# CPU 调度

# Outline

- **CPU 调度基本策略**
- Multi-Level Feedback Queue
- Proportional Share
- 多核 CPU 调度

# CPU 调度

- 中断 / 异常：进程切换的方法
- 调度：进程切换的决策
  - 优化目标 1：更小的 turnaround time （周转时间），任务从到达到整体完成的延迟

$$T_{turnaround} = T_{completion} - T_{arrival}$$

  - 多任务：尽可能小的平均 turnaround time

# First In, First Out (FIFO)

- First Come, First Served (FCFS)
- 例如 A, B, C 几乎同时到达， $T_{arrival} = 0$
- 平均 turnaround time = (10+20+30)/3=20
- 优点：简单

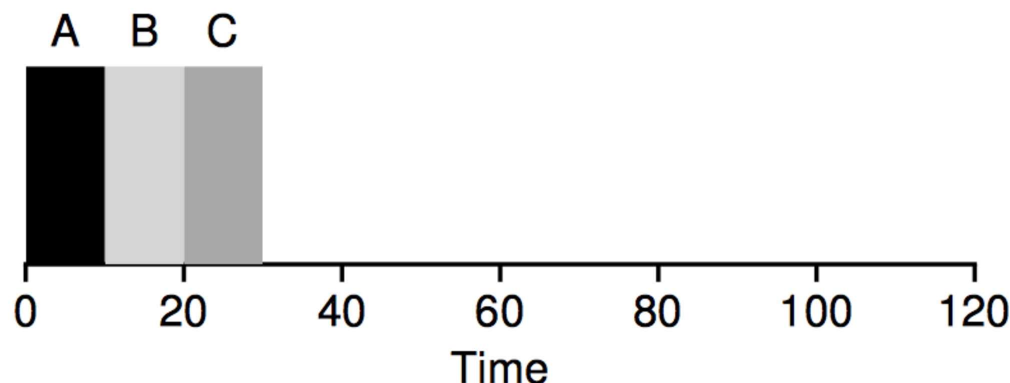

# First In, First Out (FIFO)

- 缺点
  - 当任务长度差距较大时，如下图
  - 平均 turnaround time = (100+110+120)/3 = 110

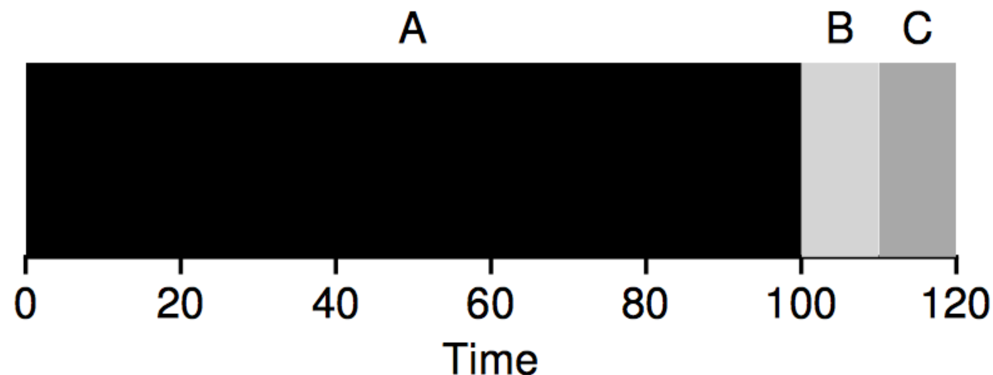

# Shortest Job First (SJF)

- 有助于减小平均 turnaround time，例如上面的情况
- 平均 turnaround time = (10+20+120)/3 = 50

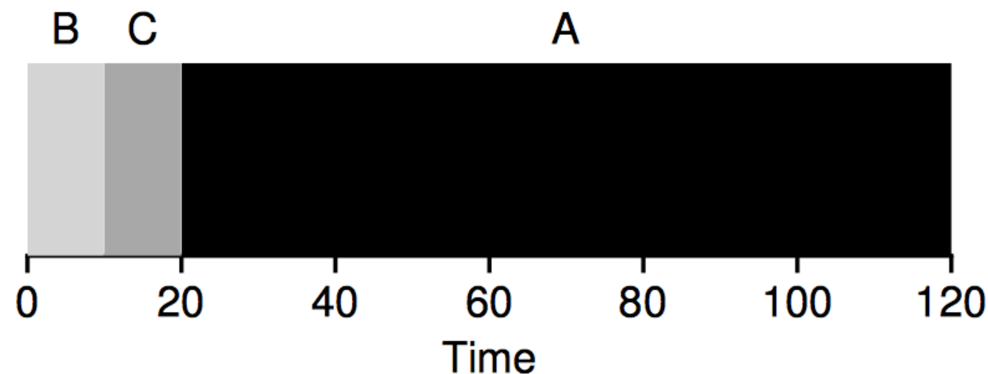

# Shortest Job First (SJF)

- 对于任务同时到到， SJF 是最优调度算法了
- 但如果长任务 A 先到达，则 SJF 没有办法
  - 例如 A 在 0 时刻到达， B 和 C 在 10 时刻到达
  - 平均 Turnaround time = (100+100+110)/3 = 103.3

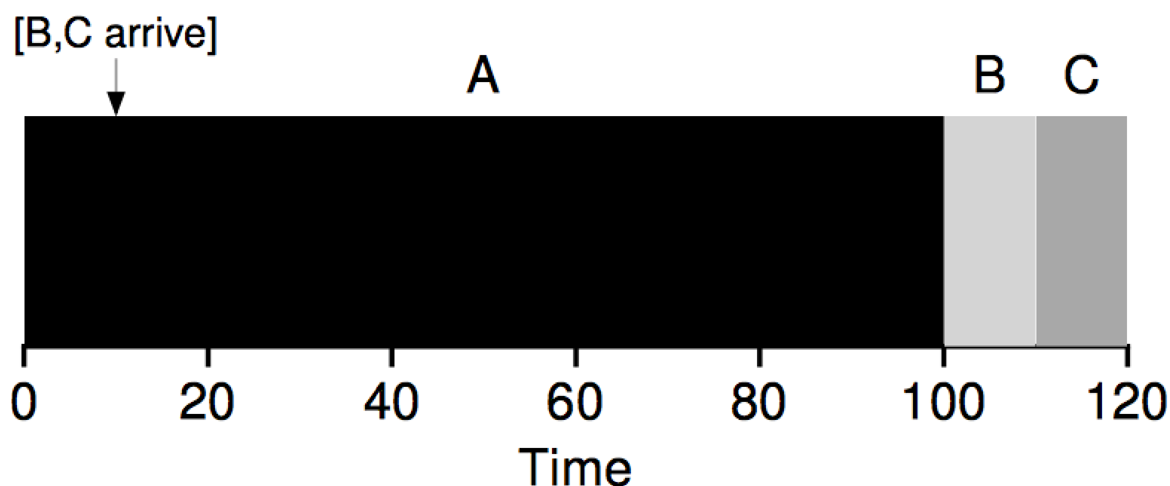

# Shortest Time-to-Completion First (STCF)

- 上述问题改进方法：
  - 不要把一个任务执行到底才切换
  - 允许任务抢占（时间片 / 中断作为切换点）
- STCF
  - 在 SJF 上增加抢占功能，剩余时间最短的任务优先
  - **Preemptive Shortest Job First**（**PSJF**）
  - 平均 turnaround time = (120+10+20)/3 = 50

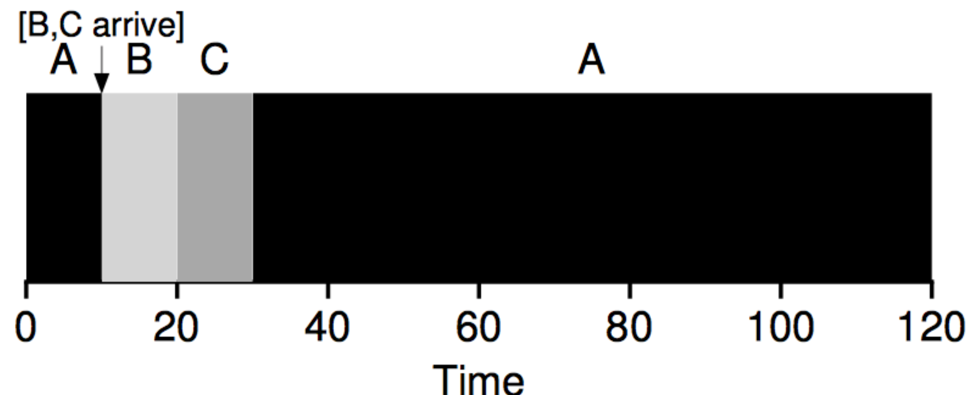

# 平均 Turnaround Time 的问题

- 平均 Turnaround Time 反映整体性能
  - 但有些 Job 被平均（自己牺牲，换来整体平均更好，例如长任务）
- 不能做到公平（ Fairness ）
  - 用户感受可能不好
  - 极端情况出现“饥饿问题”（ job 不断到达，某些 Job 一直不被调度）
- 如果所有 job 属于一个用户，还可以接受
  - 如果 jobs 属于不同用户（尤其是付费用户），则无法接受牺牲
  - 云计算下的公平性问题
  - 效率和公平往往不能兼得

