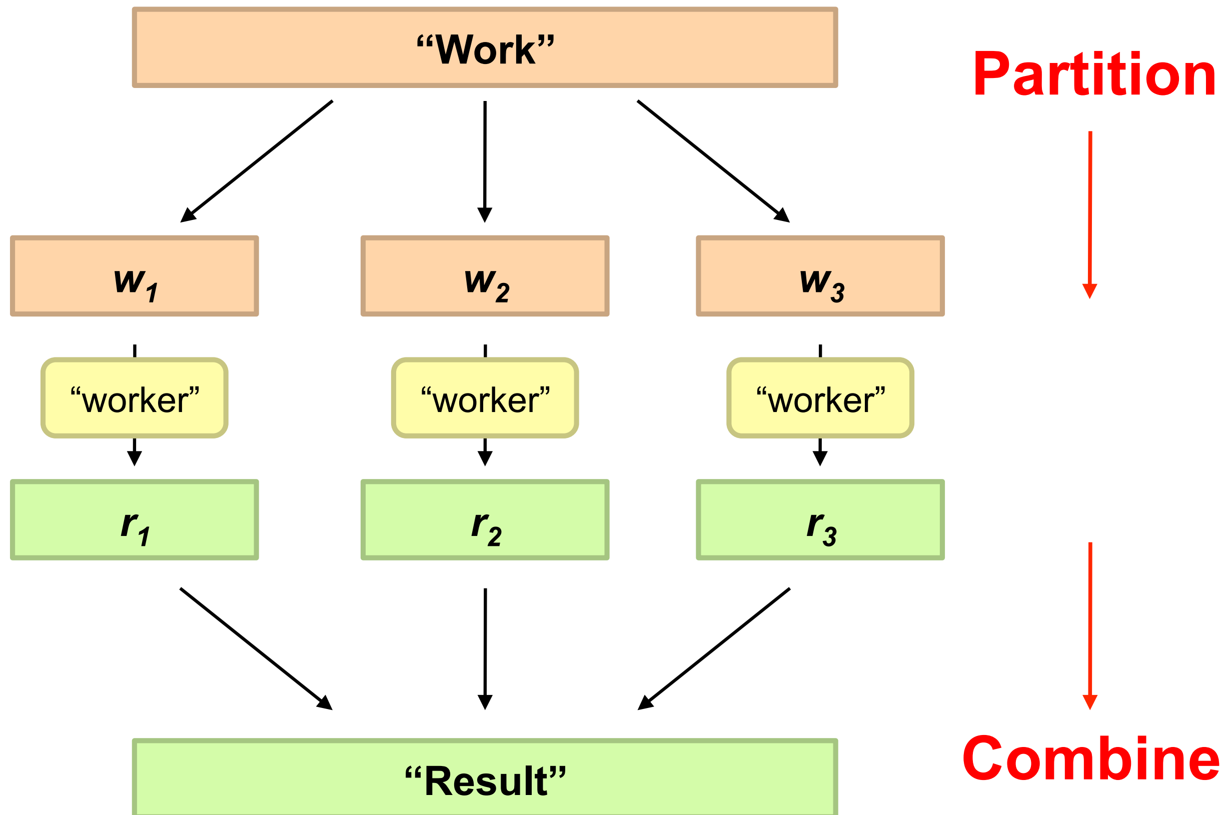

并行化的挑战

想象一下一个公司中多人协作

- 如何将 task 分配给 worker?
- 如果 task 比 worker 多怎么办?
- 如果 worker 需要共享部分结果怎么办?
- 如何汇总部分结果?
- 如何知道所有 worker 已经完成了工作?
- 如果 worker 故障怎么办?

What is the common theme of all of these problems?

并行化的挑战

Two common themes

1. **Communication between workers (e.g., to exchange state)**
2. **Access to shared resources (e.g., data)**

管理多个 worker

□很困难，因为我们

- 不知道 worker 运行的顺序
- 不知道 worker 什么时候会互相干扰
- 不知道 worker 访问共享数据的顺序

□因此，我们需要

- 信号量 Semaphores (锁定 lock、解锁 unlock)
- 条件变量 Conditional variables (等待 wait、通知 notify、广播 broadcast)
- 同步屏障 Barriers

□但还是有很多问题

- 死锁 Deadlock，活锁 Livelock，竞争条件 Race conditions
- Dining philosophers, sleeping barbers, cigarette smokers...

Where the rubber meets the road

养兵千日，用兵**一时**

- 并发性 (concurrency) 很难推理

- 以下场景使并发推理更困难
  - 数据中心规模（甚至跨数据中心）
  - 出现故障时
  - 多个服务交互

- 更不用说调试 (debugging) 了

- 现实情况
  - 大量**一次性**的解决方案，自定义代码
  - 编写自己的专用库，然后使用它进行编程
  - 程序员显式**管理一切负担**

What is the point?

隐藏细节

- **开发者不需要关心 race conditions, lock contention 等并发问题**

分离 What 和 How

- **开发者指定需要执行的计算**
- **执行框架 (“runtime”) 处理实际的计算**

Computational Model for Web-scale Information Processing: MapReduce

大数据并行运算编程模型

MapReduce: Simplified Data Processing on Large Clusters

Jeffrey Dean and Sanjay Ghemawat

jeff@google.com, sanjay@google.com

Google, Inc.

典型的大数据计算问题

- Iterate over a large number of records
- Extract something of interest from each
- Shuffle and sort intermediate results
- Aggregate intermediate results
- Generate final output

Map

Reduce

Key idea: provide a functional abstraction for these two operations

数据流以特定结构呈现，即 key-value 分布式存储

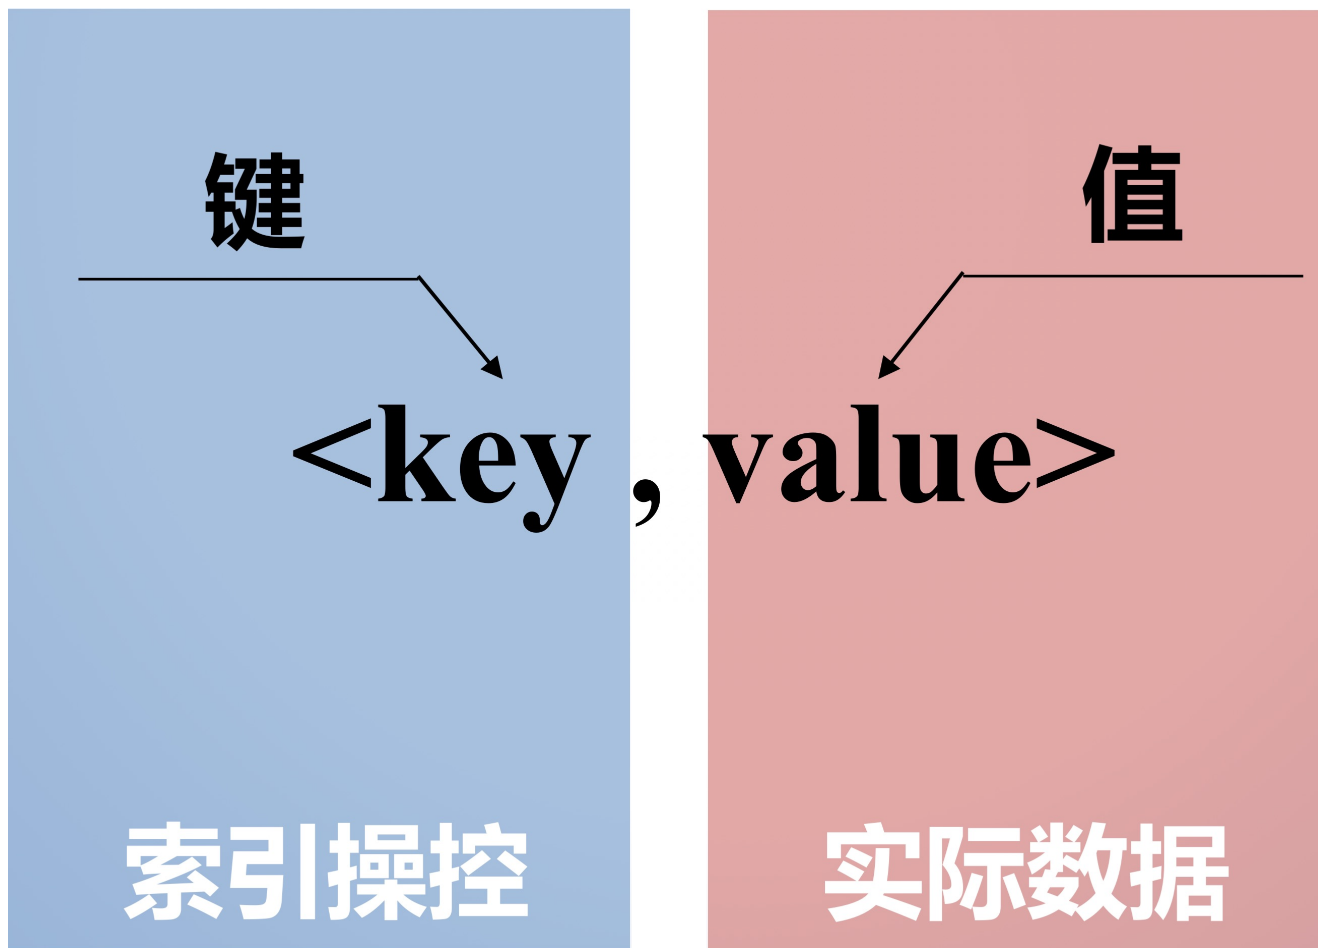

MapReduce

Map：映射操作 定义 **Reduce：归纳化简**

主要操作

Map

$(key_1, val_1) \dashrightarrow <key_2, val_2>^*$

Reduce

$(key_2, val_2) \dashrightarrow <key_3, val_3>^*$

- All values with the same key are sent to the same reducer
- <a, b>* means a list of tuples in the form of (a, b)

开发人员仅需指定 Map 和 Reduce 函数，
并行计算框架负责执行

MapReduce

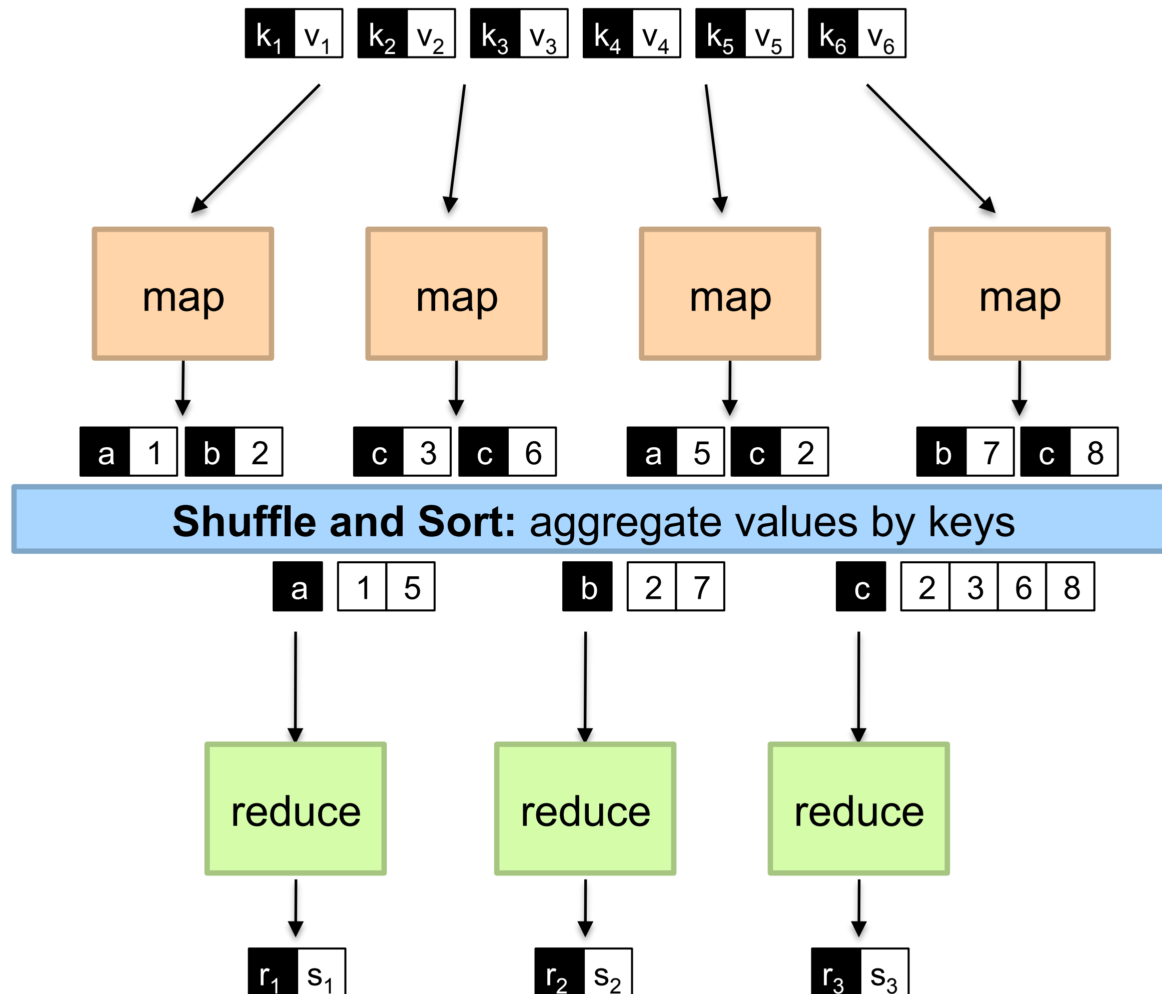

MapReduce是一个软件框架，简化复杂编程

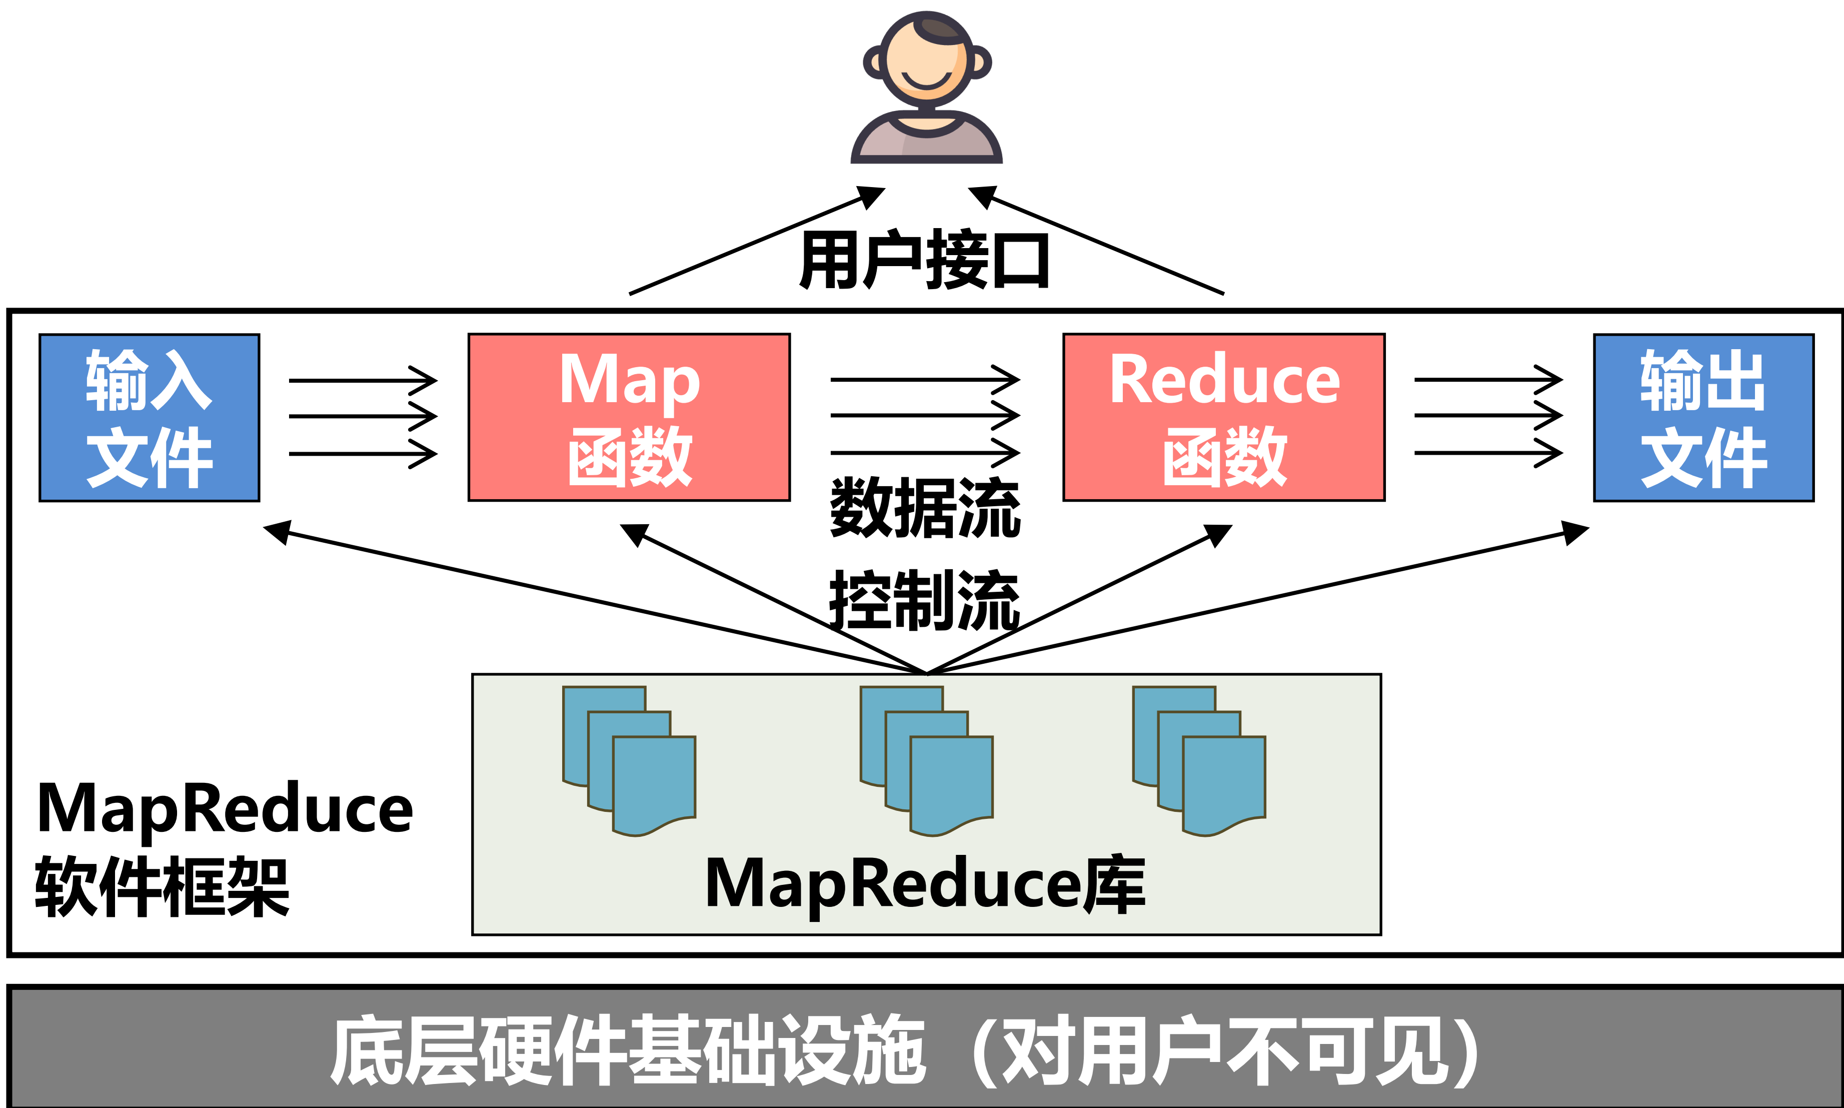

回顾计数问题

Hello World Bye World
Hello SYSU Bye SYSU
Bye SYSU Hello SYSU

Map

Hello (1) World (1) Bye (1) World (1)
Hello (1) SYSU (1) Bye (1) SYSU (1)
Bye (1) SYSU (1) Hello (1) SYSU (1)