# CPU 调度

- **优化目标 2： Response time**
  - 任务的第一次被调度时间与到达时间之差

$$T_{response} = T_{firstrun} - T_{arrival}$$

  - 之前的调度算法（如 SJF ）会导致 response time 很差（ B 和 C ）

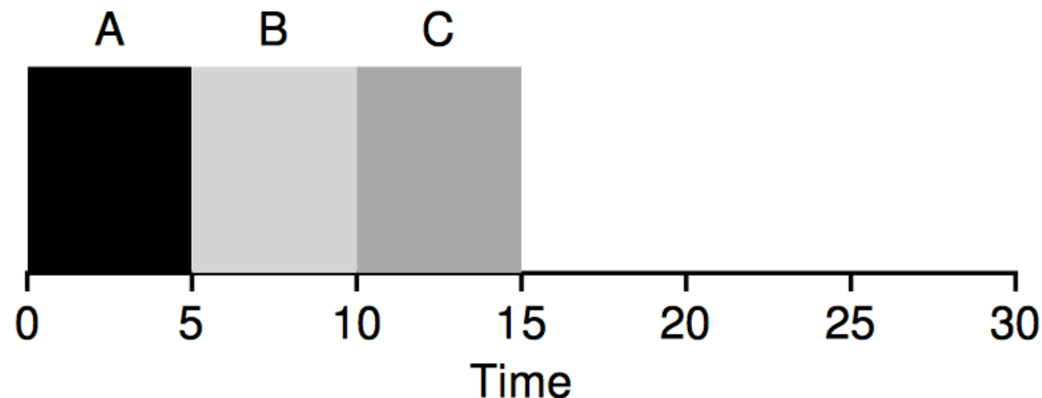

# Round Robin

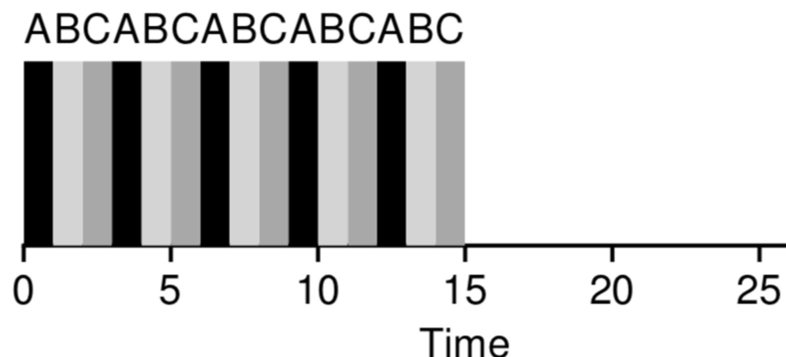


- 基于时间片，轮流执行任务
- response time 小
- 增加 context switch 的开销
  - 增大时间片能减小开销的比例，但也会增大 response time
  - 所以需要在二者之间 tradeoff
    - 偏重公平 (response time)： RR
    - 不看重公平 (turnaround time)： SJF, STCF

➢ Systems 领域多数情况都是在 tradeoff，因为实际情况因素很多，某方面最优一般都伴随其他方面的副作用

# 考虑 I/O

- I/O 操作远比 CPU 周期要慢
- 进程执行 I/O 操作时，要 block 住，直到 I/O 完成
- STCF 的问题
  - A 和 B 都是 50ms 的任务
  - 每次 interrupt， A 剩余的时间小于 B，那么会优先调度 A，浪费 CPU 时间

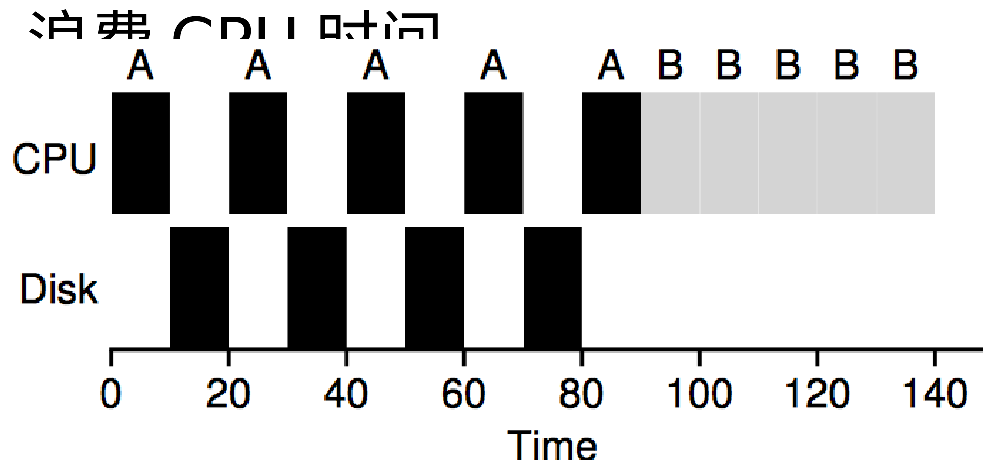

# 考虑 I/O

- 解决方案
  - 把 A 看做 5 个 10ms 的子任务
  - 每次 A 开始 I/O 时，调度器只剩 B 一个选项，调度 B
  - 当 I/O 完成时（ interrupt ）， A 的剩余时间段，调度 A
  - （或者增加调度条件，有 I/O 阻塞不能调度）

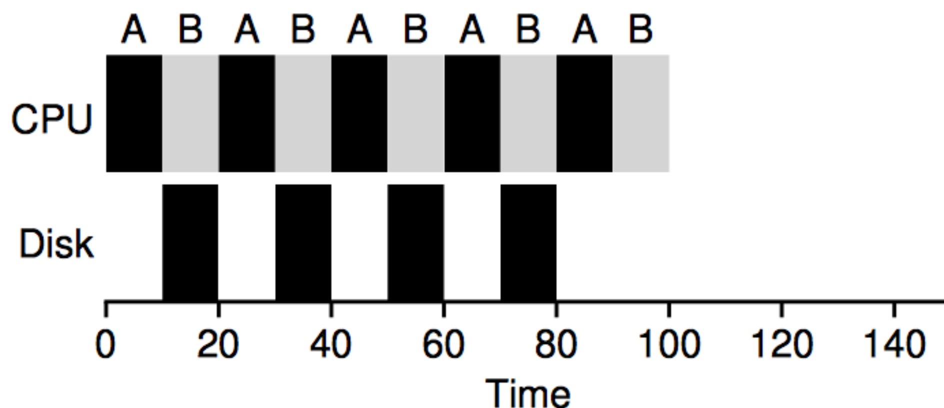

# 课堂练习 1

- 有 5 个待运行作业，估计它们的运行时间分别是 9、 6、 3、 5、 X。以何种顺序运行这些作业能够得到最短的平均响应时间（答案将依赖于 X）。

# 练习 1 答案

- 其他四个作业的顺序应该是从短到长：
- 3 、 5 、 6 、 9
- 那么 X 可能处于 5 种位置

# 课堂练习 2

例 1：假定要在一台处理器上执行如下图所示的作业，它们在 0 时刻以 1，2，3，4，5 的顺序到达。给出采用下列调度算法时的调度顺序、平均周转时间(turnaround time)和平均响应时间(response time)

（1）FCFS

（2）RR(时间片为 1，不考虑优先级)

（3）非抢占式 SJF(shortest job first)

| 作业 | 执行时间 | 优先级 |
|---|---|---|
| 1 | 10 | 3 |
| 2 | 1 | 1 |
| 3 | 2 | 2 |
| 4 | 3 | 4 |
| 5 | 5 | 2 |

# 练习 2 答案

（1）FCFS: （2 分）

| P1 | P2 | P3 | P4 | P5 |
|---|---|---|---|---|

0 10 11 13 16 21

平均响应时间＝（0＋10＋11＋13＋16）/ 5 = 10

平均周转时间＝（10＋11＋13＋16＋21）/ 5 = 14.2

（2） RR(TQ=1)

| P1 | P2 | P3 | P4 | P5 | P1 | P3 | P4 | P5 | P1 | P4 | P5 | P1 | P5 | P1 | P5 | P1 | P1 | P1 | P1 | P1 |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|

0 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19
20 21

平均响应时间＝（0＋1＋2＋3＋4）/ 5 = 2

平均周转时间＝（21＋2＋7＋11＋16）/ 5 = 11.4

# 练习 2 答案

（3） SJF

| P2 | P3 | P4 | P5 | P1 |
|---|---|---|---|---|

0　　1　　3　　6　　11　　21

平均响应时间＝（11＋0＋1＋3＋6）/ 5 = 4

平均周转时间＝（21＋1＋3＋6＋11）/ 5 = 8.4

# Outline

- CPU 调度基本策略
- **Multi-Level Feedback Queue**
- Proportional Share
- 多核 CPU 调度

# 以上调度算法的共同问题

- 假设我们知道每个任务的时间，从而短任务优先
- 但实际上我们一般是没法预知的

# Multi-Level Feedback Queue (MLFQ)

- 提出者
  - Corbato， 1962， Compatible Time-Sharing System (CTSS) 的一部分
  - Corbato 后来参与 Multics 操作系统的工作
  - 后来获得 ACM 图灵奖
- MLFQ 目标
  - 不知道任务长度的前提下，尽量短任务优先来减小 turnaround time
  - 减小 response time，但又不像 RR 那样伤害 turnaround time

# Multi-Level Feedback Queue (MLFQ)

- 分为多个优先级队列
- 规则
  - **Rule 1:** If Priority(A) > Priority(B), A runs (B doesn't).
  - **Rule 2:** If Priority(A) = Priority(B), A & B run in RR.

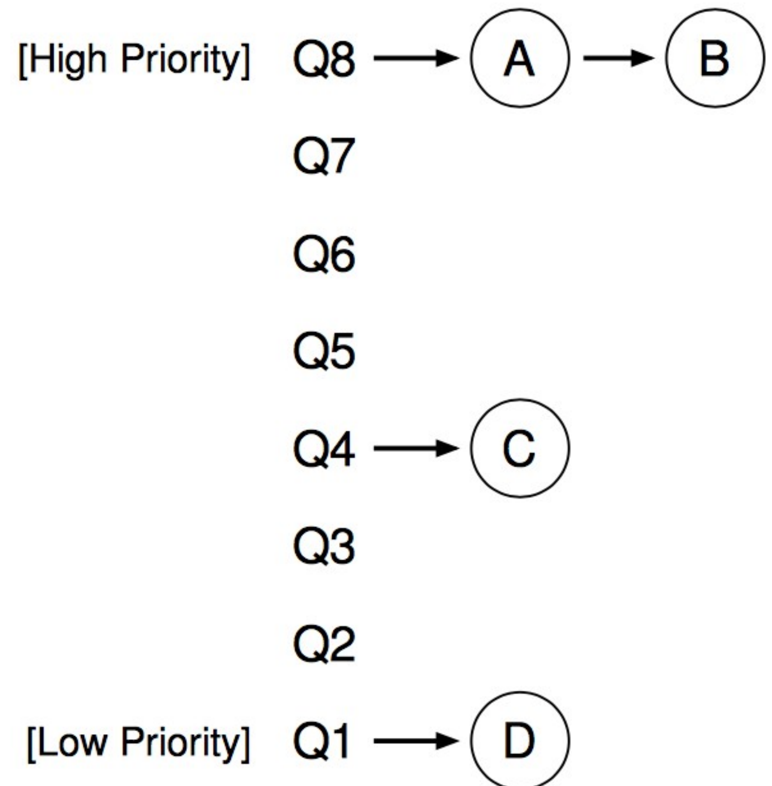

# Multi-Level Feedback Queue (MLFQ)

- **Workload 分析**
  - 一种是 interactive short-running 任务，经常交换，让出 CPU，对 response time 要求高
  - 一种是 longer-running CPU-bound 任务，对 response time 要求不高，但对 turnaround time 要求高

- System 优秀论文经常这样，抓住主要矛盾（通过 workload 分析等方式），针对性设计（传统方法一般不这样）
  - 例如上述分类中，两类 job 并不都是 turnaround time 和 response time 都需要，而是每类偏重一个方面，这样就容易优化了

# Multi-Level Feedback Queue (MLFQ)

- Attempt #1: How To Change Priority
  - **Rule 3:** When a job enters the system, it is placed at the highest priority (the topmost queue).
  - **Rule 4a:** If a job uses up an entire time slice while running, its priority is *reduced* (i.e., it moves down one queue). 【针对 CPU-bound 任务】
  - **Rule 4b:** If a job gives up the CPU before the time slice is up, it stays at the *same* priority level. 【针对 interactive 任务】