回顾计数问题

Hello (1) World (1) Bye (1) World (1)
Hello (1) SYSU (1) Bye (1) SYSU (1)
Bye (1) SYSU (1) Hello (1) SYSU (1)

Shuffle

Hello (1) Hello (1) Hello (1)
World (1) World (1)
Bye (1) Bye (1) Bye (1)
SYSU (1) SYSU (1) SYSU (1) SYSU (1)

回顾计数问题

Hello (1) Hello (1) Hello (1)
World (1) World (1)
Bye (1) Bye (1) Bye (1)
SYSU (1) SYSU (1) SYSU (1) SYSU (1)

Reduce

Hello： (1+1+1=3)
World： (1+1=2)
Bye： (1+1+1=3)
SYSU： (1+1+1+1=4)

MapReduce能够提供 数据并行 型计算的动态调度

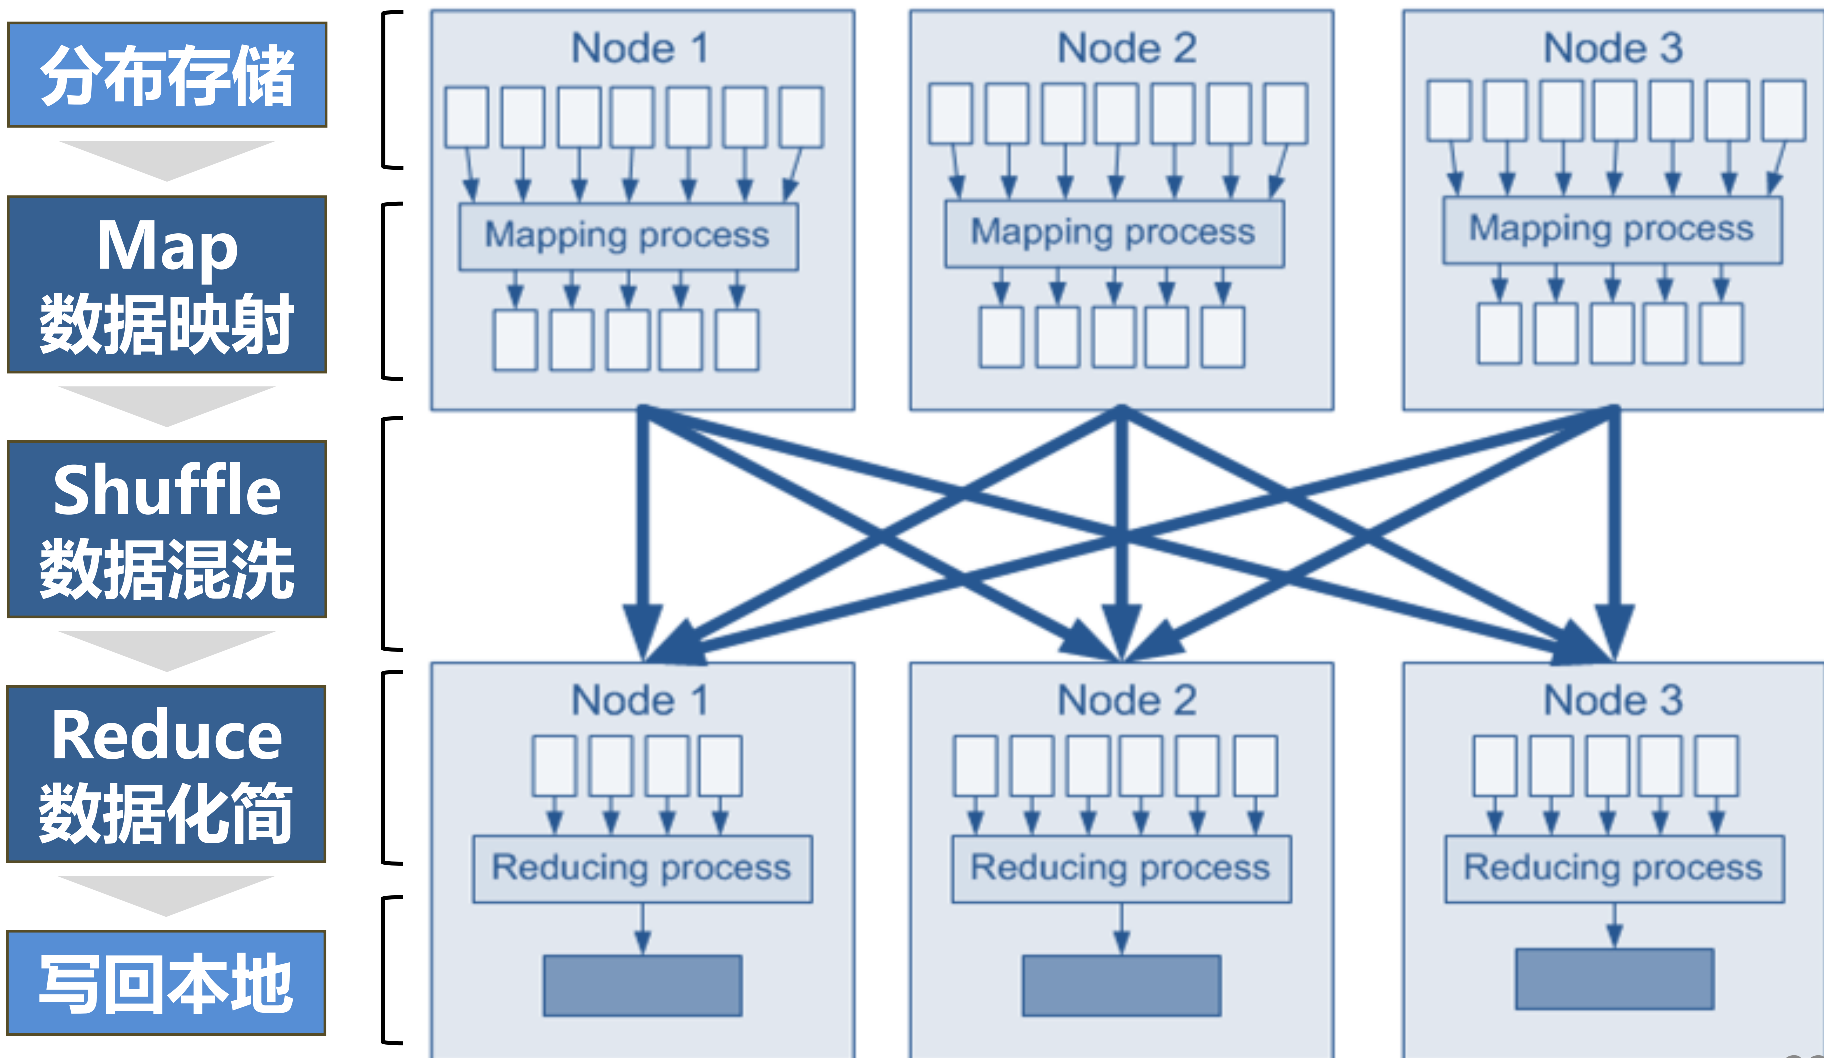

Q: MapReduce 适用性判断

□判断以下场景是否适合用 MapReduce，填 ✓ 或 X：

场景描述	✓ / X
1. 统计 10TB 网站日志中每个 URL 访问次数	___
2. 训练深度神经网络（需反复迭代）	___
3. 对 100 亿条订单按用户 ID 汇总消费总额	___
4. 实时处理搜索请求（< 100ms）	___
5. 对超大文本建立倒排索引	___

总结： MapReduce 最适合 ____ 类型任务，不适合 ______ 和 ________ 类型任务

MapReduce 是开源框架 Hadoop 的核心

Hadoop的计算模型，提供一种基于写入-读取的并行编程模型，用于大规模数据集的并行处理

Hadoop的分布式文件系统，支持在成千上万的服务器节点上分布式存储大量的数据

The Google File System

Sanjay Ghemawat, et al. The Google File System. SOSP 2003.

Fun "facts" about Jeff Dean

来自崇拜他的（前）谷歌员工们

- 编译器不会给 Jeff 警告，但 Jeff 会警告编译
- Jeff 直接用二进制写代码，他写源代码是为了给其他开发人员参考
- Jeff 写代码的速度在 2000 年底提高了 40 倍，原因是他更新了 USB 2.0 的键盘
- 当 Jeff 失眠时，他的大脑用 MapReduce 数羊
- 所有的指针都指向了 Jeff
- Jeff 的手表会显示从 1970 年 1 月 1 日起的秒数，他从不迟到
- To Jeff Dean, "NP" means "No Problem”

More: https://zhuanlan.zhihu.com/p/33047210

MapReduce 优化

MapReduce 深度优化

分布式计算的任务拖延问题

映射

计算任务

He was an old man who fished alone in a skiff in the Gulf Stream and he had gone...

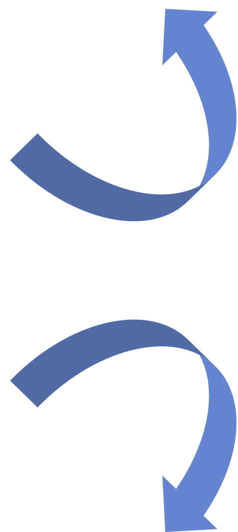

task

task

task

task

task

task

化简

计算结果

词	频
fish	3%
old	3%
man	3%
now	3%
down	2%
when	2%
line	2%

MapReduce 深度优化

分布式计算的任务拖延问题

映射

计算任务

He was an old man who fished alone in a skiff in the Gulf Stream and he had gone...

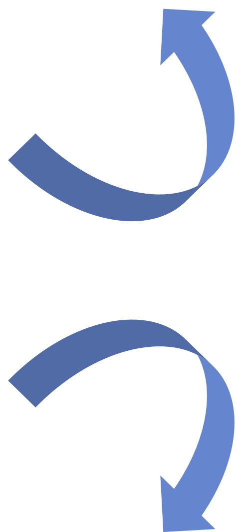

task

task

task

task

task 延迟任务

task

化简

计算结果

词	频
fish	3%
old	3%
man	3%
now	3%
down	2%
when	2%
line	2%

MapReduce 深度优化

利用空闲节点避免应用进度滞后

MapReduce 的一个关键优点是自动处理故障，若一个节点崩溃，则在另一台机器上重新运行其任务

同样重要的是，若一个节点可用但表现不佳，称之为滞后节点 (straggler)，则会在另一台机器上运行其任务的副本（也称为“备份执行"），以更快地完成计算

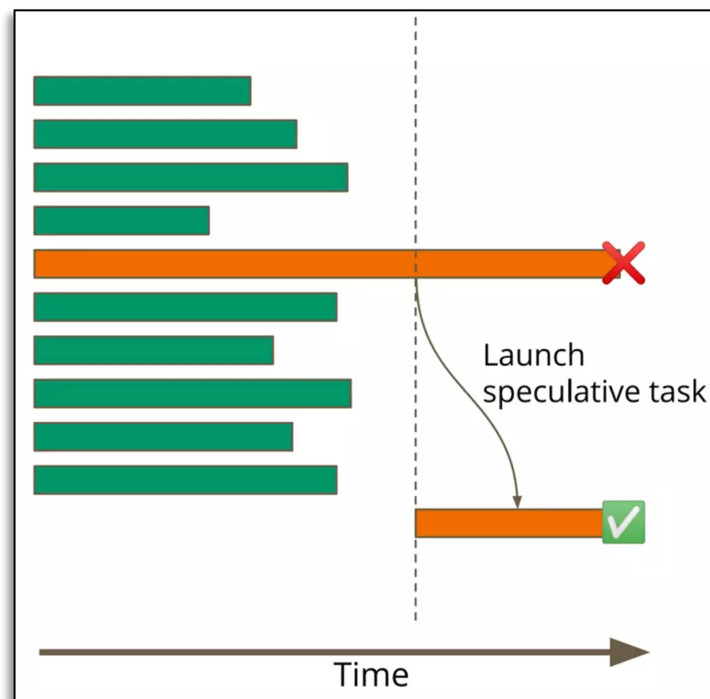

MapReduce 深度优化

利用空闲节点避免应用进度滞后

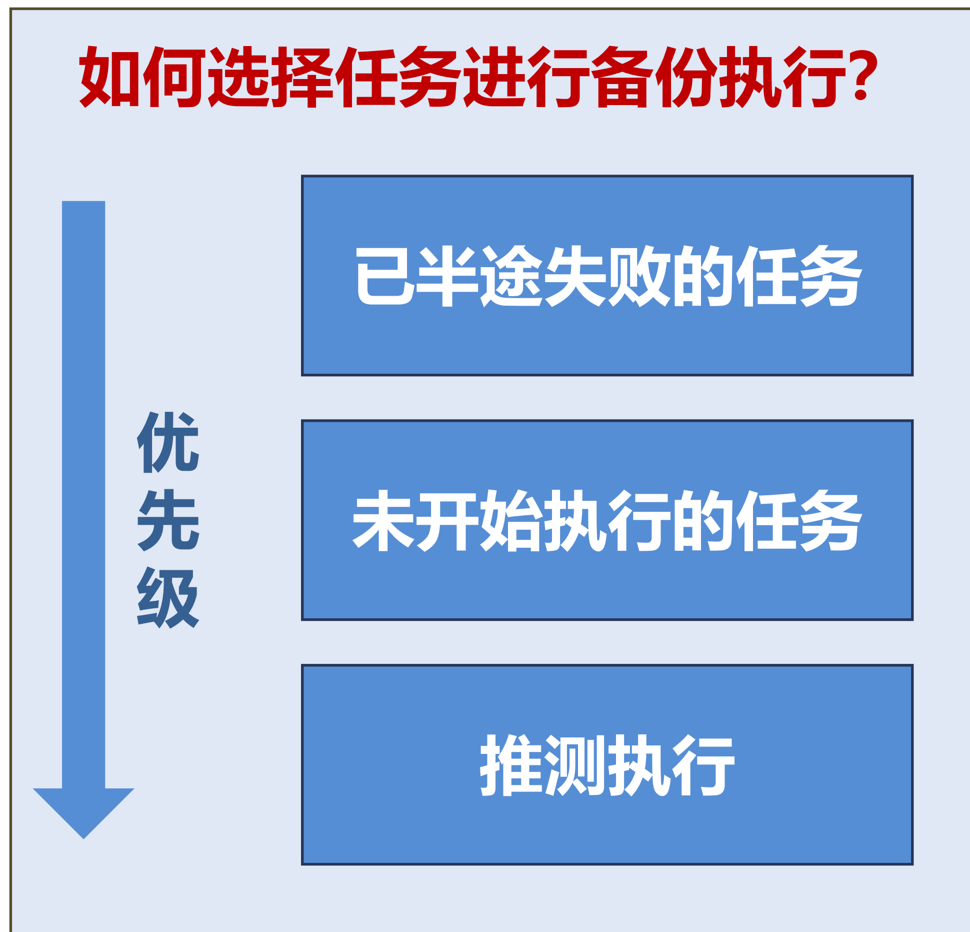

创建副本

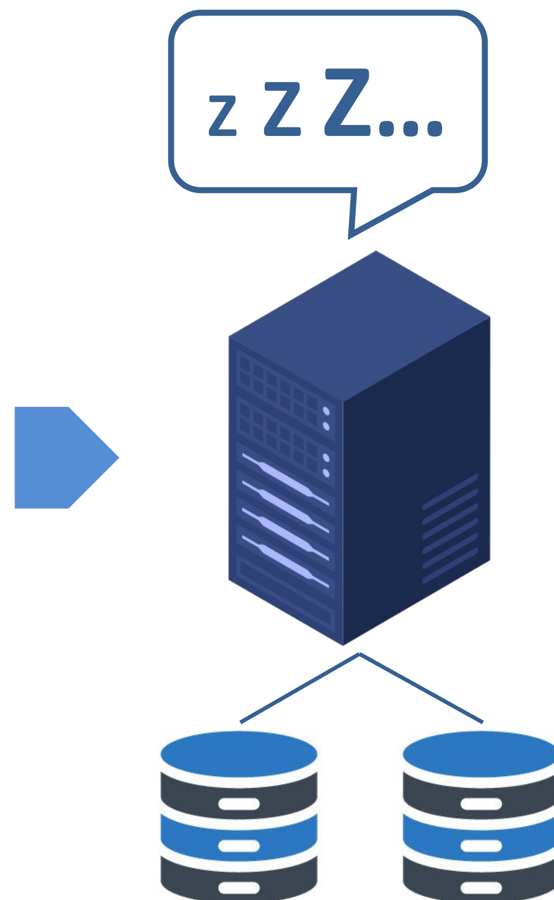

Improving MapReduce Performance in Heterogeneous Environments, OSDI 2008

如何推测哪些任务需要备份执行?

利用空闲节点避免应用进度滞后

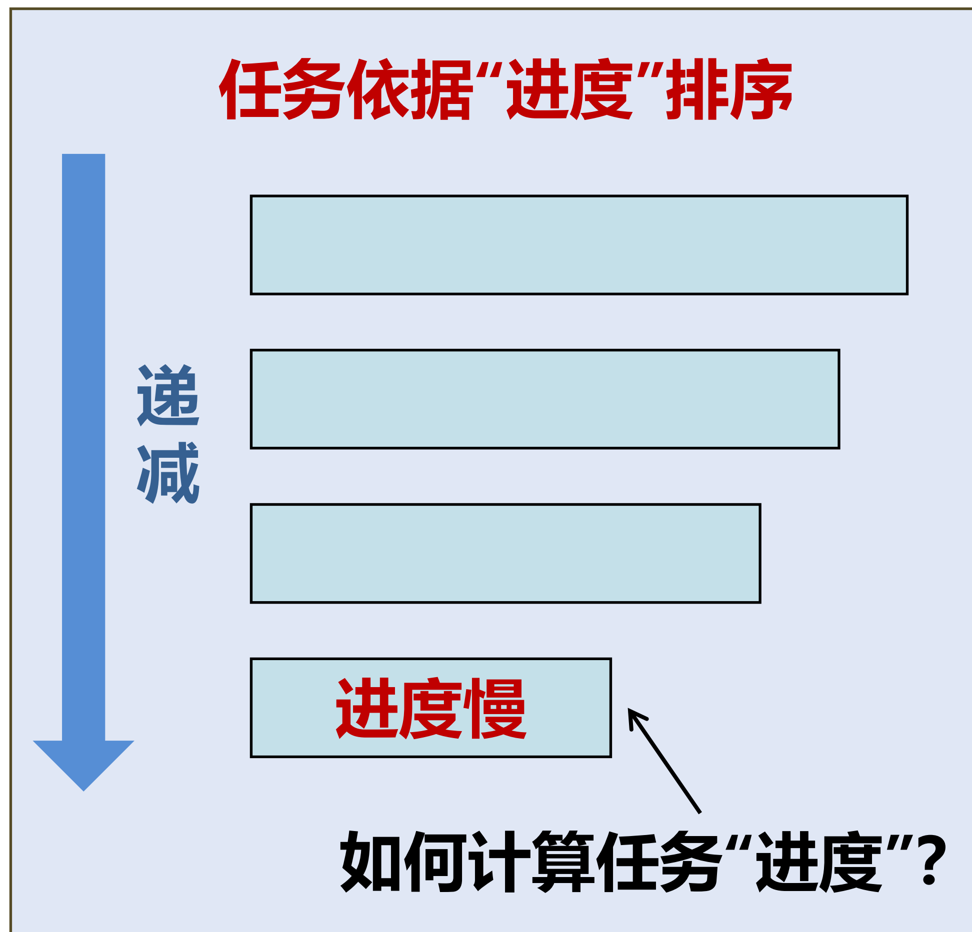

深度优化

推测执行：Map 类任务打分

依据已完成输入的数据的比重

Data loading...

A 进度分：1/3

B 进度分：2/3

深度优化

推测执行：Reduce 类任务打分

依据以下三个部分的进度

1/3分数比重	1/3分数比重	1/3分数比重
数据复制阶段	数据混洗阶段	数据计算阶段

A

进行到一半的复制阶段

A 进度分：1/3*50%=1/6

B

进行到一半的混洗阶段

B 进度分：1/3+1/3*50%=1/2

MapReduce 深度优化

基于排序和阈值的推测执行

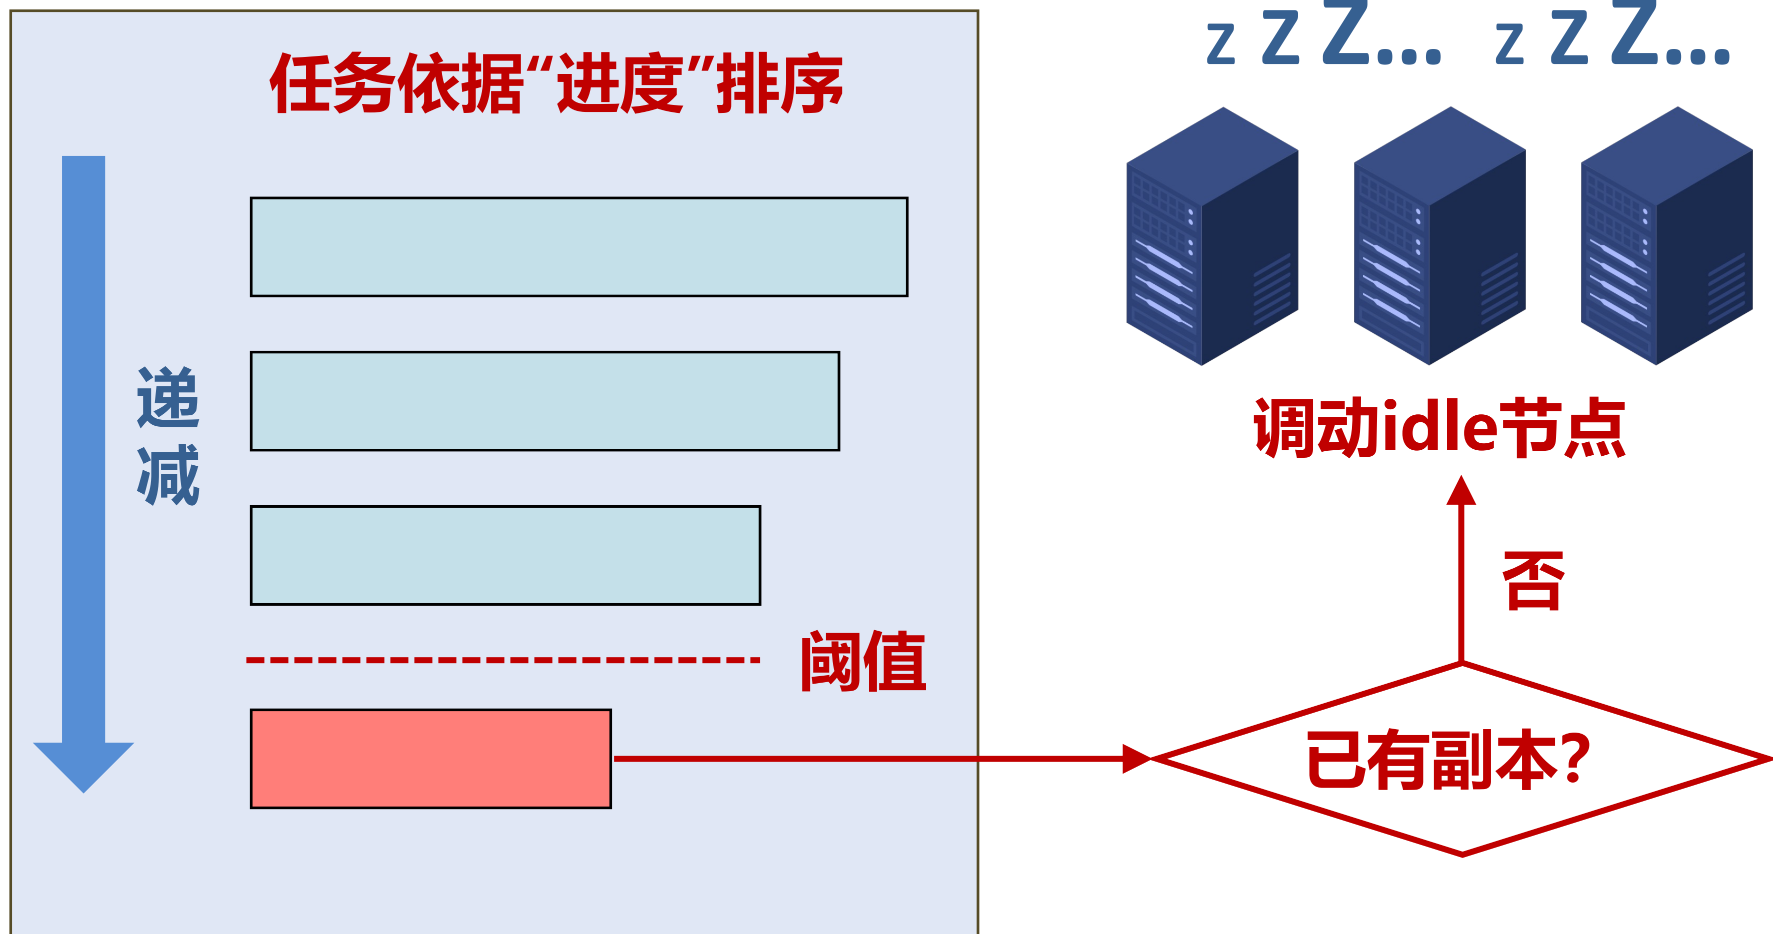

开放思考

图结构处理：数据计算成本小，数据访问开销大

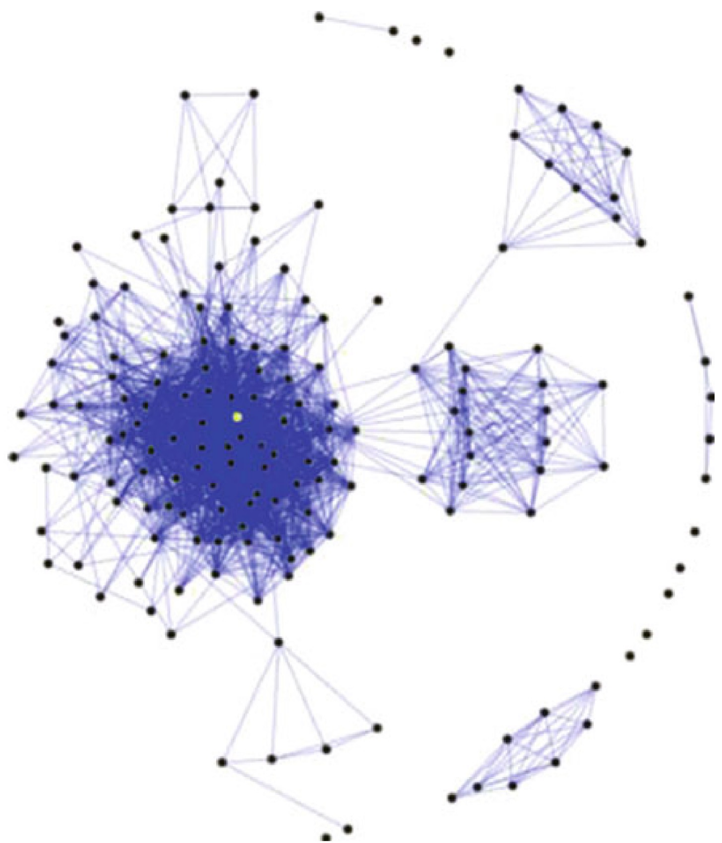

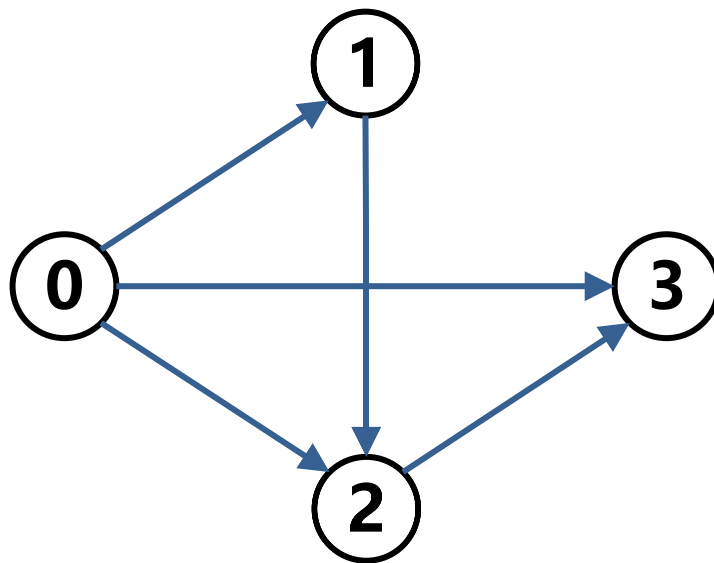

开放思考

图结构处理的GAS模型

The GAS model represents three conceptual phases of a vertex-program: Gather, Apply, and Scatter

Gather: information about adjacent vertices and edges is collected

Apply: updates the value of the central vertex

Scatter: uses the central vertex to update the data on adjacent edges

Spark 和 GraphX

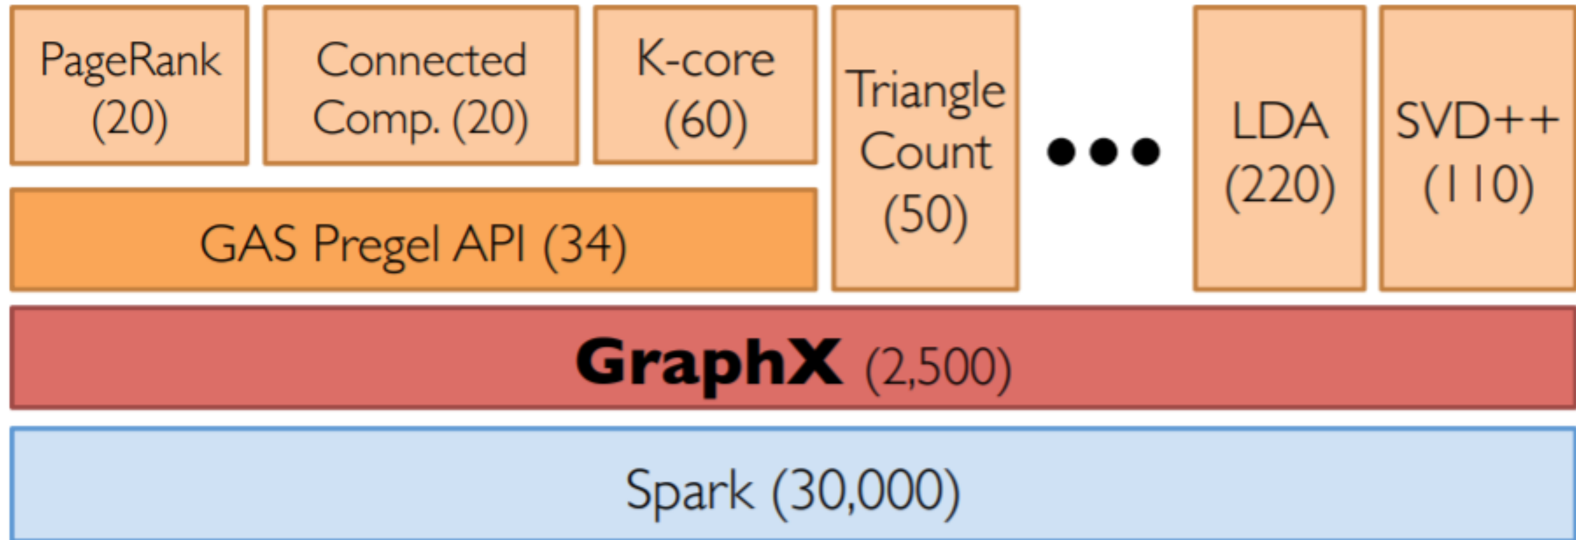

GraphX is a thin layer on top of the Spark general-purpose dataflow framework (lines of code)

https://spark.apache.org/graphx/

并行计算的长尾问题

99th Percentile Latency at Scale with Apache Kafka

Technology < Apache Kafka

FEB 25, 2020 **READ TIME: 23 MIN**

Fraud detection, payment systems, and stock trading platforms are only a few of many Apache Kafka® use cases that require both *fast* and *predictable* delivery of data. For example, detecting fraud for online banking transactions has to happen in real time in order to deliver business value, without adding more than 50—100 ms of overhead to each transaction in order to maintain a good customer experience.

同一起跑线，速度差数倍?

《连线》杂志主编克里斯·安德森和他的“长尾理论”

计算中的长尾

George Zipf
哈佛大学语言学家

"在自然语言的语料库里，一个单词出现的**频率**与它在频率表里的**排名**成**反比**"