# Multi-Level Feedback Queue (MLFQ)

- 例 1．长任务

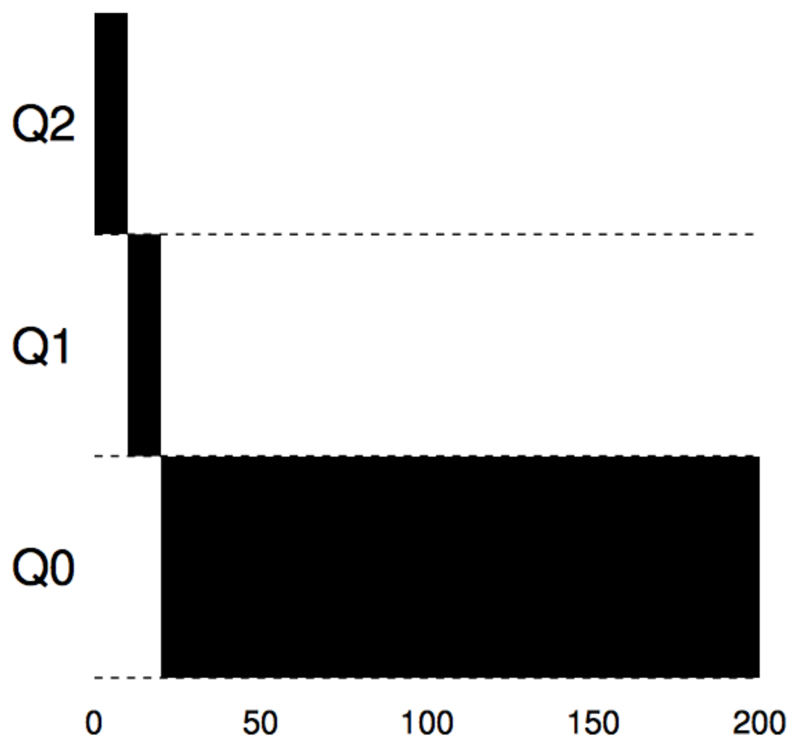


**短任务优先极高，同时有利于周转时间和响应时间**

- **例 2．又来了交互式任务**

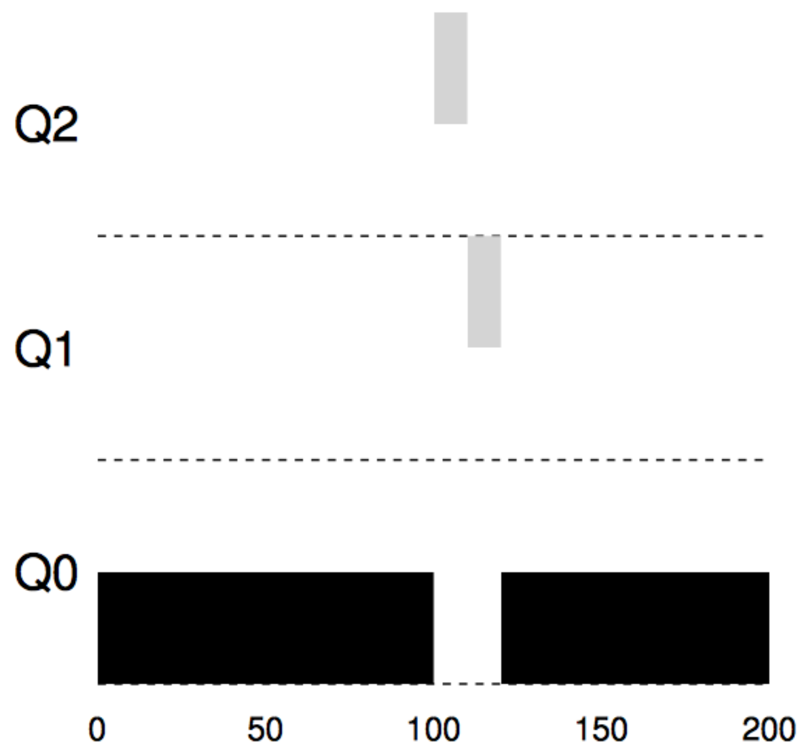


**效果上近似于 SJF ，有利于周转时间**
**同时交互式任务的响应时间很短**

# Multi-Level Feedback Queue (MLFQ)

- I/O 密集型的任务
  - 按照 Rule 4b，由于 I/O 阻塞，会提前释放 CPU ，所以一直留在高优先级

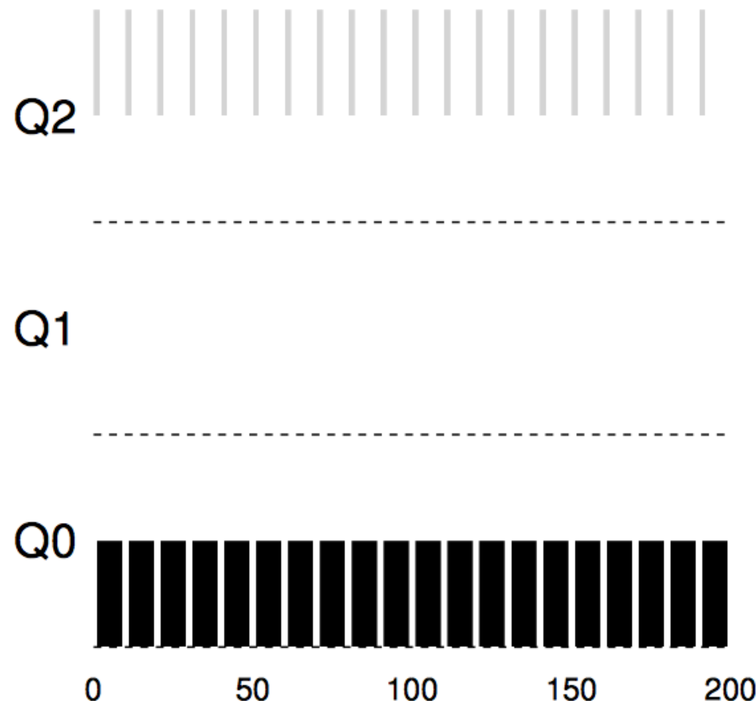

# Multi-Level Feedback Queue (MLFQ)

- MLFQ 问题总结
  - 1. CPU-bound 型任务的饥饿问题
    - 如果交互式任务数量较多，它们会交替使用 CPU
    - 低优先级的 CPU-bound 型任务可能饥饿（调度算法一定要避免的灾难）
    - * 系统工作，首先要考虑避免灾难，然后才是优化性能

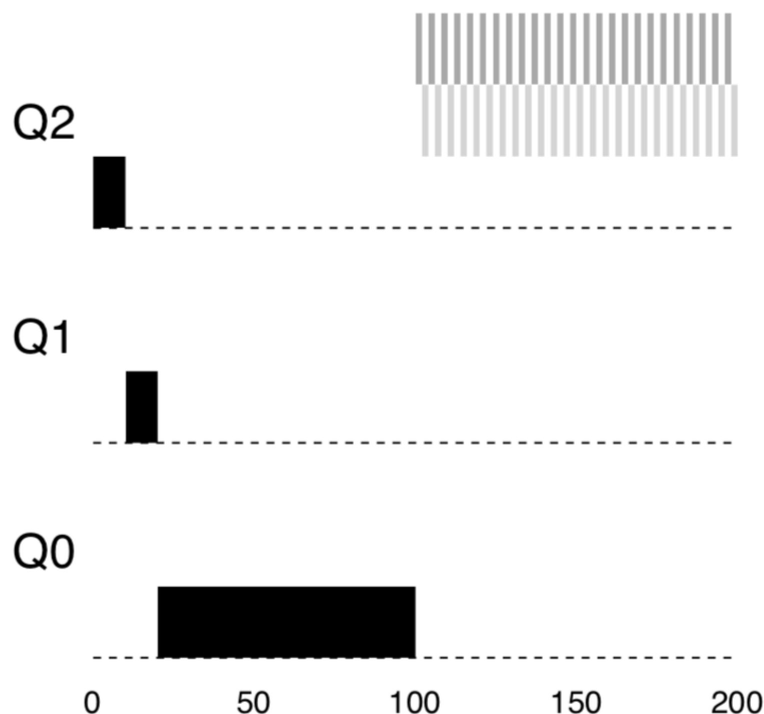

# Multi-Level Feedback Queue (MLFQ)

- MLFQ 问题总结
  - 1. 饥饿问题
  - 2. 用户会针对性修改程序，在时间片结束前进行一次没有意义的 I/O （访问一个不需要的文件），这样可以一直停留在最高优先级
    - Client 和 Server 之间的欺诈、对抗
  - 3. 程序 workload 改变模式（计算 -> 交互），没有机会上升优先级

# Multi-Level Feedback Queue (MLFQ)

- Attempt #2: The Priority Boost
  - **Rule 5:** After some time period *S*, move all the jobs in the system to the topmost queue.
  - 解决了两个问题
    - 饥饿
    - Workload 模式改变（重新做人的机会）

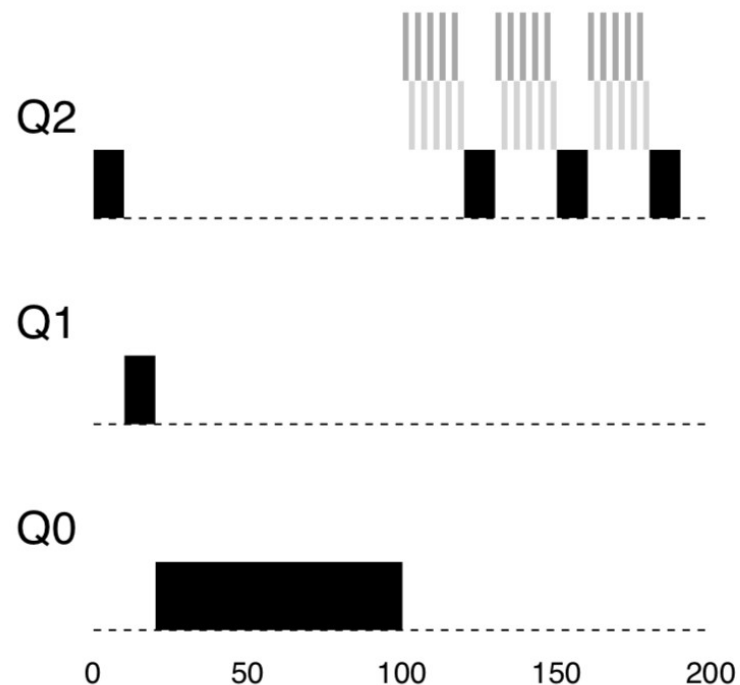

# Multi-Level Feedback Queue (MLFQ)

- Attempt #2: The Priority Boost
  - Rule 5 中的 time period *S* 应该如何设置?
    - 如果过大，没有起到效果，长任务还是可能饥饿;
    - 如果过小，交互式任务所占比重可能太少
    - 需要 black magic 才能做到（与系统中两类任务的比例动态相关）
  - 这类问题在 Systems 领域叫做 voo-doo constants
    - 西非的伏都教，信奉巫术
    - Ousterhout’s Law: 在设计算法时尽量避免引入 voo-doo constants
      - John Ousterhout， 1988 年和 Fred Douglis 提出第一个日志文件系统
    - 这也是为什么简单的方法在系统中容易被利用的原因之一（如 LRU ）

# Multi-Level Feedback Queue (MLFQ)

- Attempt #2: The Priority Boost
  - 仍然没有解决问题 2 （用户欺诈，伪装自己，在让出时间片前做一次无意义的 I/O ，以停留在高优先级）