乔治·齐夫【美】

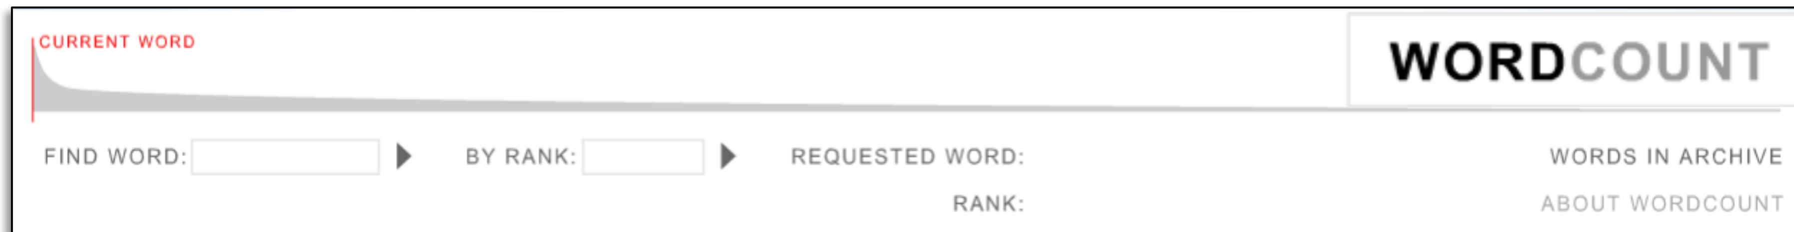

计算中的长尾

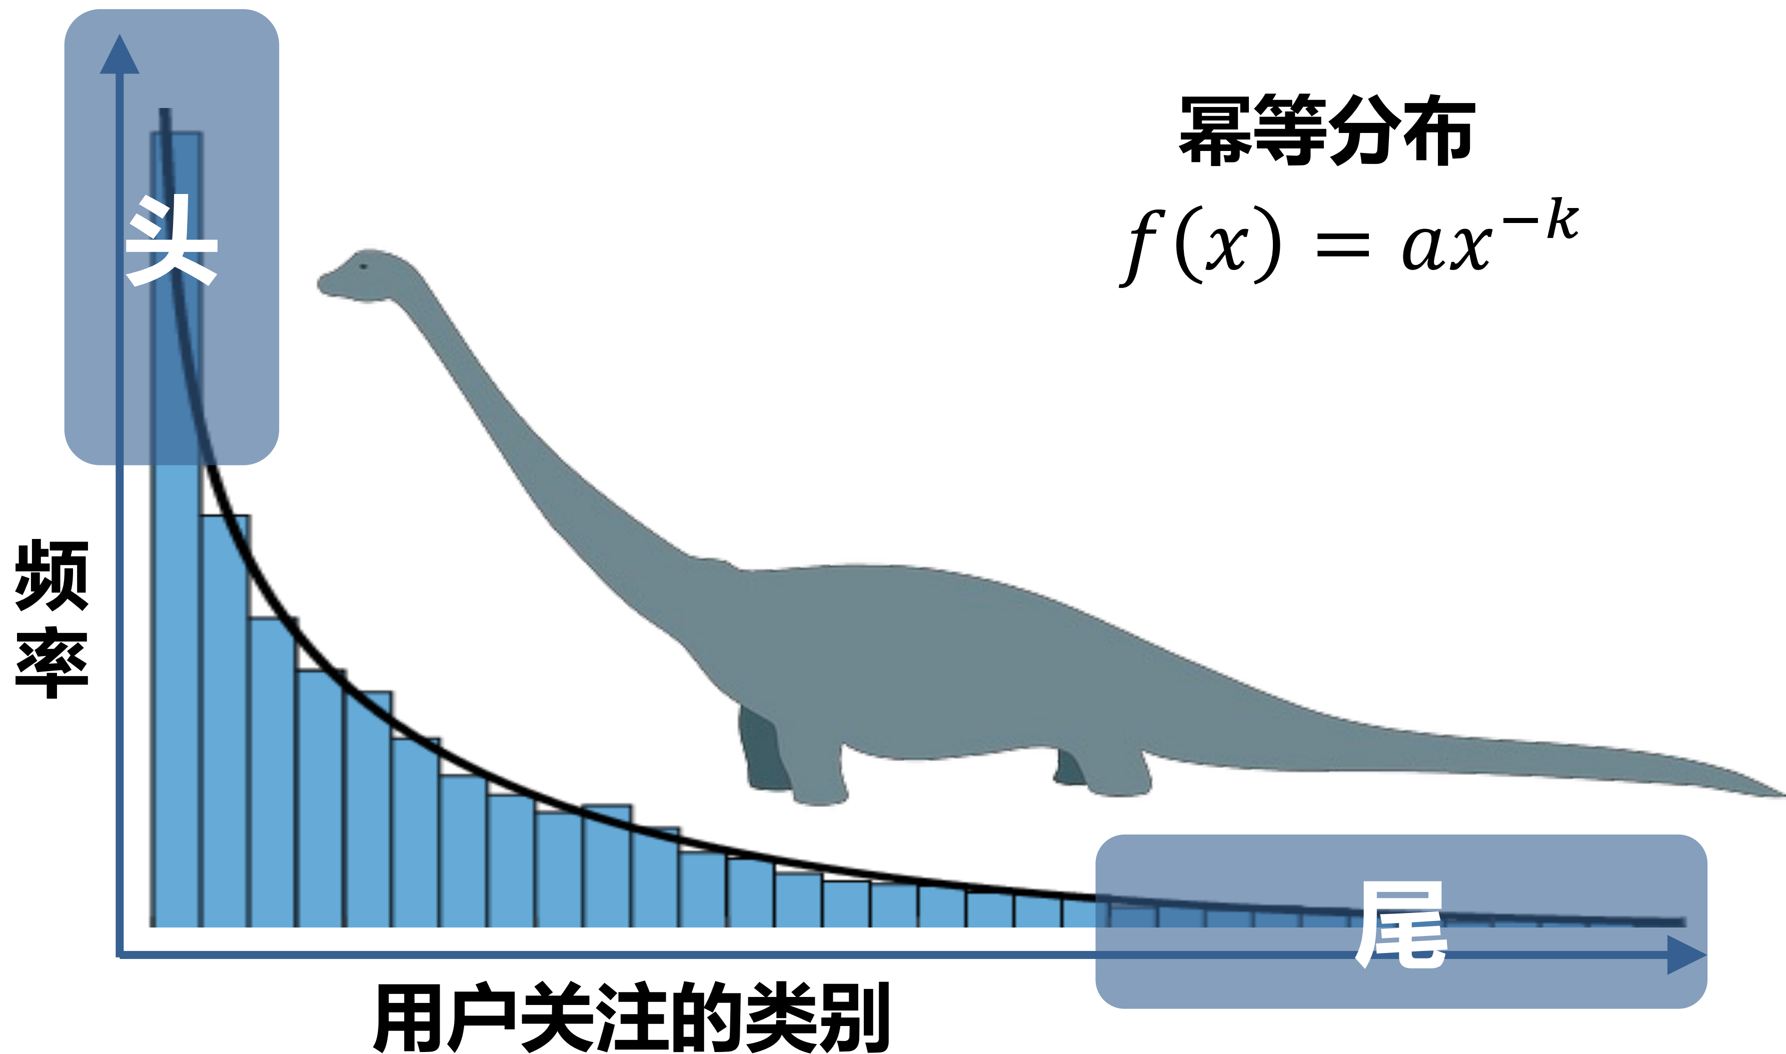

计算中的长尾

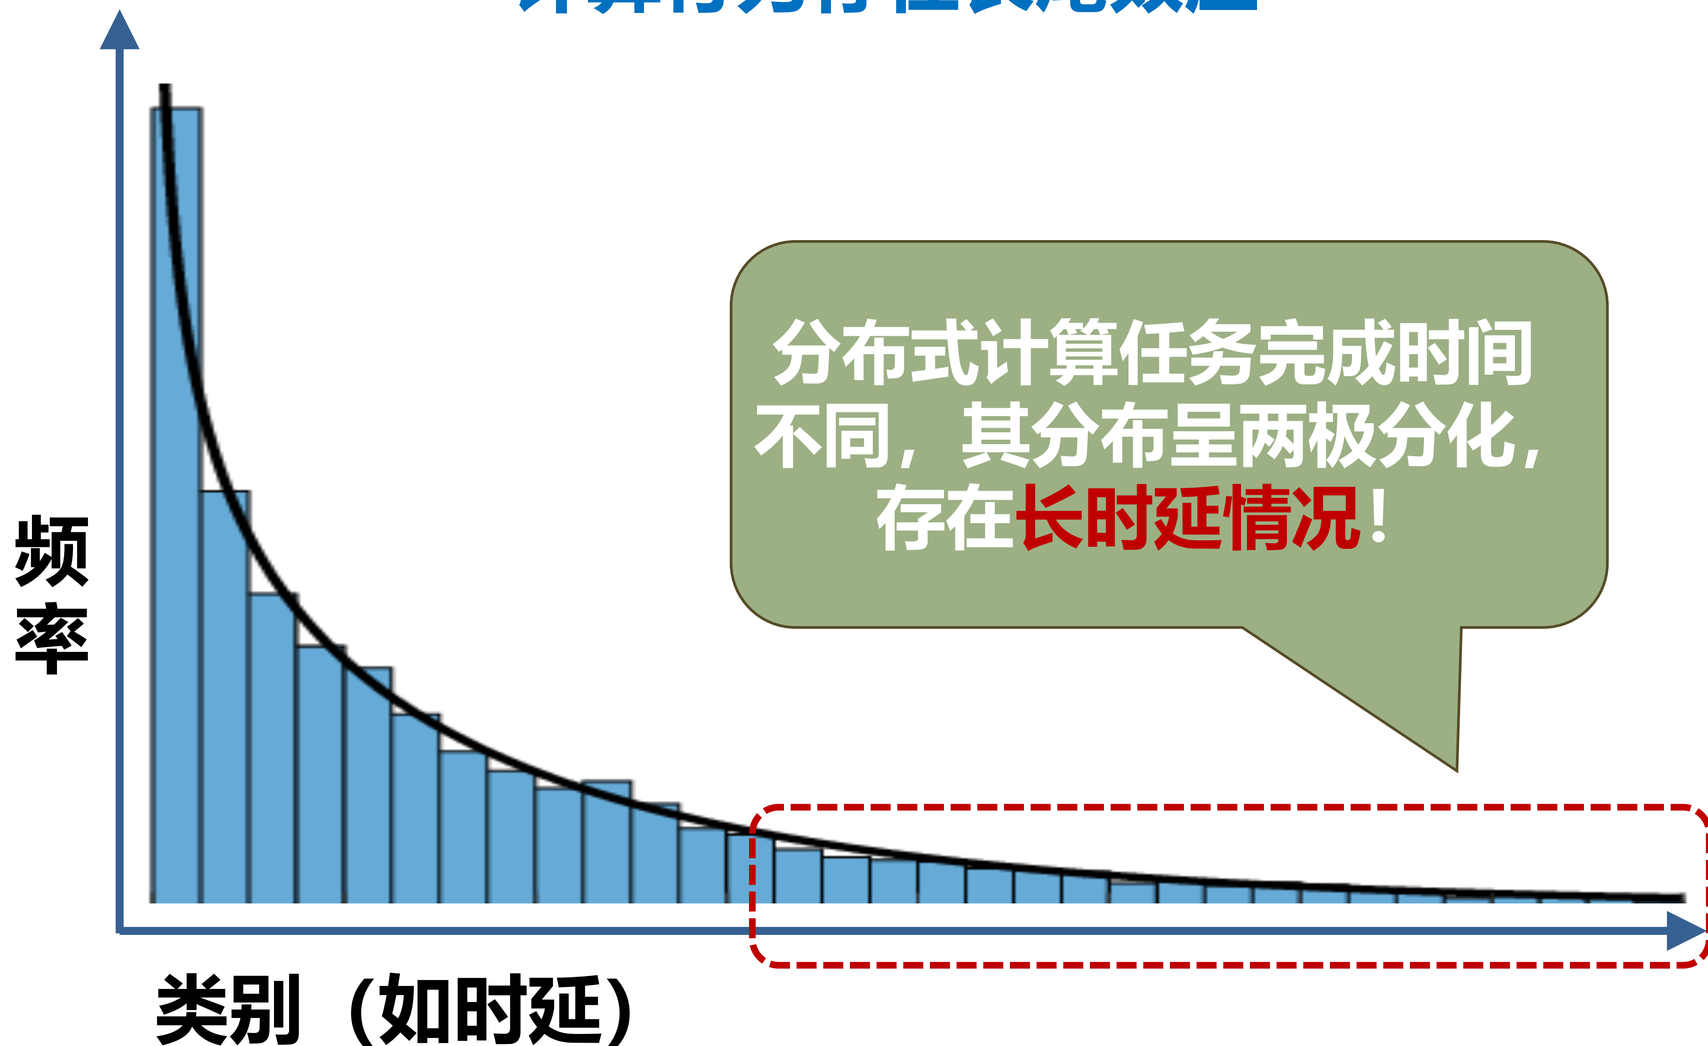

计算中的长尾

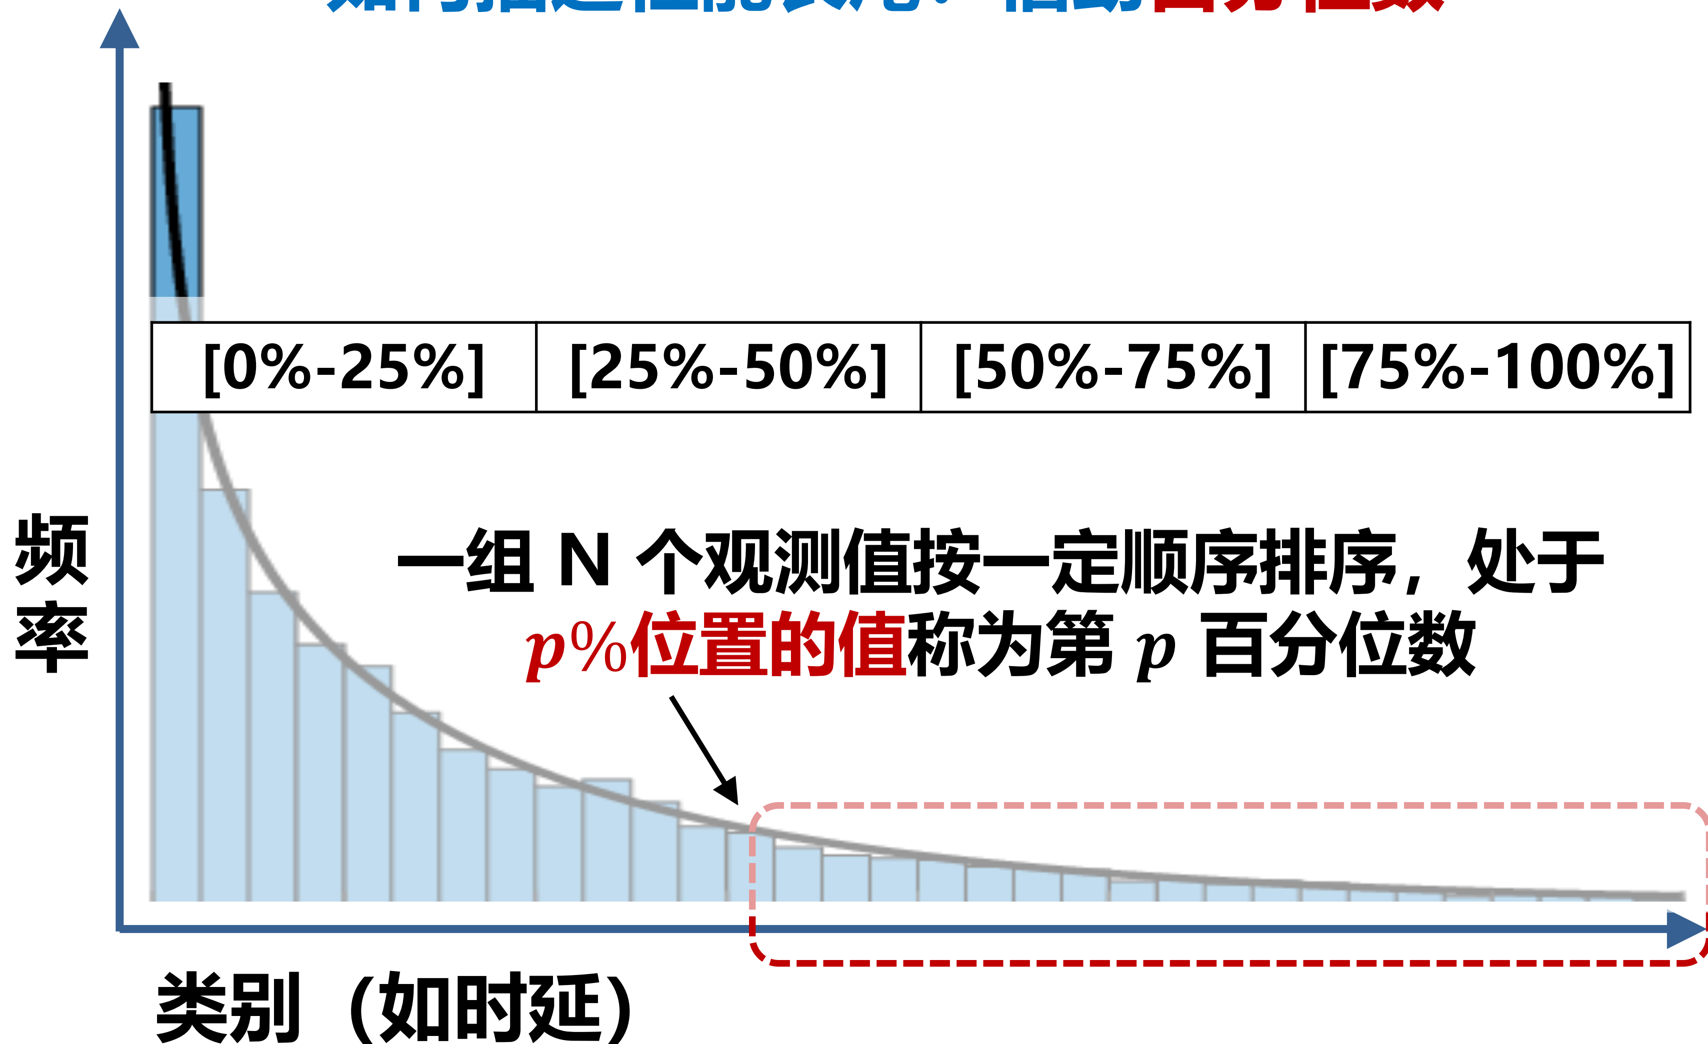

计算中的长尾

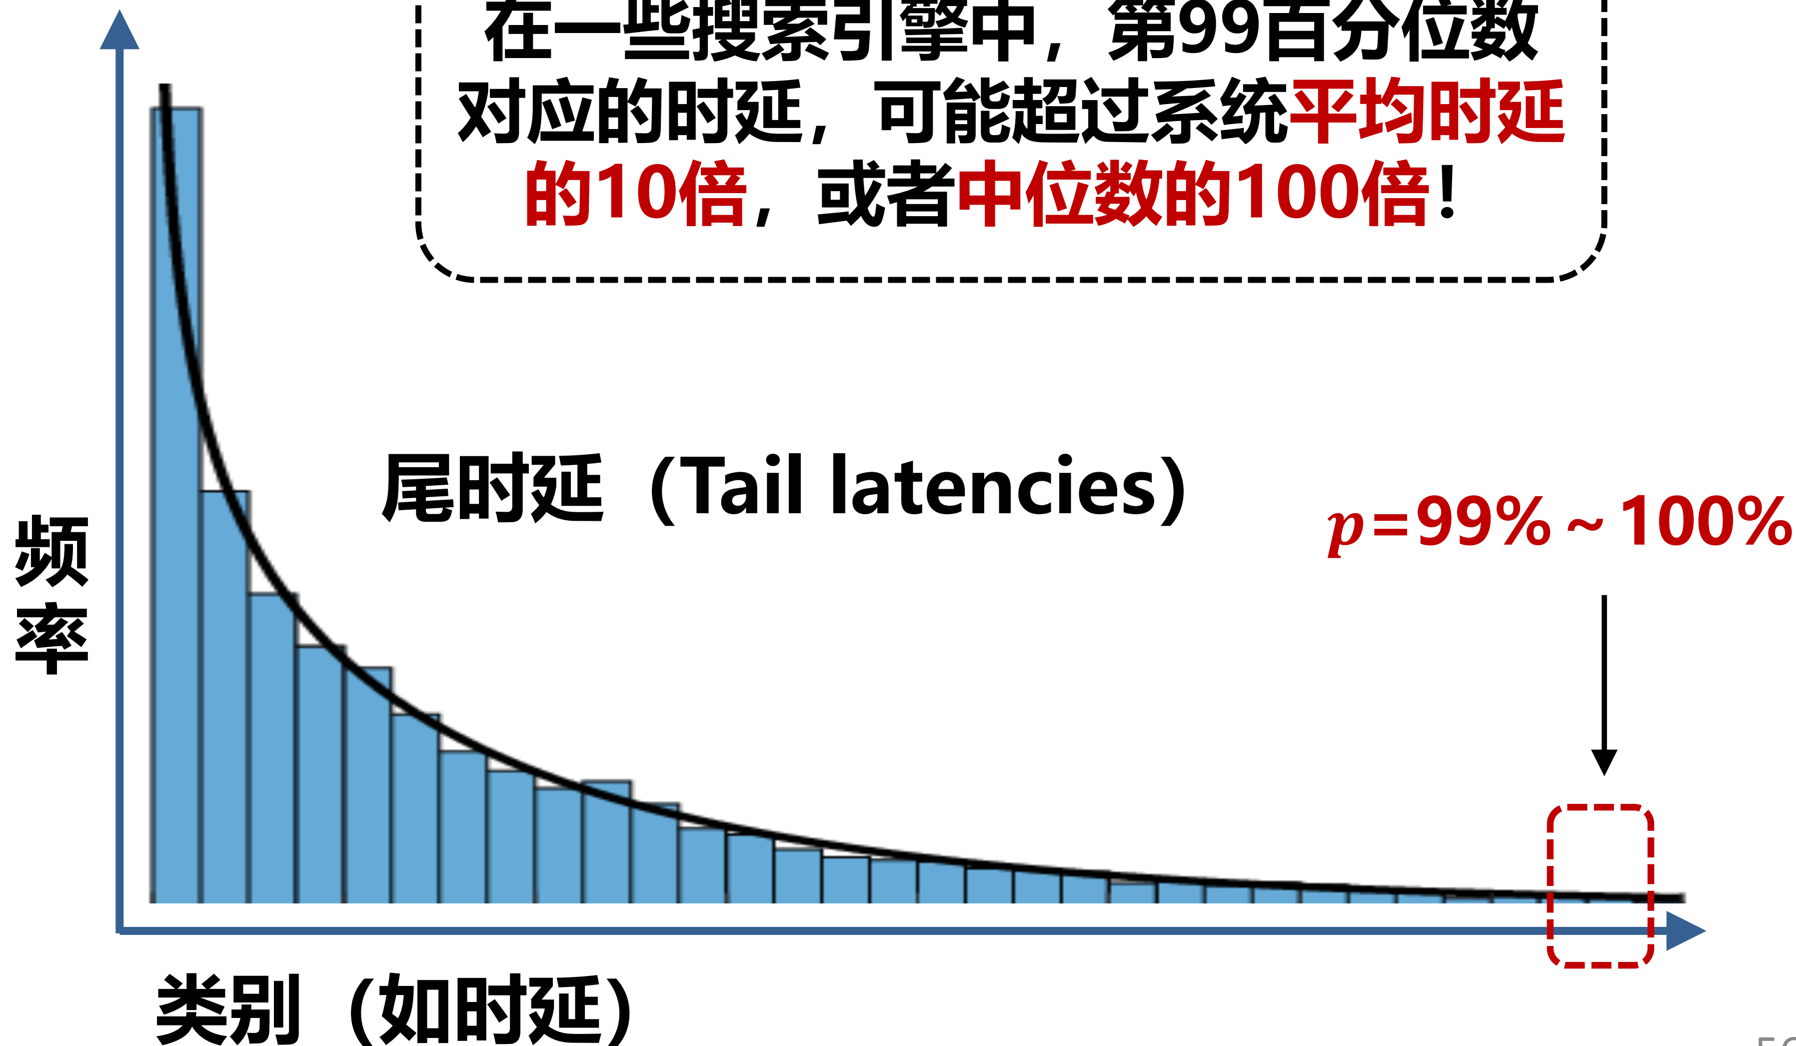

长尾背后的原因

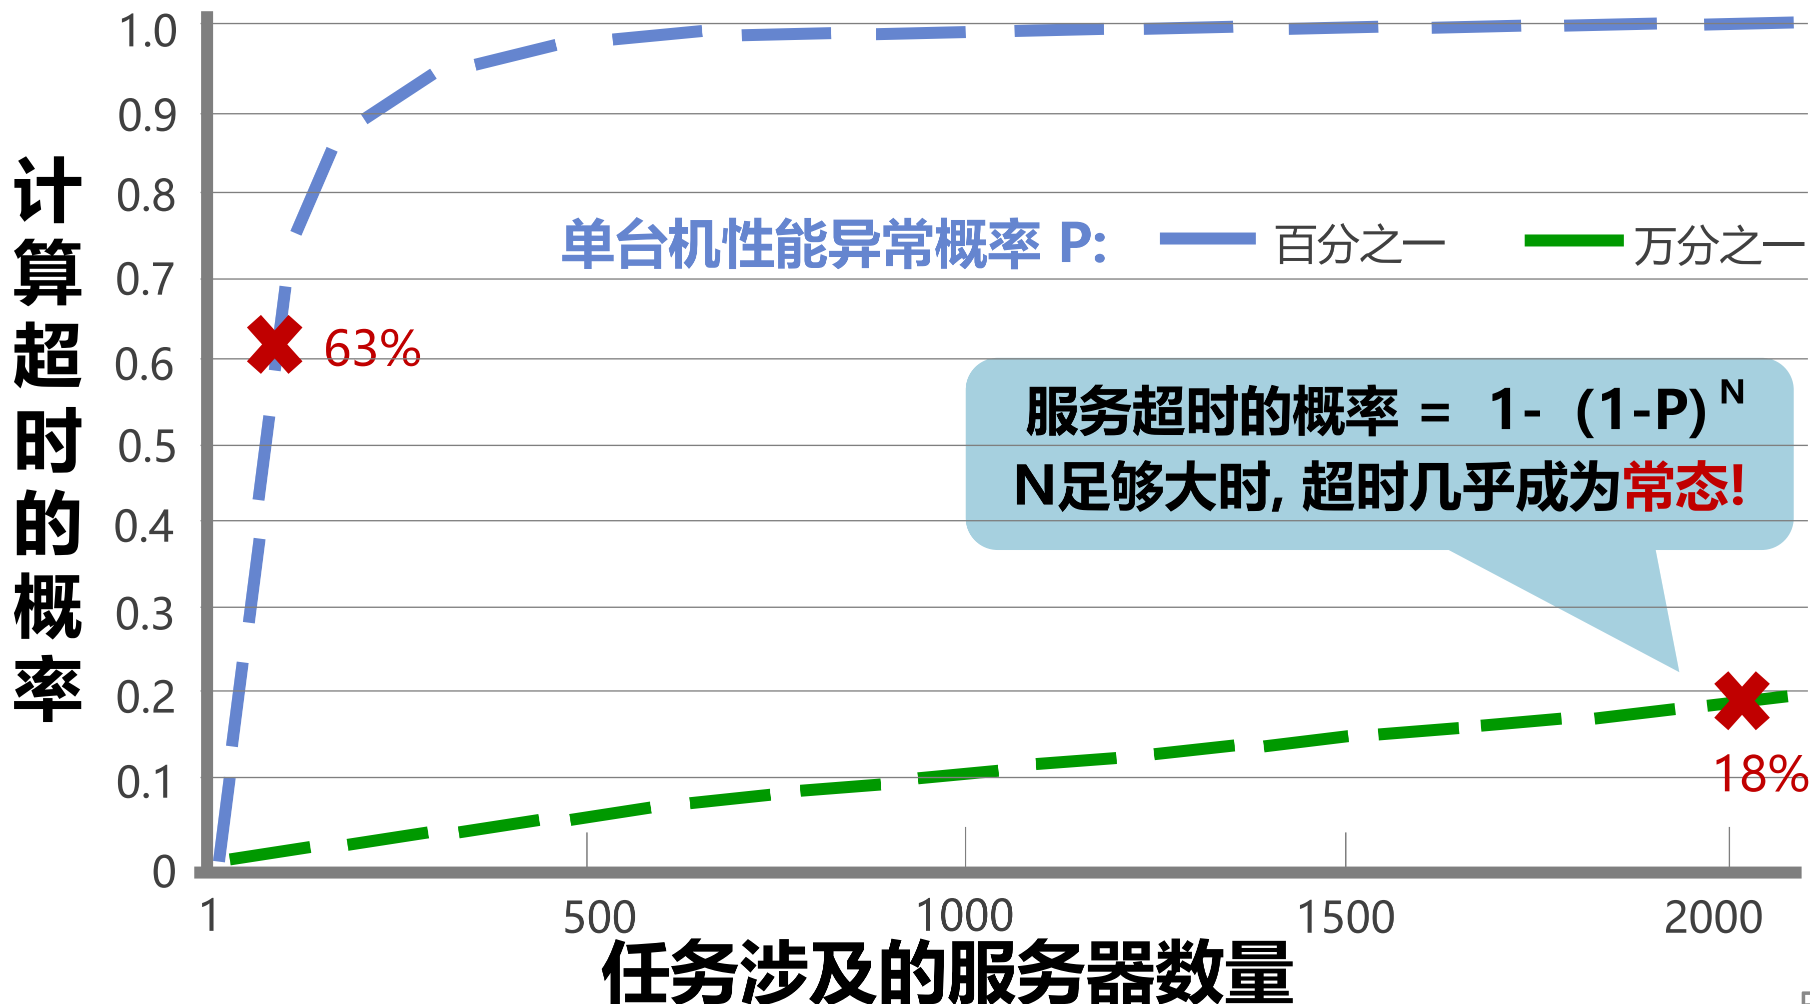

参考：Jeff Dean et al. The tail at scale, CACM, 2013

长尾背后的原因

存在不同时期、规格、和运行环境的设备

速度差异

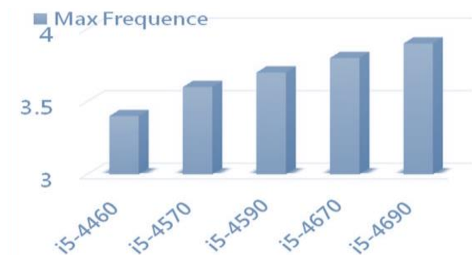

功耗差异

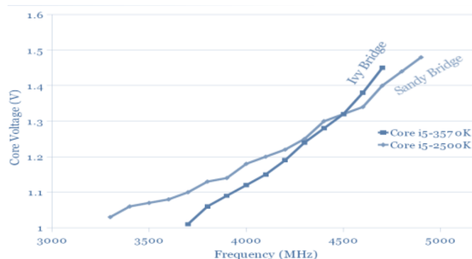

散热差异

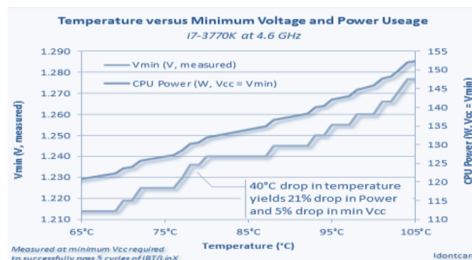