**Job A ，欺诈，占用 99% 的 CPU**

Q1

Q0

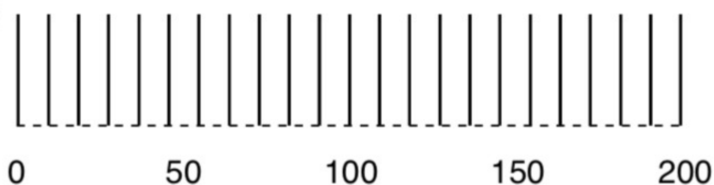


**Job B ，老实，占用 1% 的 CPU**

# Multi-Level Feedback Queue (MLFQ)

- Attempt #3: Better Accounting
  - **Rule 4:** Once a job uses up its time allotment at a given level (regardless of how many times it has given up the CPU), its priority is reduced (i.e., it moves down one queue).
    - 占用 CPU 总数达到一定量，就下降一个优先级
    - 交互式 Job 占用 CPU 少，所以应该优先极高，能够达到设计目标
    - 比提前让出时间片更合理，不容易被骗

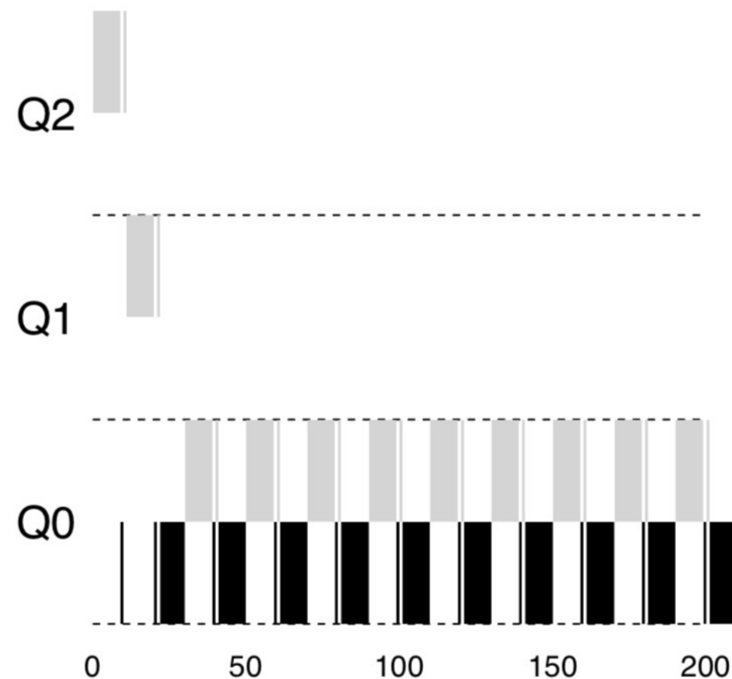

# Multi-Level Feedback Queue (MLFQ)

- MLFQ 参数调优
  - Queue 数量、每个 Q 的 time slice 大小、所有任务回到最高级的周期
  - 例如，上级的 Q 用小的 time slice，下级的 Q 用大的 time slice
    - Interactive job: 减小 response time
    - CPU-bound job: 减小 context switch 的开销

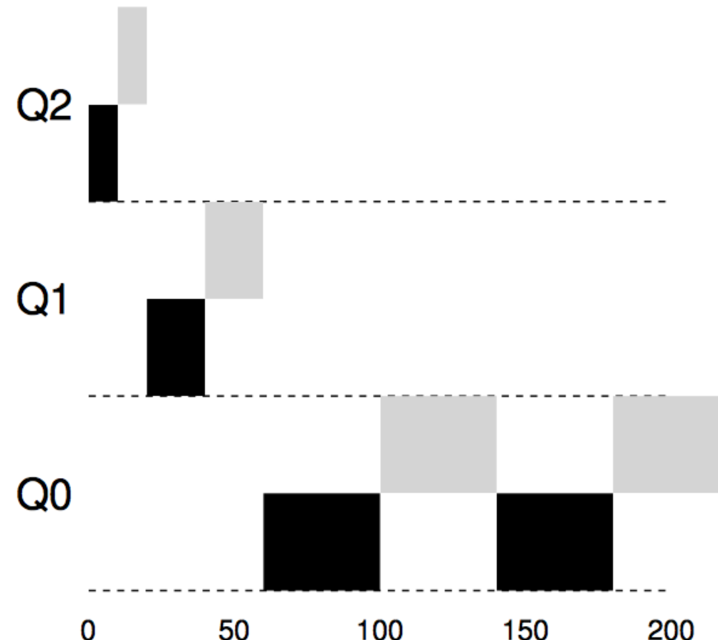

# Multi-Level Feedback Queue (MLFQ)

- MLFQ 参数调优
  - Solaris MLFQ 实现— Time-Sharing scheduling class (TS)
    - 一系列参数可以调整
    - 例如队列数量默认是 60 个
    - 时间片从 20ms 到几百 ms，甚至 1s
  - FreeBSD scheduler 采用公式计算任务的优先极

# Multi-Level Feedback Queue (MLFQ)

- **MLFQ Summary:**
  - **Rule 1:** If Priority(A) > Priority(B), A runs (B doesn't).
  - **Rule 2:** If Priority(A) = Priority(B), A & B run in RR.
  - **Rule 3:** When a job enters the system, it is placed at the highest priority (the topmost queue).
  - **Rule 4:** Once a job uses up its time allotment at a given level (regardless of how many times it has given up the CPU), its priority is reduced (i.e., it moves down one queue).
  - **Rule 5:** After some time period S, move all the

# 复杂系统设计

- Not pursuing the best,
- But avoiding disaster

# Outline

- CPU 调度基本策略
- Multi-Level Feedback Queue
- **Proportional Share**
- 多核 CPU 调度

# Proportional Share

- Proportional share scheduler
- 也叫 Fair-share scheduler
- 不追求优化 turnaround time 或 response time，而是保障每个任务得到一定比例的 CPU 时间

- 一个典型算法是 lottery scheduling (Waldspurger and Weihl, 1994)

# Lottery Scheduling

- 每个任务持有一定的 tickets，生成随机数，落在哪个任务的范围内，就调度哪个任务
- Tickets 比例决定优先级
  - 例如 A 有 75 个 ticket， B 有 25 个 ticket

Here is an example output of a lottery scheduler's winning tickets:

```
63 85 70 39 76 17 29 41 36 39 10 99 68 83 63 62 43  0 49 49
```

Here is the resulting schedule:

```
A  B  A  A  B  A  A  A  A  A  A  B  A  B  A  A  A  A  A  A
```

# Lottery Scheduling

- 衡量 Fairness– Unfairness 指数 U
  - 任务中第一个完成的时间除以第二个完成时间
  - 例如第一个任务时间 10 完成，第二个 20 完成，那么 U=0.5
  - 对于基本上同时到达的任务，完全公平的情况下，应该 U=1

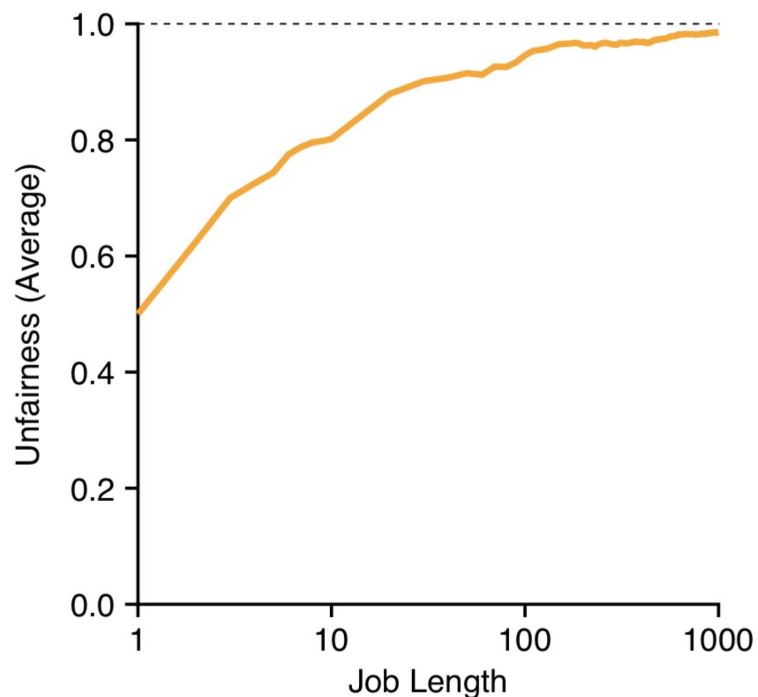


**两个 Job，任务越长，U 越接近于 1**

# Lottery Scheduling

- 为什么不使用确定性的调度方法?
  - 如 stride scheduling (1995)
  - 每个任务调度一次后，走一定步长，每次选择总步长最小的任务调度
  - 例如 A, B, C 的 stride 分别为 100, 200, 40 （权重比例为倒数， 2:1:5）

**结果 A 调度 2 次， B 1 次， C 5 次，与预期一致**

| Pass(A) (stride=100) | Pass(B) (stride=200) | Pass(C) (stride=40) | Who Runs? |
|---|---|---|---|
| 0 | 0 | 0 | A |
| 100 | 0 | 0 | B |
| 100 | 200 | 0 | C |
| 100 | 200 | 40 | C |
| 100 | 200 | 80 | C |
| 100 | 200 | 120 | A |
| 200 | 200 | 120 | C |
| 200 | 200 | 160 | C |
| 200 | 200 | 200 | ... |

# Lottery Scheduling

- 为什么不使用确定性的调度方法?
  - 因为 stride scheduling 需要维护 global state (A, B, C 的当前步长)
  - 如果新引入一个 job，那么这个 job 的起始步长设为多少合适?
  - 而 lottery scheduling 不需要维护 global state，对于每个 job 都通过生成随机数调度

# Lottery Scheduling

- 随机算法的好处
  - 避免一些特殊情况的问题（例如 LRU 在 cyclic-sequential workloads 下命中率低的问题）
  - 简单，轻量级
  - 性能好，快速

  - 深入理解 RANDOM 算法
    - 冷热数据均等几率淘汰
    - 但热数据重新进入概率高很多
    - 看似公平随机，实际更有利于热数据（达到设计目的）

# Outline

- CPU 调度基本策略
- Multi-Level Feedback Queue
- Proportional Share
- **多核 CPU 调度**

# 多核 CPU 调度

- 多核 CPU 的新问题：
  Cache 一致性问题
  - 核 1 、核 2 都 cache 同一份数据
  - 核 1 修改数据
  - 核 2 读数据会不一致
  - 解决：
    - **bus snooping（总线监听），在 bus 监控 cache 行为，做相应处理**
    - **增加性能开销**

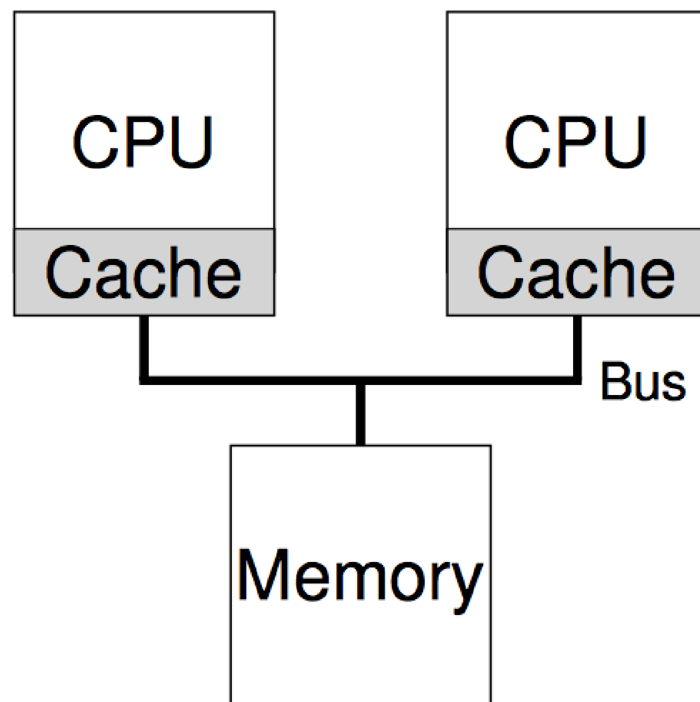

# 多核 CPU 调度

- bus snooping ( 总线监听 )
  - MESI 方案（针对 cacheline ）
    - **M (modified)**: cl 经过修改，是系统唯一正确版本，其他 CPU cache 中该数据失效 (->[I]) ，从这个 cache 读取
    - **E (exclusive)**: cache 中唯一与主存一致的数据，其他 CPU cache 中该数据失效 (->[I]) ，从该 cache/ 主存读取；写操作 [E]->[M]
    - **S (share)**：多个 cache 一致，如果写则 write through ，改为 [E]
    - **I (invalidate)**：失效，当作没有

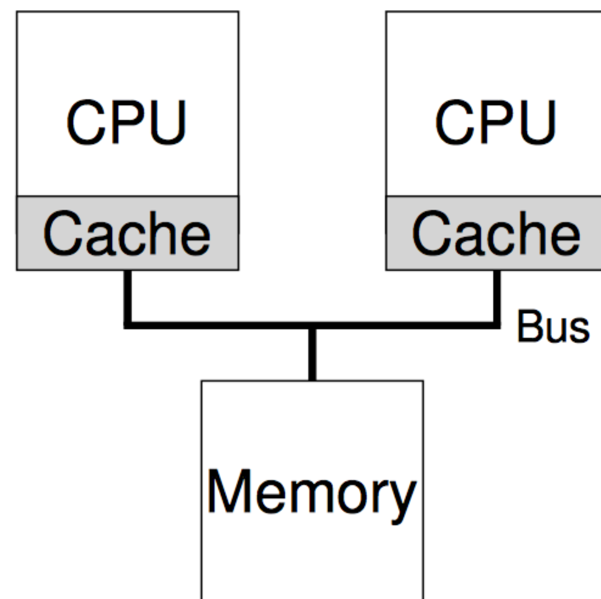

# 多核 CPU 调度

- Cache Affinity（密切关系，亲近）
  - 一个进程连续调度到同一个 CPU 核上， cache 和 TLB 都有效，性能会比较好
  - 如果调度到不同的核上，则 cache 资源浪费

# 多核 CPU 调度

- **Single-Queue Multiprocessor Scheduling** or **SQMS**
  - **一个大队列，哪个核闲置，就调度一个任务**
  - **优点： Load balance**
  - **缺点： LOCK 开销大； cache affinity 差，性能差**

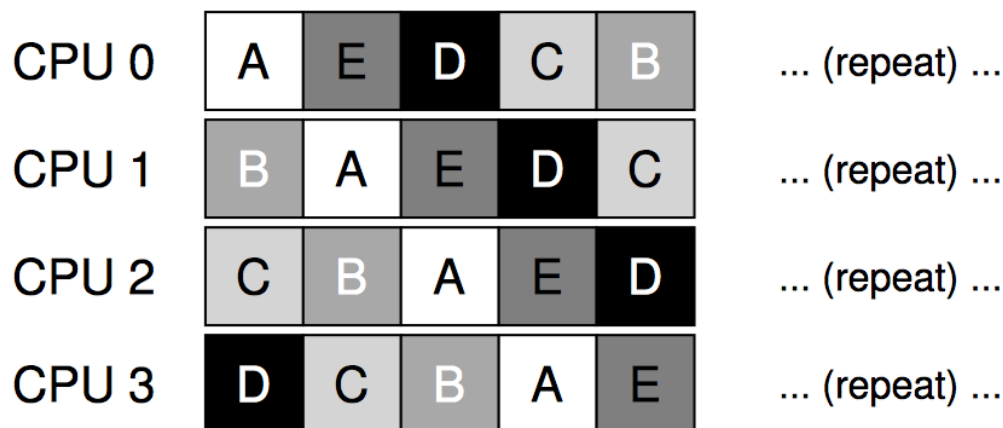

# 多核 CPU 调度

- **Single-Queue Multiprocessor Scheduling** or **SQMS**
  - 改进：
    - 尽量调度到一个 CPU 核上
    - 少数任务切换
  - 扩展性不好

| | | | | | | |
|---|---|---|---|---|---|---|
| CPU 0 | A | E | A | A | A | ... (repeat) ... |
| CPU 1 | B | B | E | B | B | ... (repeat) ... |
| CPU 2 | C | C | C | E | C | ... (repeat) ... |
| CPU 3 | D | D | D | D | E | ... (repeat) ... |

# 多核 CPU 调度

- **Multi-Queue Multiprocessor Scheduling** (or **MQMS**)
  - 每个 CPU 核一个独立的队列
  - 优点：性能好（Lock 冲突少， cache affinity 好）
  - 缺点： load balance
    - 解决： **work stealing**