长尾背后的原因

同一批次的计算设备，其他特征也会存在差异

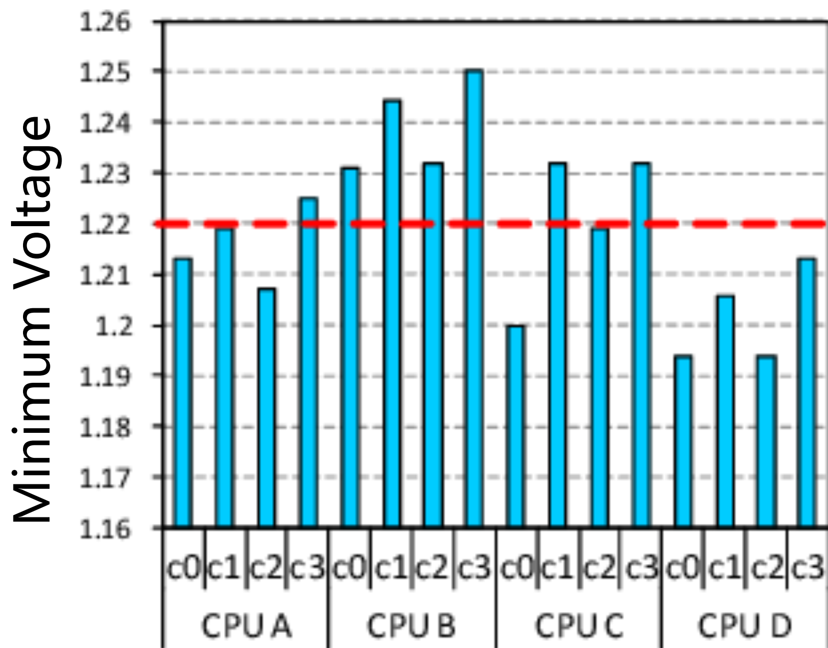

集成显卡关闭状态

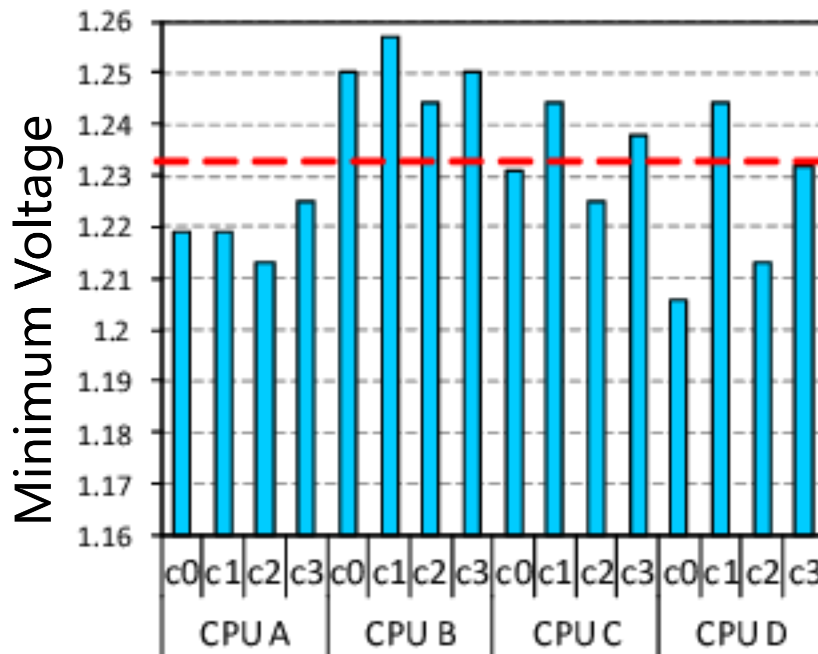

集成显卡打开状态

Tang et al. Exploring Hardware Profile-Guided Green Datacenter Scheduling, ICPP 2015

长尾背后的原因

网络通讯拥塞

计算资源竞争

设备特征差异

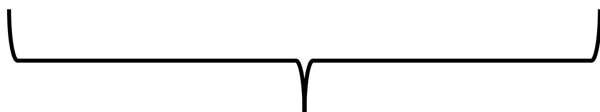

具有不确定性，但可能缓解

难以避免

改善长尾问题

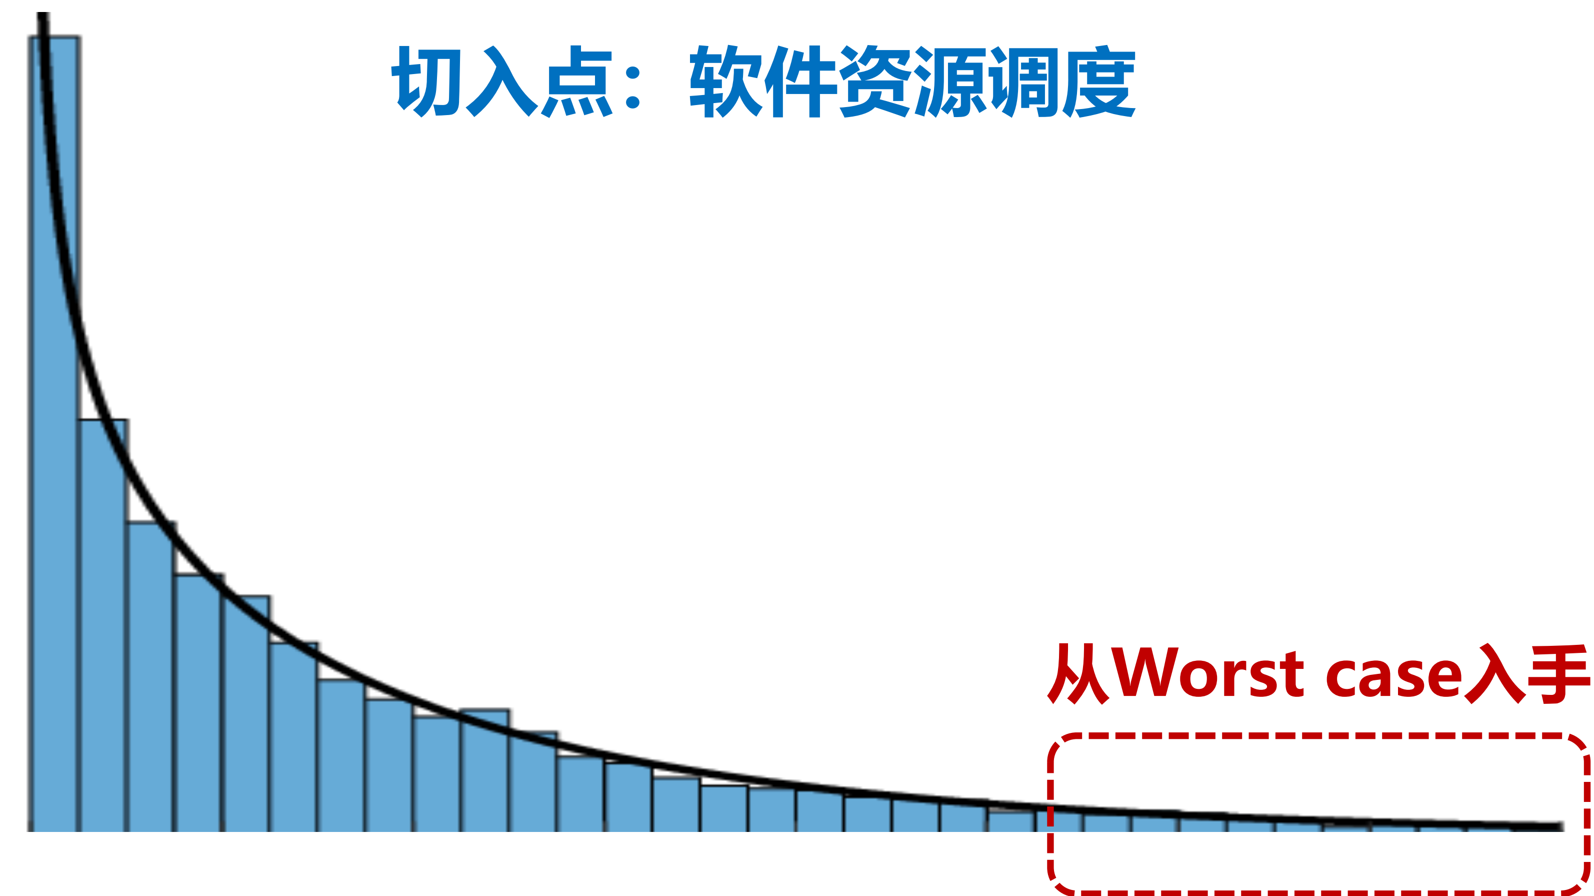

改善长尾问题

DOI:10.1145/2408776.2408794

Software techniques that tolerate latency variability are vital to building responsive large-scale Web services.