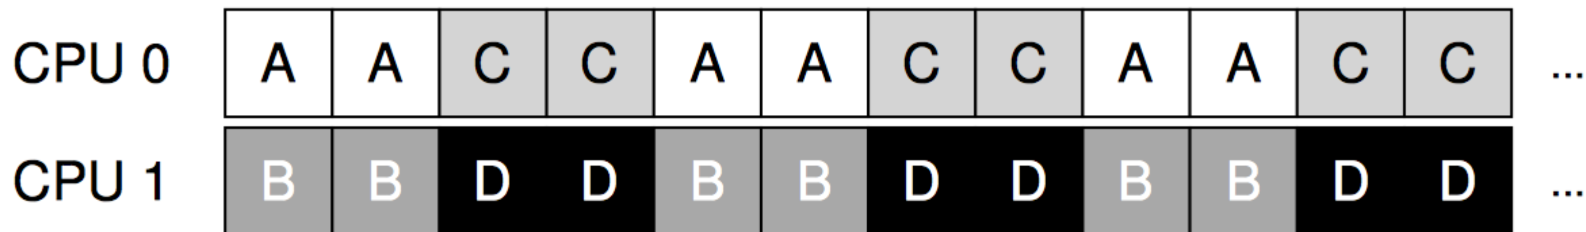

# 多核 CPU 调度

- **Multi-Queue Multiprocessor Scheduling** (or **MQMS**)
  - 主要缺点： load imbalance

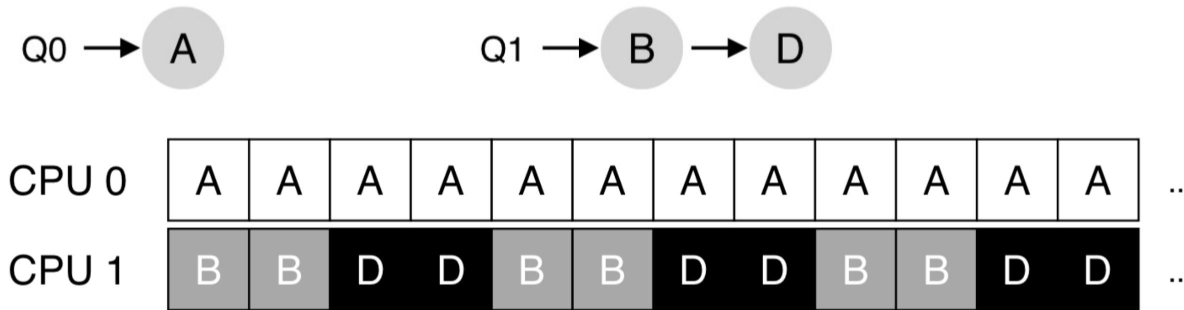


**Job C 执行完了， A 的份额是 B,D 的两倍**

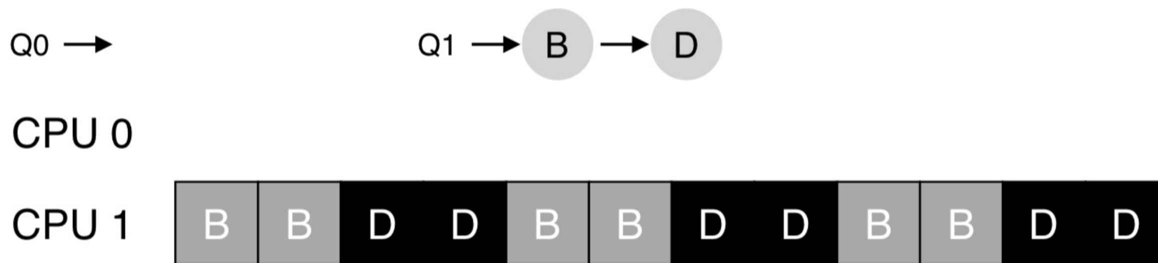


**Job A 也执行完了， CPU 0 完全闲置**

**变形金钢中， Cybertron 母星就是被 bad CPU scheduling decisions 毁了**

# 多核 CPU 调度

- 解决 load imbalance 的办法： migration
  - 但这种情况下，单独迁移一个 job 并不解决问题

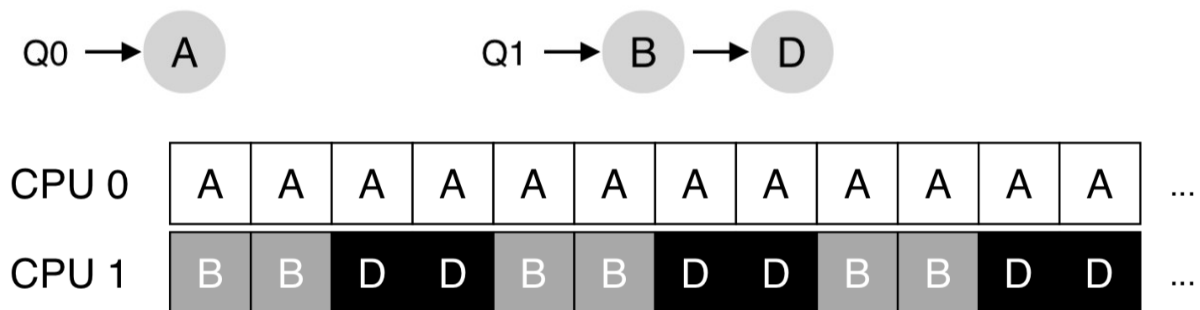


  - Work stealing
    - 不饱和队列从其他队列拿过来一两个 job； 但频率提高也会有问题

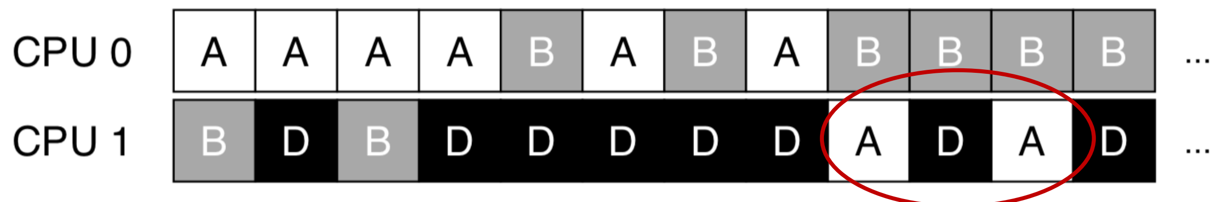

# 多核 CPU 调度

- Linux 的多核 CPU 调度策略
  - 没有一种确定的方案完全优于其他
  - CFS （Completely Fair Scheduler）：多队列
    - 类似于 stride scheduler
  - BFS （BF Scheduler）：单队列
  - O(1) Scheduler：多队列
    - 类似于 MLFQ

# 课堂练习

例 3：某系统的进程状态如图所示。

（1）说明一个进程发生状态变化 3、4、6 的原因。

（2）下述因果变迁是否会发生？若会，在什么情况下发生？

A. 3→5　　B. 6→4　　C. 6→7

（3）根据此进程状态图，说明该系统的 CPU 调度策略和调度效果。

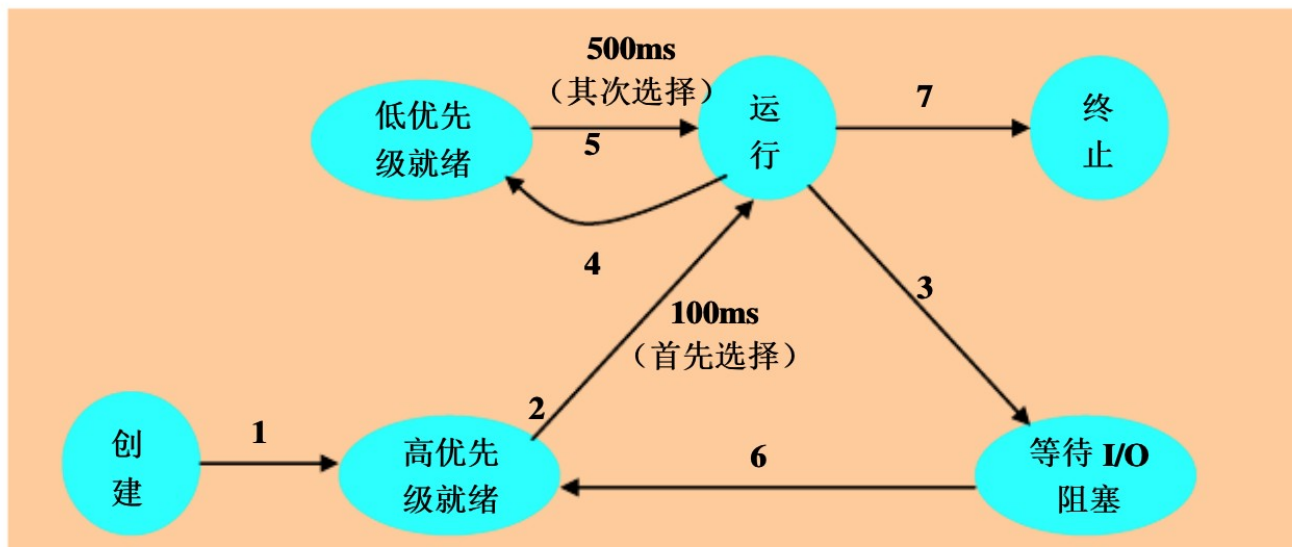

# 练习答案

（1）变化 3 的原因是运行进程提出 I/O 请求。发生变化 4 的原因是运行进程的时间片到。发生变化 6 的原因是阻塞进程因所等待的 I/O 操作完成而被 I/O 中断服务程序唤醒。