BY JEFFREY DEAN AND LUIZ ANDRÉ BARROSO

The Tail at Scale

改善长尾问题

□任务的特征

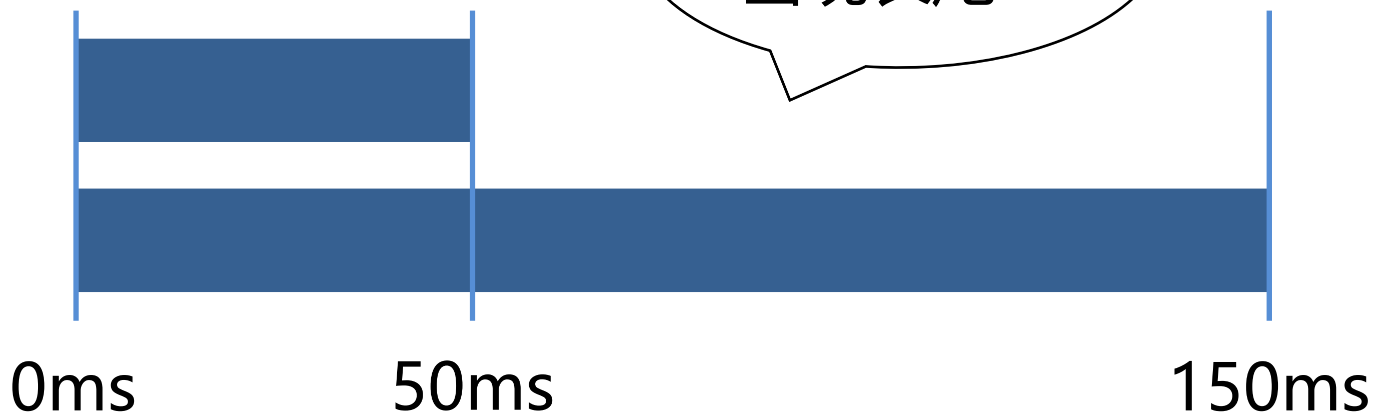

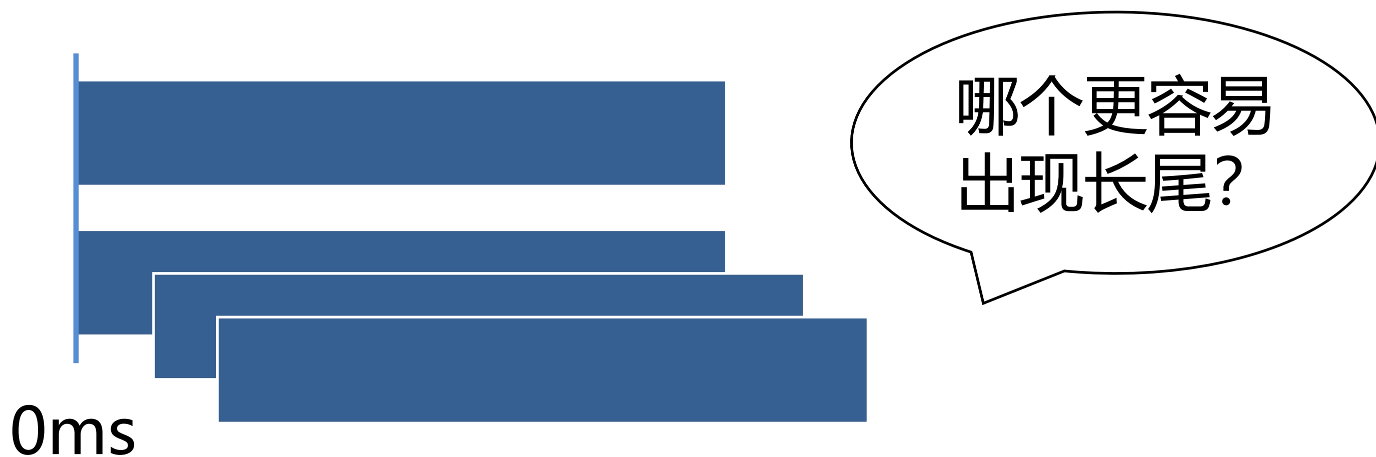

长短任务的长尾特征

- Bing demand distribution and average speedup

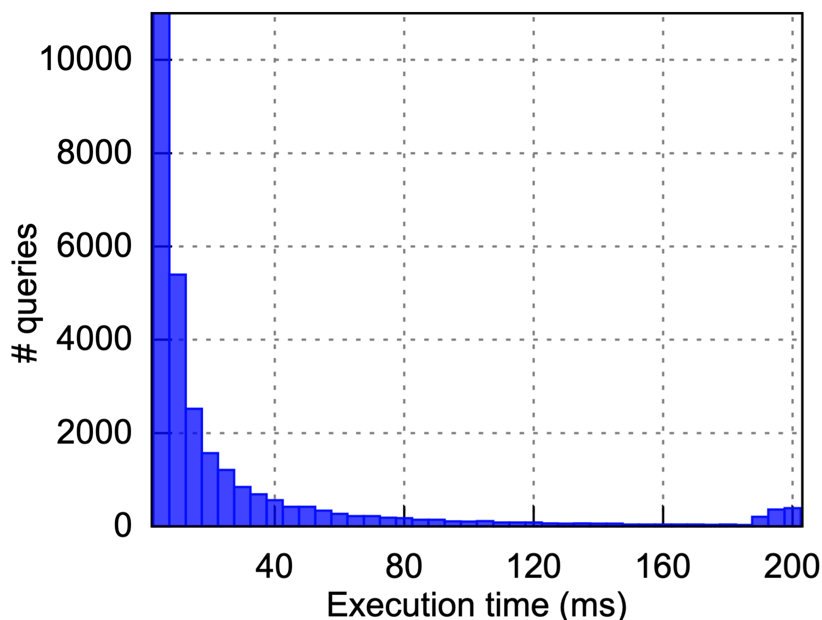

(a) Sequential execution time histogram of 30K requests

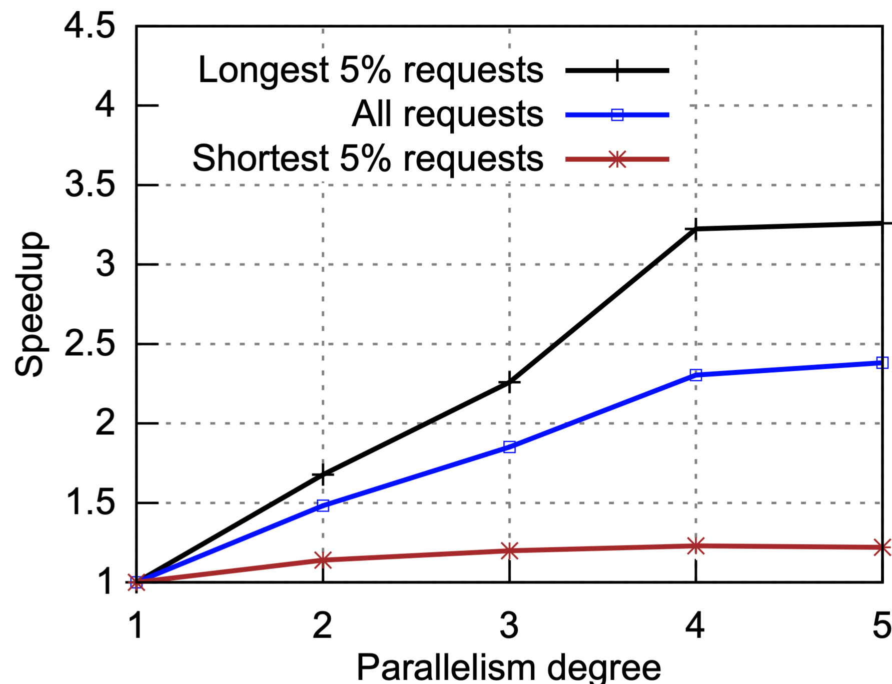

(b) Average speedup

提高长任务的并行度获得的加速比更明显

多少任务的长尾特征

- Effect of fixed parallelism on latency in Lucene

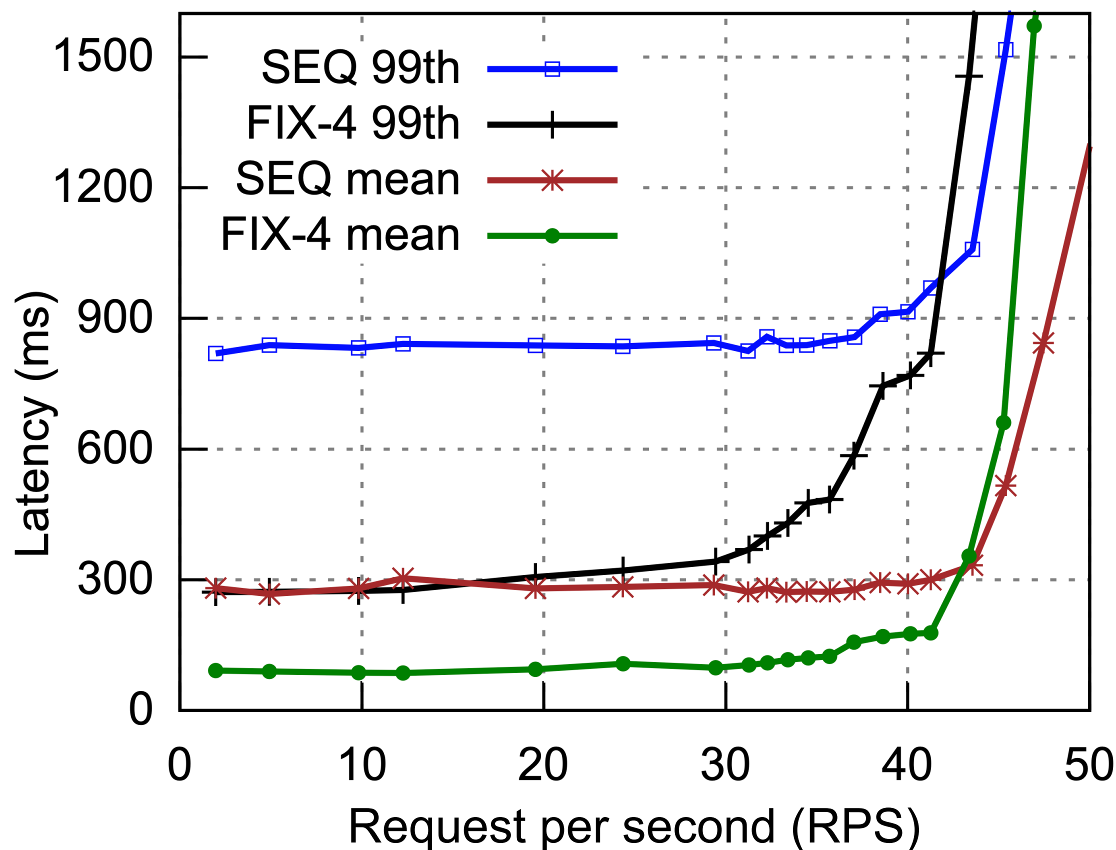

- **SEQ** 每个任务顺序执行
- **FIX-4** 每个任务使用 4 个 worker threads

相同并行度下，多任务更容易出现长尾

Increase the probability that short requests will finish with less parallelism, which saves resources, while assigns long requests more parallelism, which reduces tail latency.

问题是，我们无法预测任务的长短！

Few-to-Many (FM) 渐增式调度算法原理

Few-to-Many: Incremental Parallelism for Reducing Tail Latency in Interactive Services. ASPLOS 2015.

改善长尾问题

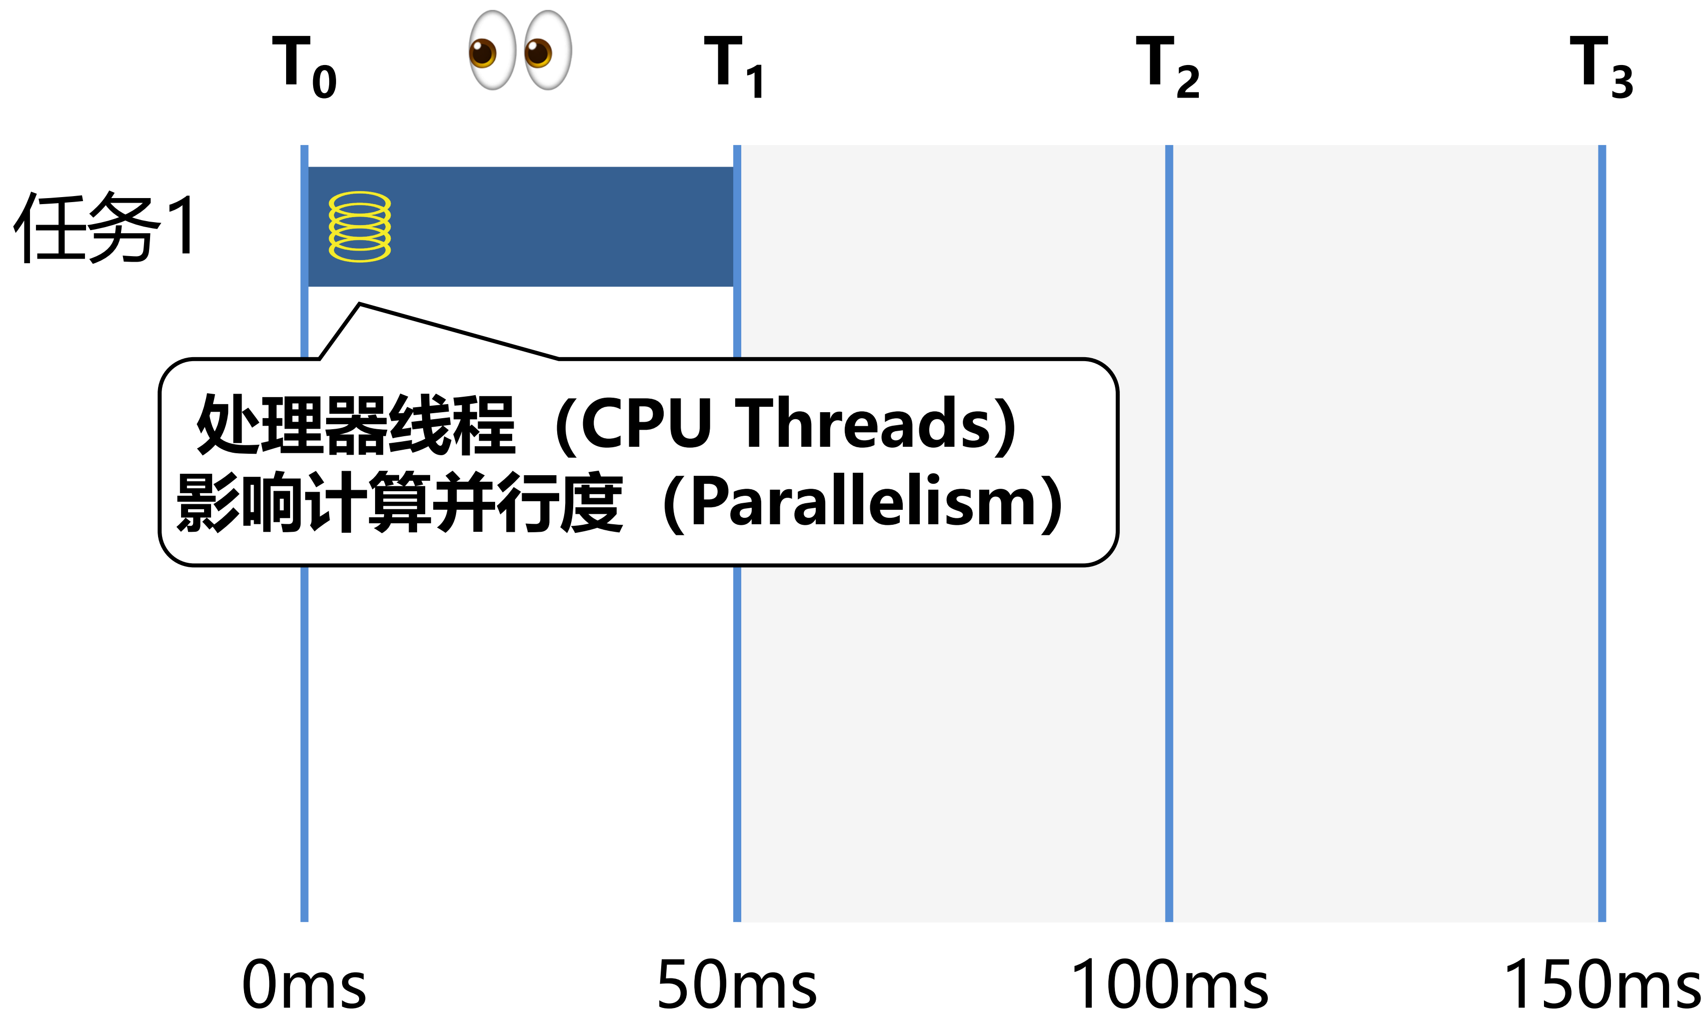

改善长尾问题

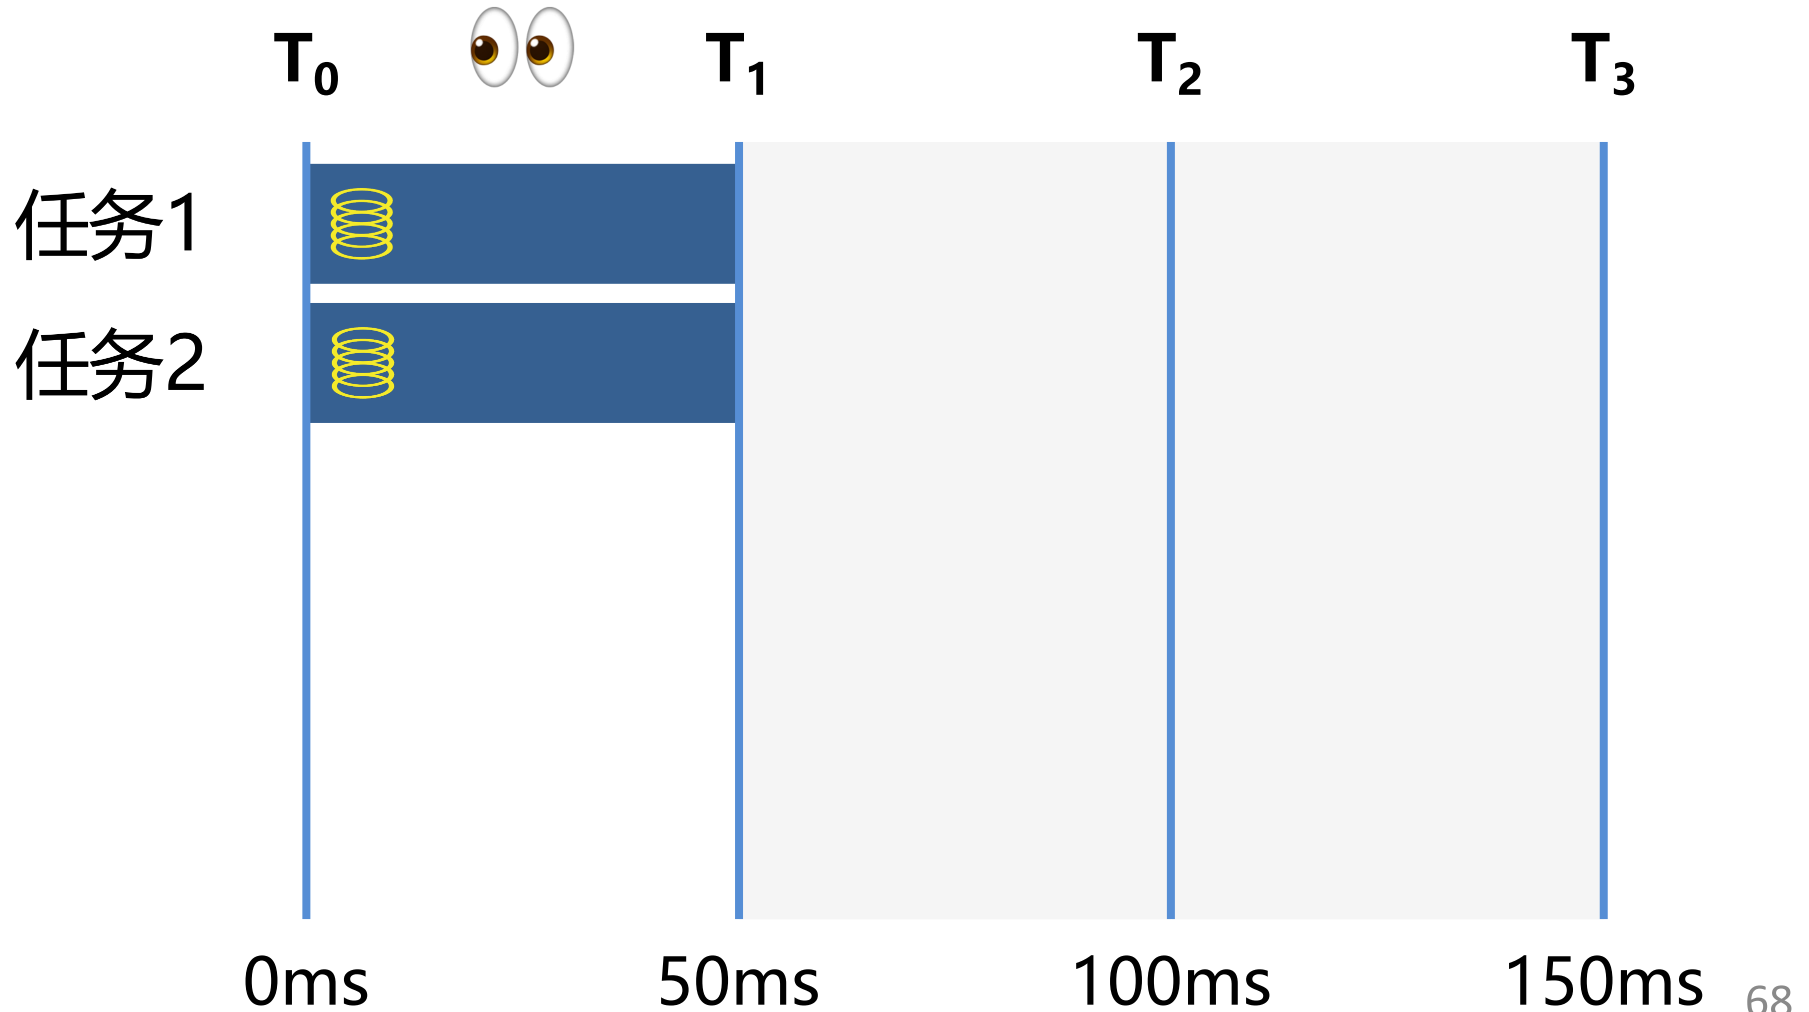

改善长尾问题

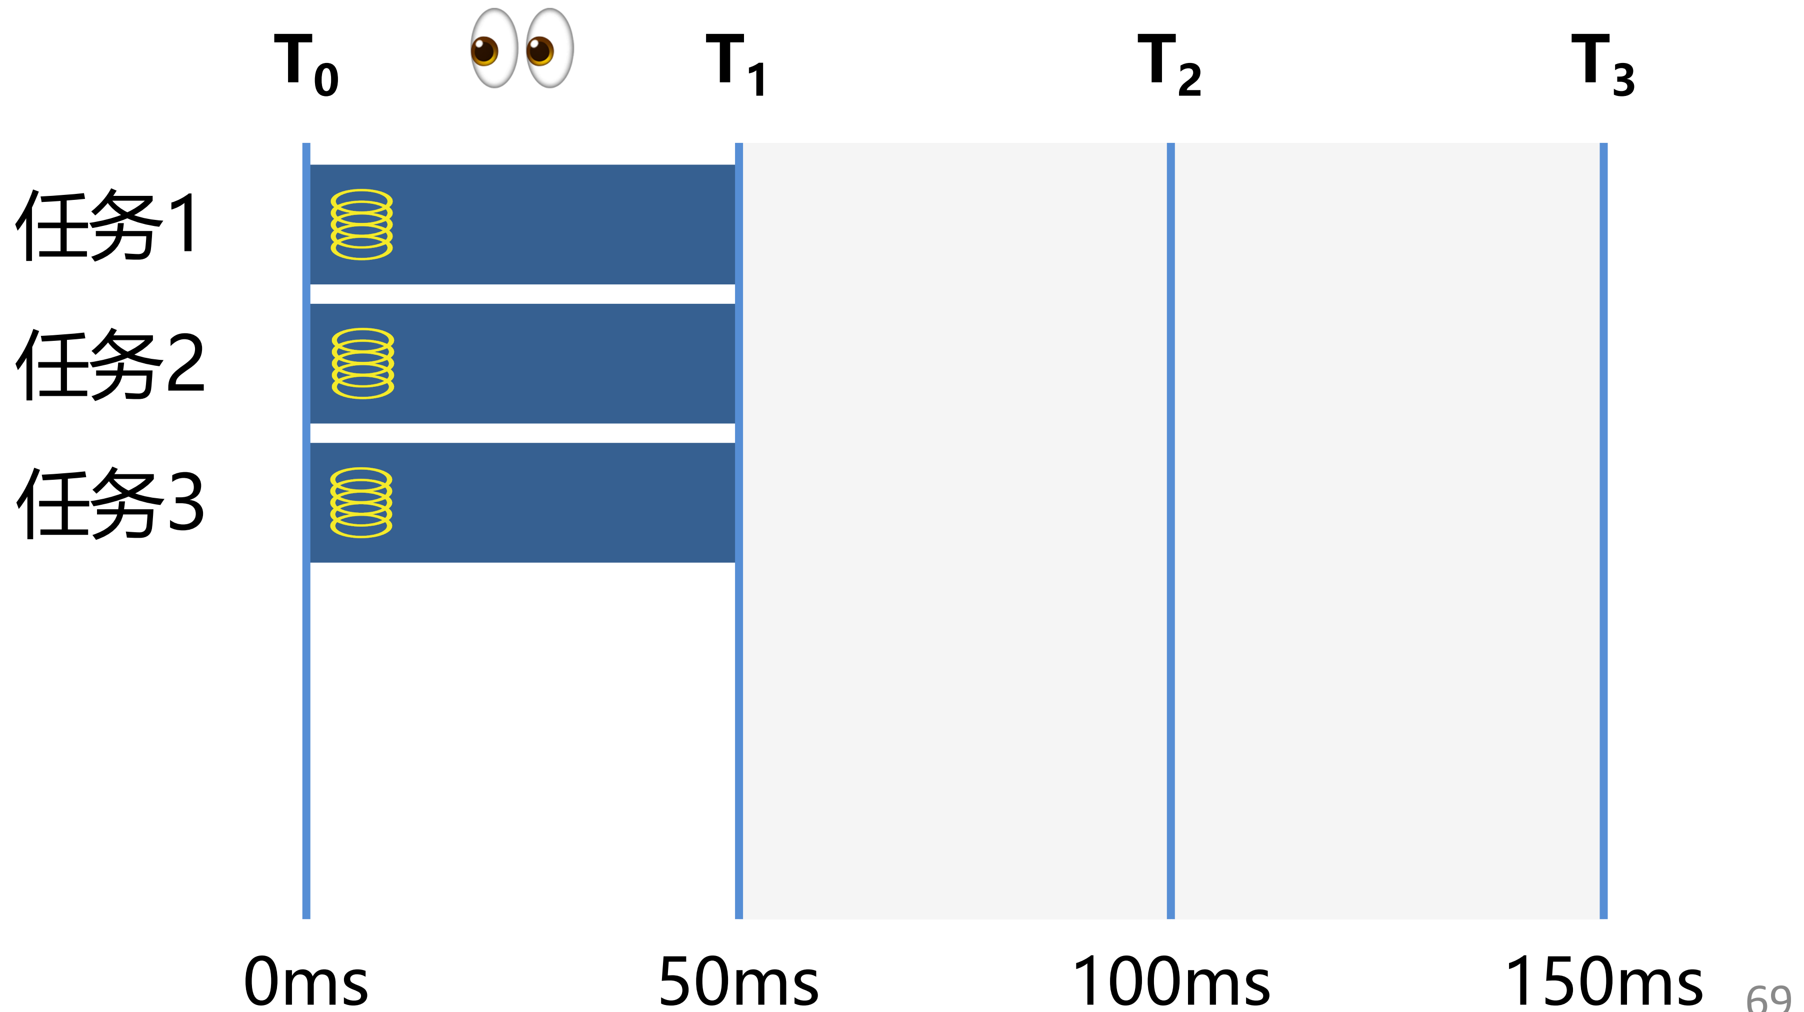

改善长尾问题

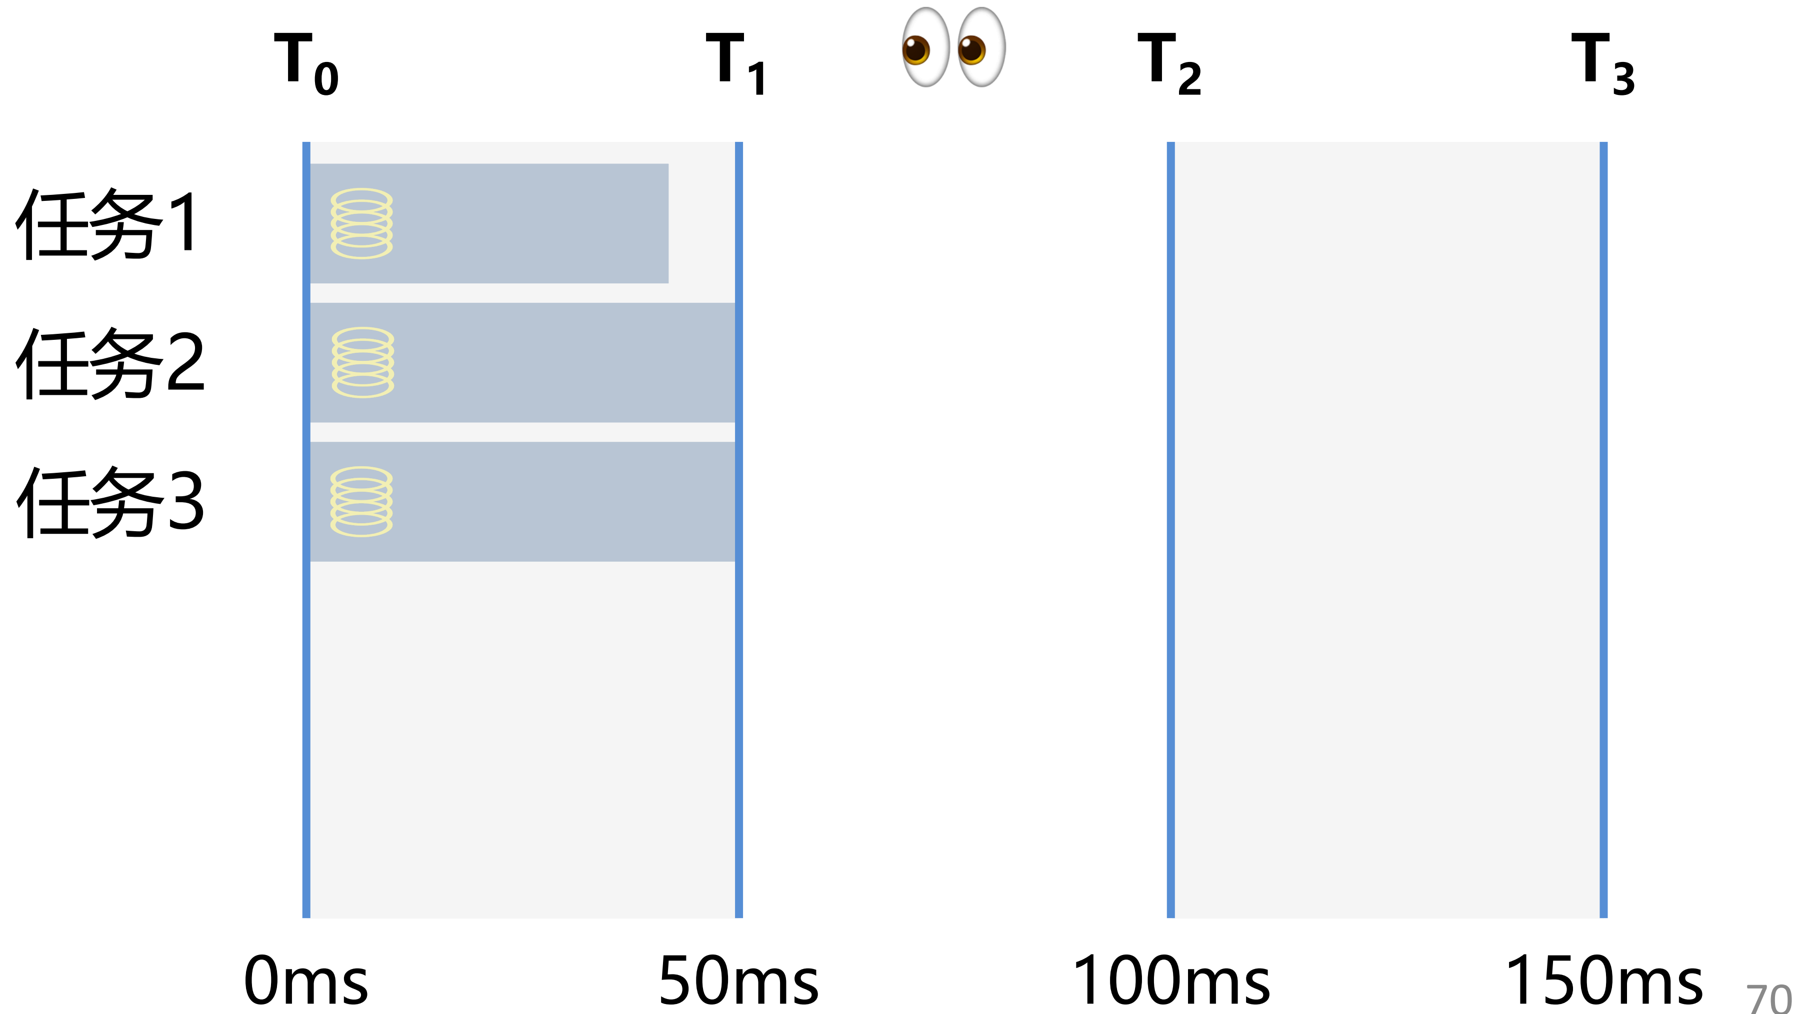

改善长尾问题

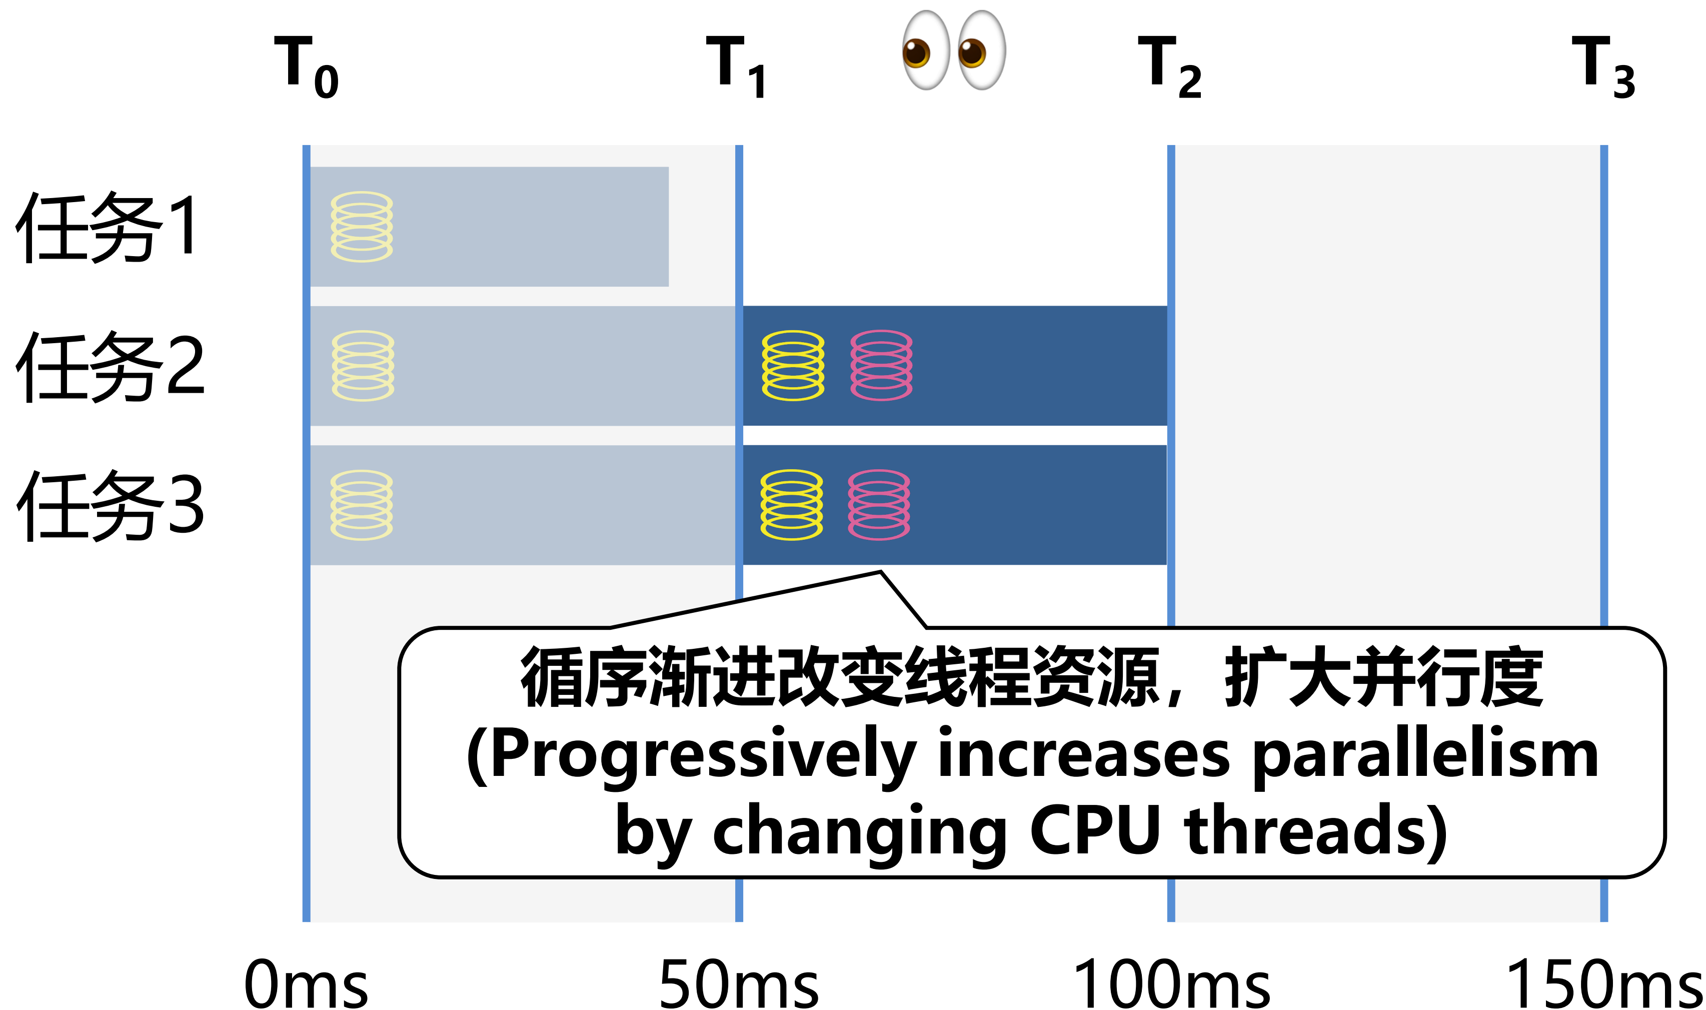

改善长尾问题

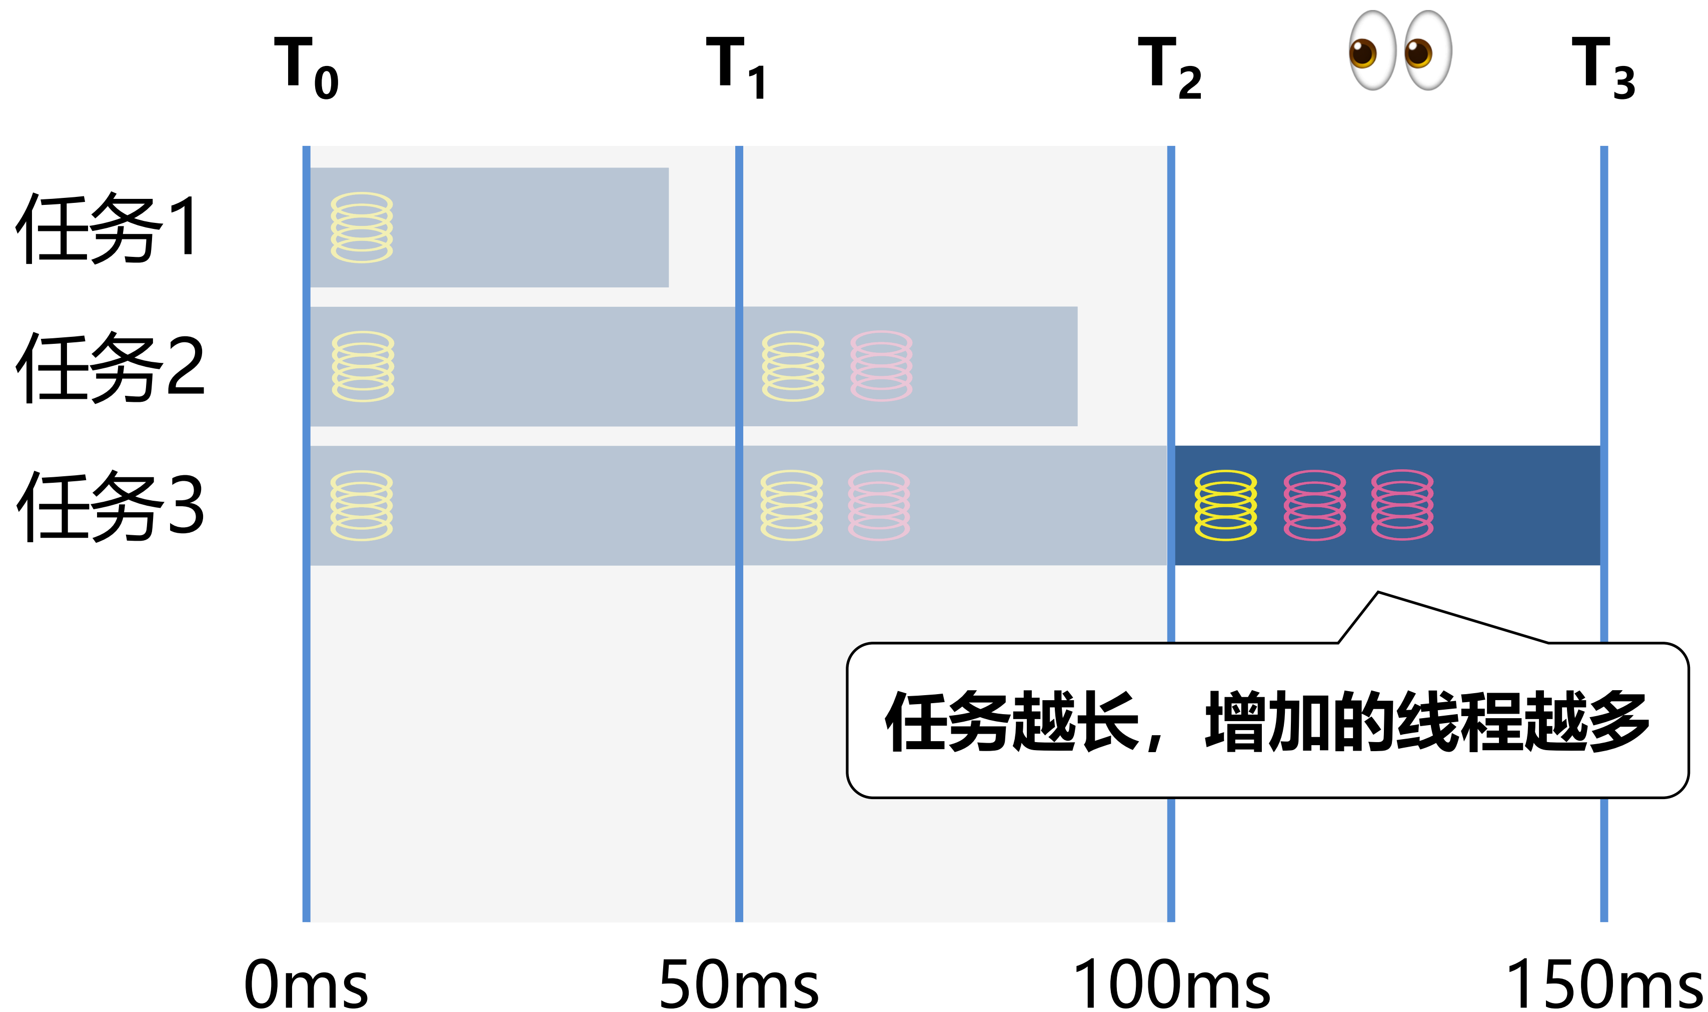

改善长尾问题

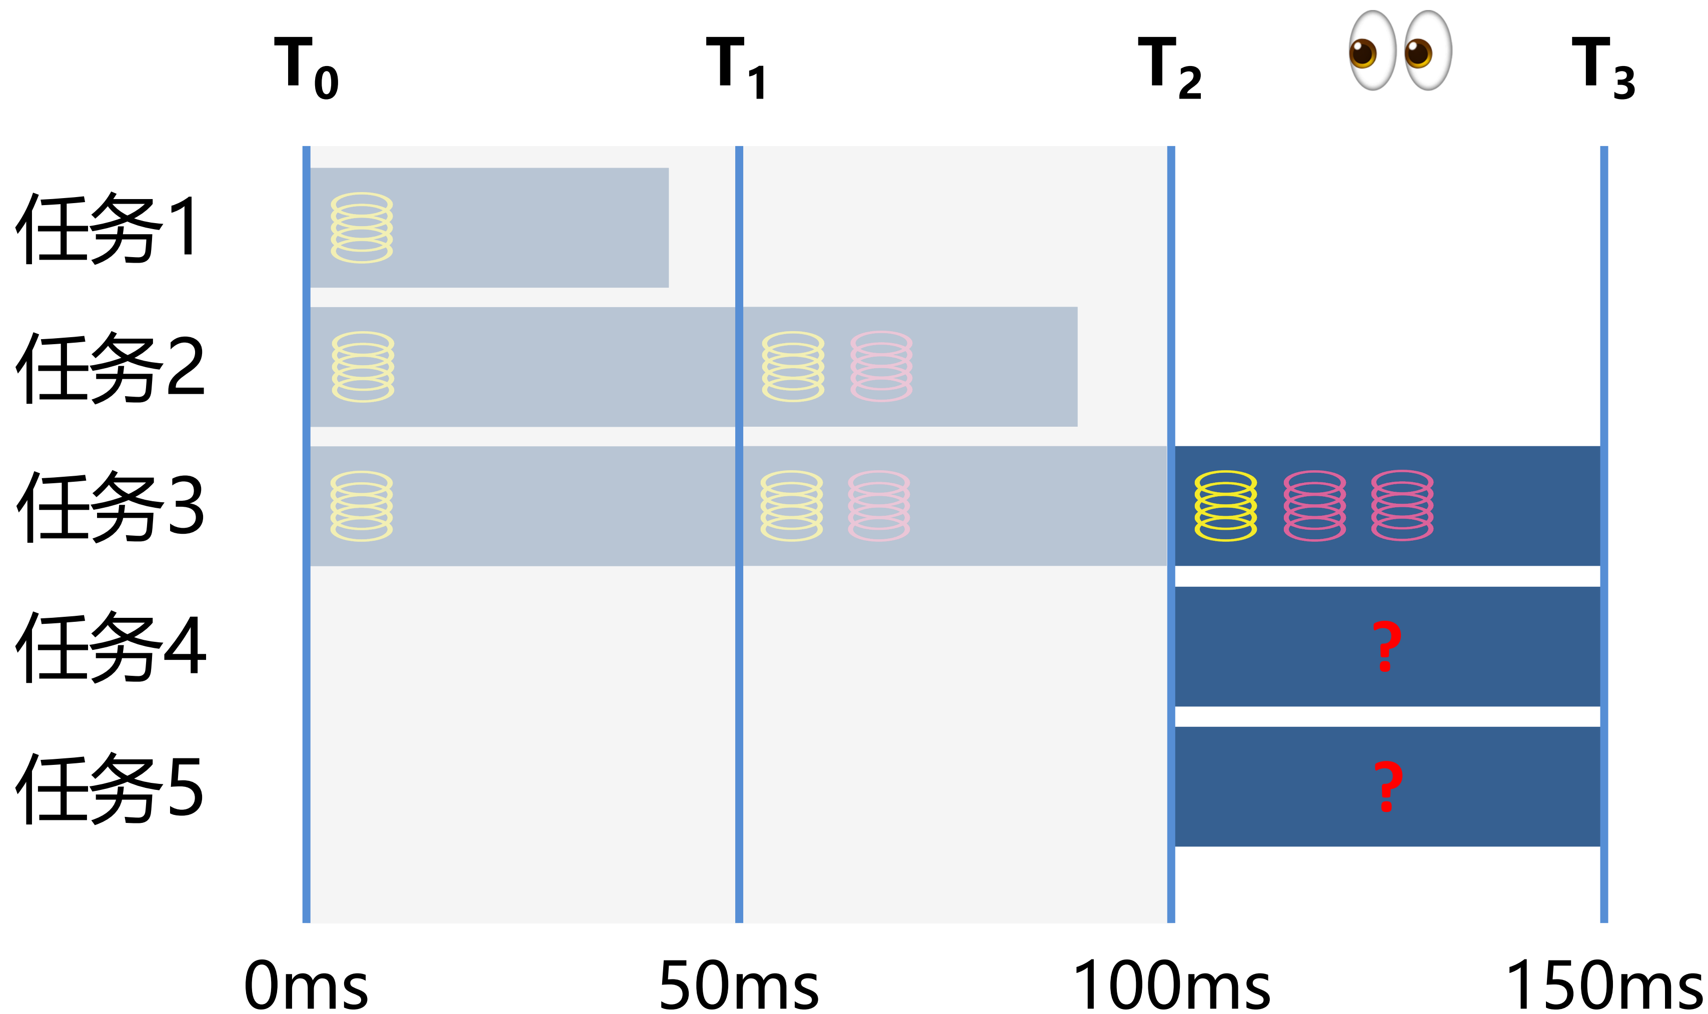

改善长尾问题

□Few-to-Many (FM) 渐增式调度算法最简单版本

Simply increase parallelism periodically, e.g., add one thread to each request after a fixed time interval.

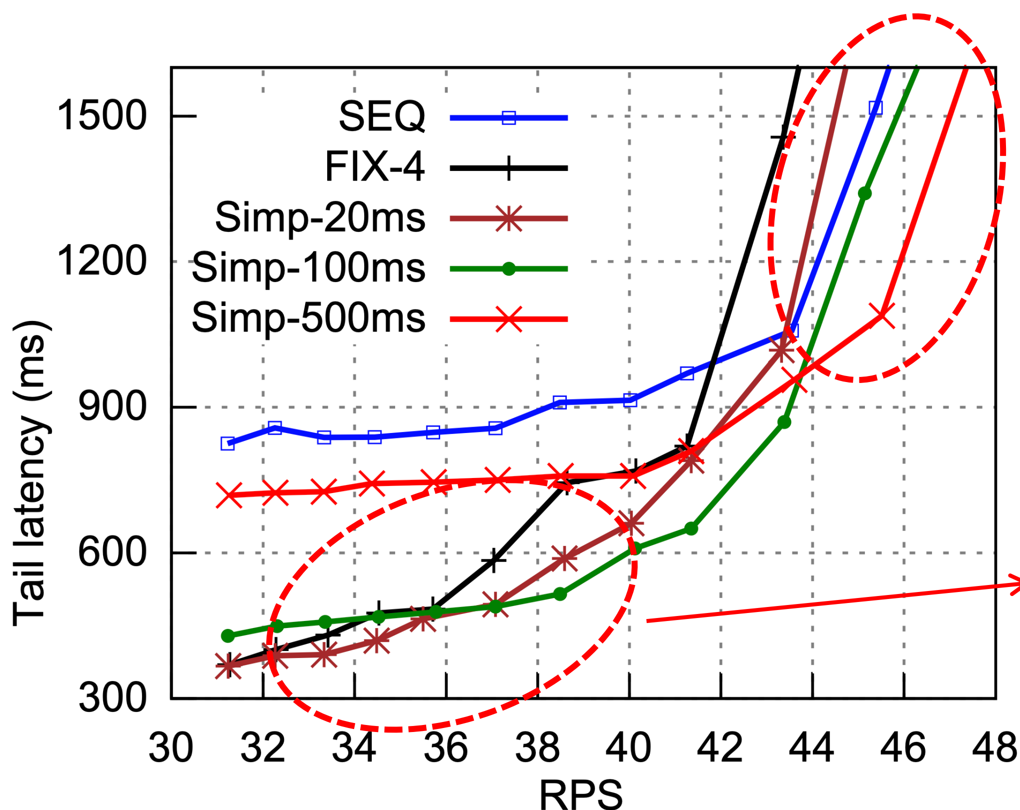

- **Simp-Xms** 从1个worker thread开始，每隔 X ms 增加1个 worker thread

问题：难以选择合适的 interval，不同 interval 在不同 RPS 下有不一样的表现

改善长尾问题

Few-to-Many (FM) 渐增式调度算法实现

Offline阶段	基于历史数据构建 Interval Table
Online阶段	通过查询 Interval Table 实时调整并发度

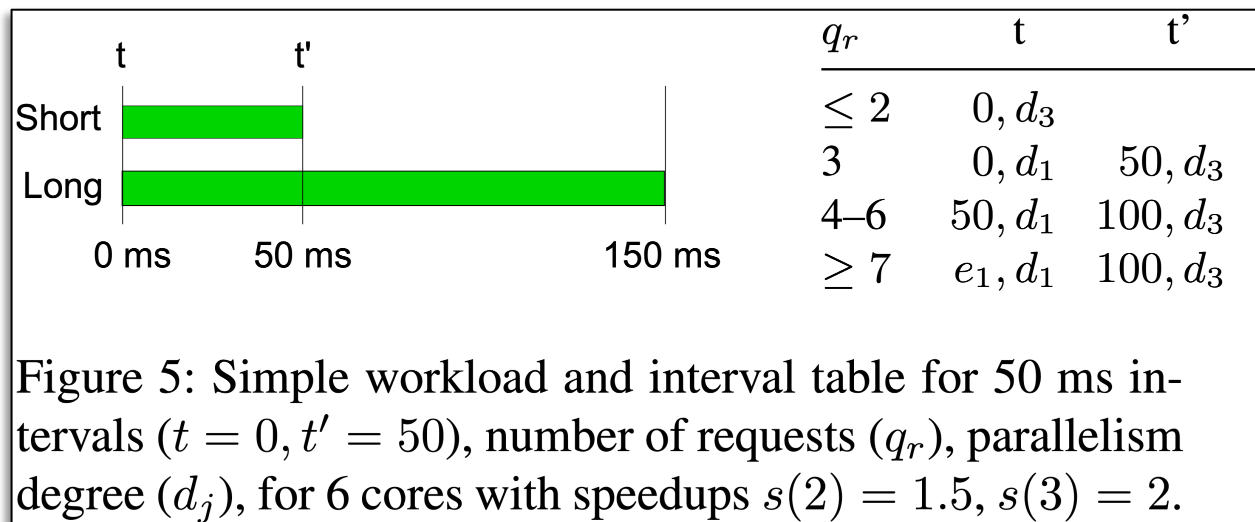

q_r	t	t'
≤ 2	$0, d_3$	
3	$0, d_1$	$50, d_3$
4–6	$50, d_1$	$100, d_3$
≥ 7	e_1, d_1	$100, d_3$

Figure 5: Simple workload and interval table for 50 ms intervals ($t = 0, t' = 50$), number of requests (q_r), parallelism degree (d_j), for 6 cores with speedups $s(2) = 1.5$, $s(3) = 2$.

改善长尾问题

Few-to-Many (FM) 渐增式调度算法实现

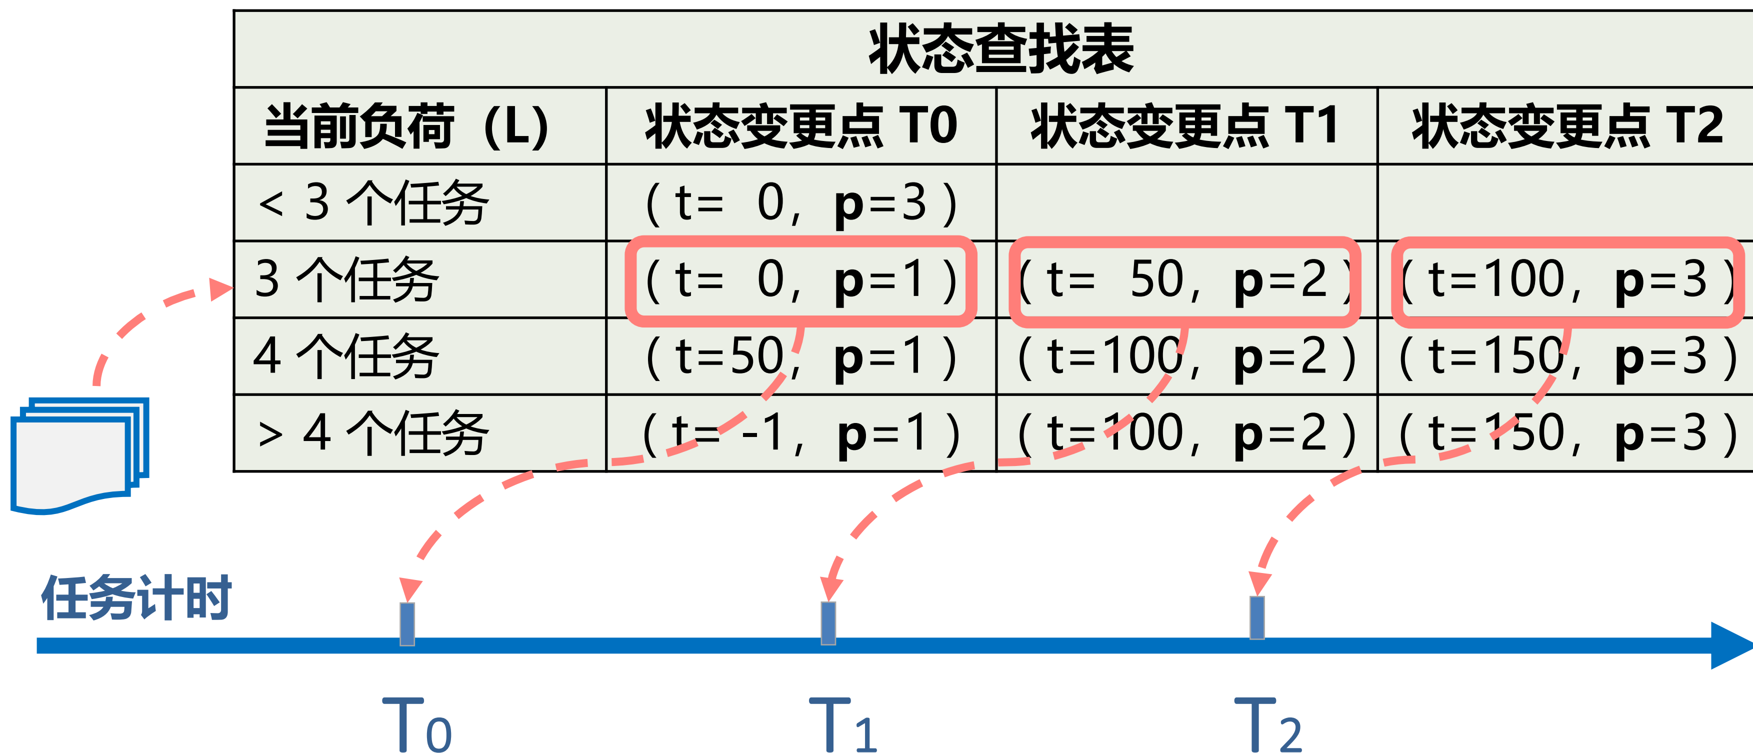

状态查找表			
当前负荷（L）	状态变更点 T0	状态变更点 T1	状态变更点 T2
< 3 个任务	(t= 0，**p**=3)		
3 个任务	(t= 0，**p**=1)	(t= 50，**p**=2)	(t=100，**p**=3)
4 个任务	(t=50，**p**=1)	(t=100，**p**=2)	(t=150，**p**=3)
> 4 个任务	(t= -1，**p**=1)	(t=100，**p**=2)	(t=150，**p**=3)

FM: 将计算资源优先给予低负载、长任务的情况

Few-to-Many: Incremental Parallelism for Reducing Tail Latency in Interactive Services, ASPLOS 2015

Q: Few-to-Many 调度模拟

已知条件:
4 个 CPU 线程 | 3 个任务同时到达 | 检查点 T1=50ms, T2=100ms
任务时长（调度器未知）：A=30ms, B=90ms, C=180ms

策略一：固定均分（每任务 ≈ 1.33 线程）

A ≈ ______________ ms, B ≈ ______________ ms, C ≈ ________________ ms

最慢任务完成时间 = _____ ms

策略二：Few-to-Many（检查点动态调度）

T=0：3 任务各分 ___ 线程（余 ___ 线程空闲）

T1=50ms：A 已完成（30ms < 50ms），空闲 ___ 线程 → 分配给 ___

T2=100ms：B 状态? ___________ C 状态? ___________

C 最终完成时间 ≈ ___ ms

问题： FM 的优势体现在哪里? __________________________________

Q: 校园搜索引擎 ①/②

背景：校园搜索引擎

- 500GB 索引分布在 50 台服务器上
- 目标：P99 响应时间 < 200ms
- 单台服务器 P99 响应时间 = 150ms
- 单台服务器超时概率（>200ms） = 2%

问题 1：计算整体超时概率

每次查询需要所有 50 台服务器都在 200ms 内响应。

整体超时概率 $= 1 - (1 - 0.02)^{50} =$ ____________

这意味着大约每 ___ 次查询就有 ___ 次超时

可以接受吗? ____

思考：单节点 2% 的超时看起来不高，但 50 台汇聚后呢?

Q: 校园搜索引擎 ②/②

问题 2：选择优化策略（可多选）

为降低整体尾时延，以下哪些策略有效？打 ✓：

- □ **A.** 推测执行 — 对慢节点启动备份任务
- □ **B.** 数据分片 — 减少每台服务器的数据量
- □ **C.** 设置超时 — 超时后直接返回部分结果
- □ **D.** 副本冗余 — 同时向多个副本发请求，取最快的
- □ **E.** 增加 CPU 核心 — 提升单台处理能力

问题 3：MapReduce 适用性 + 架构思考

这个系统适合用 MapReduce 吗？为什么？

适合 / 不适合： ________

理由： ____

⭐ **Bonus：** 画一张整体架构图（方框 + 箭头即可）

（提示：用户请求如何分发？索引如何分布？慢节点如何处理？）

改善长尾问题

其他典型调度算法

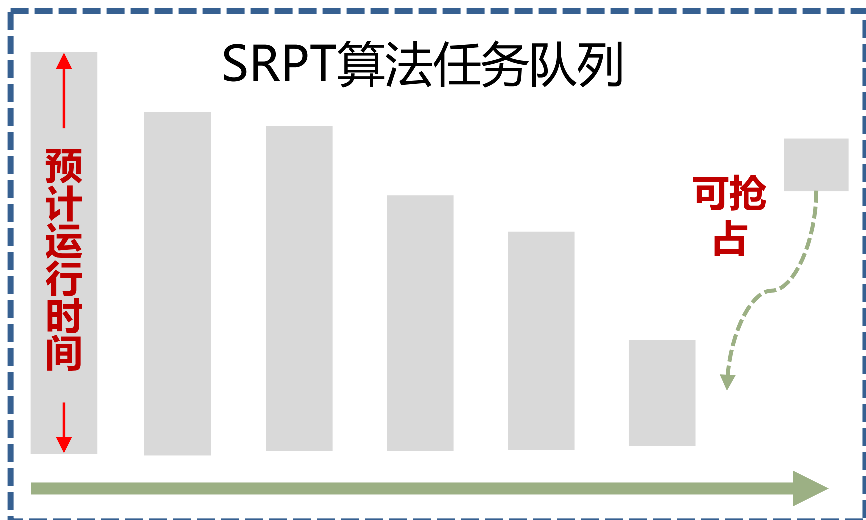

Shortest Remaining Processing Time (SRPT) scheduling policy

SPRT 在平均响应时间方面可达最优

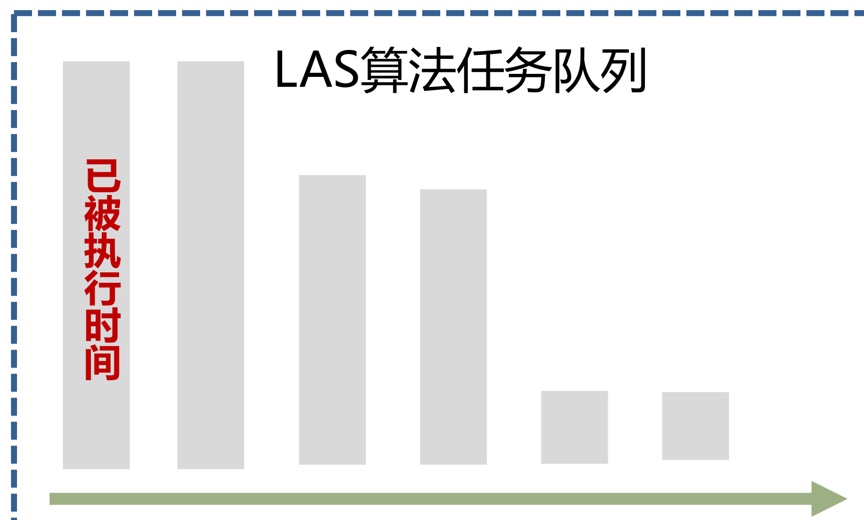

LAS does not rely on a priori estimates of runtime

LAS机制适合长尾分布的任务

SPRT的关键问题是需要对任务的实际运行时间有感知

LAS一个挑战：需要避免任务抢占和恢复引发的性能开销

谢谢

陈壮彬
软件工程学院
chenzhb36@mail.sysu.edu.cn