（2）A. 因果变迁 3——5 会发生：当某个运行进程由于 I/O 请求而阻塞时，如果此时系统中不存在高优先级就绪进程而只存在低优先级就绪进程，则系统将选择一个低优先级进程投入运行。

B. 因果变迁 6——4 不会发生：发生 4 的原因只可能是时间片用完。

C. 因果变迁 6——7 不会发生：发生 7 的原因是进程在时间片用完前提前运行结束。

（3）该系统的集成调度策略是多级队列调度策略，它将系统中的所有进程按照优先级的高低组织成高优先级和低优先级两个队列，两个队列均采用时间片轮转调度算法，但高优先级队列的时间片较短（100ms），低优先级队列的时间片较长（500ms），系统总是先调度高优先级队列上的进程，仅当该队列为空时，才调度低优先级队列上的进程。

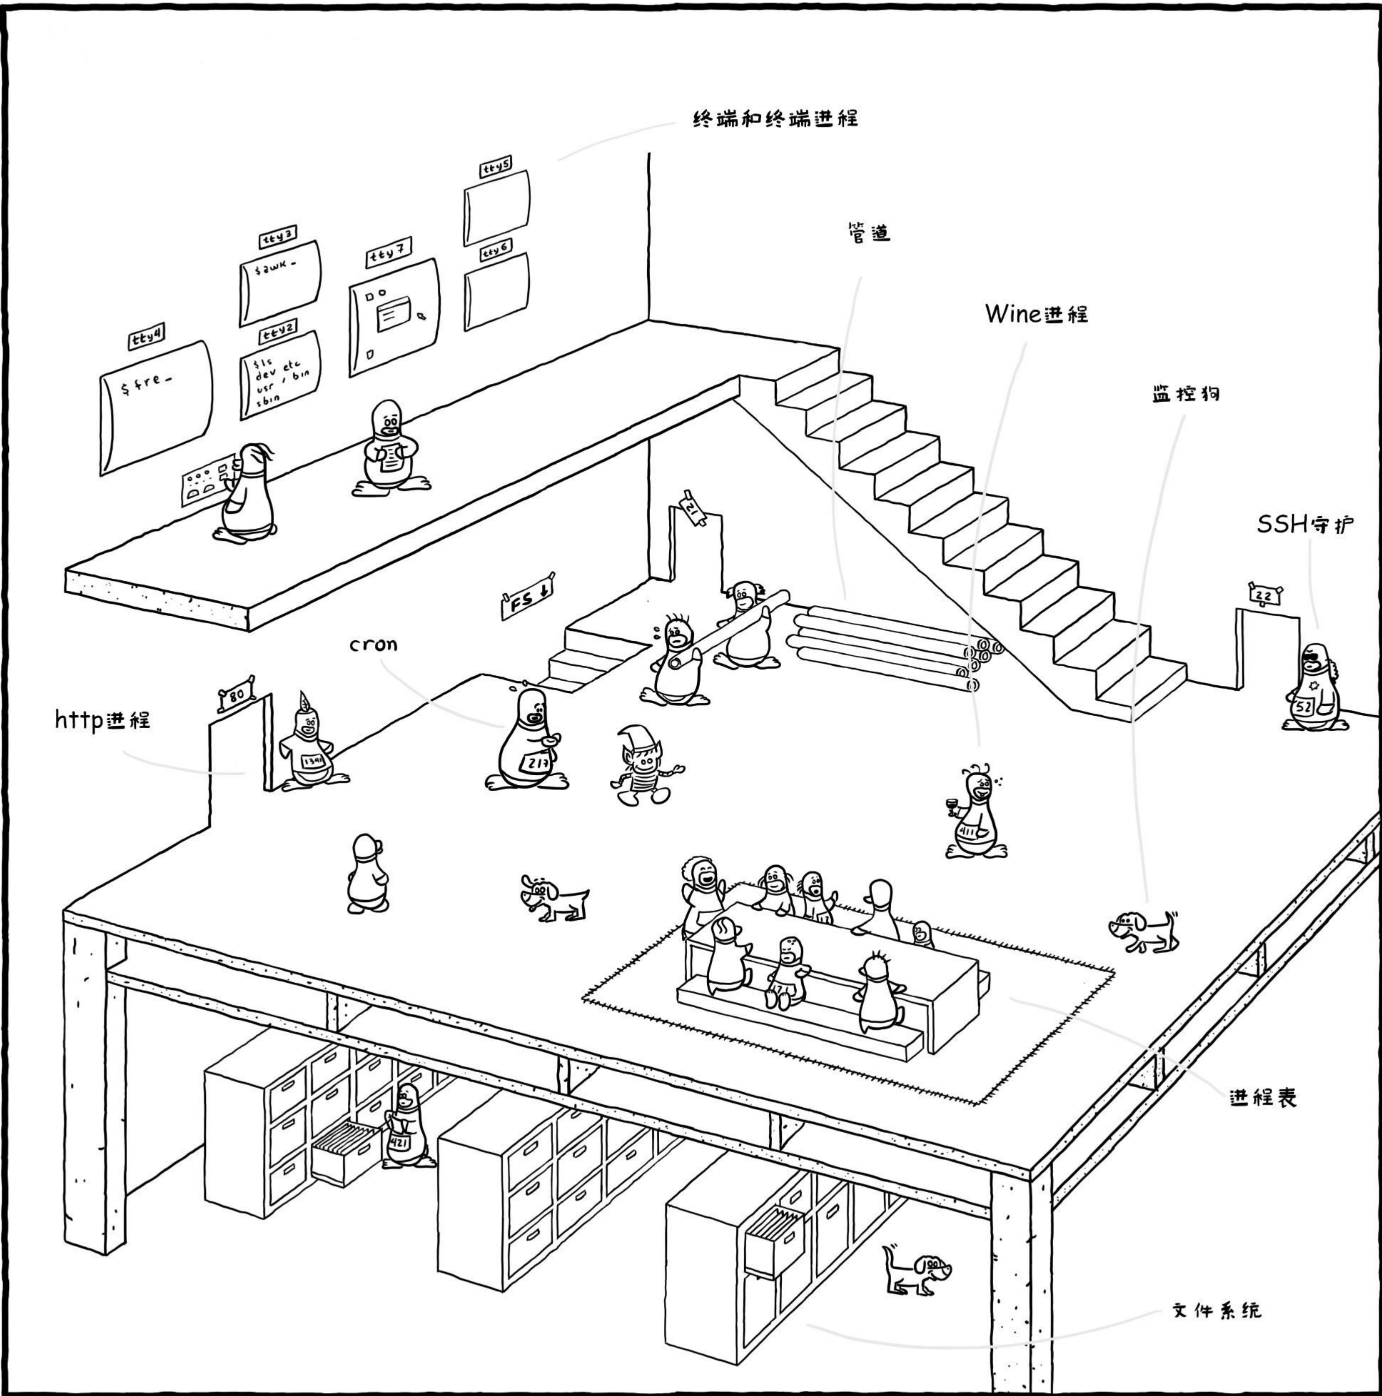
终端和终端进程
tty5
tty3
$awk_
tty7
tty6
tty4
$fre_
tty2
$ls etc
dev / bin
usr
sbin
管道
Wine进程
监控狗
SSH守护
22
FS
cron
http进程
80
217
52
411
421
进程表
文件系统
原创：Daniel Stori {turnoff.us}
汉化：LCTT @ Bestony
字体：蔡云汉天真娃娃书法体、Comic San MS

# 国产 CPU

# 冯诺伊曼结构

数据流

控制流

运算器

输入设备

存储器

输出设备

控制器

计算机之父——约翰·冯·诺依曼

# 哈佛结构

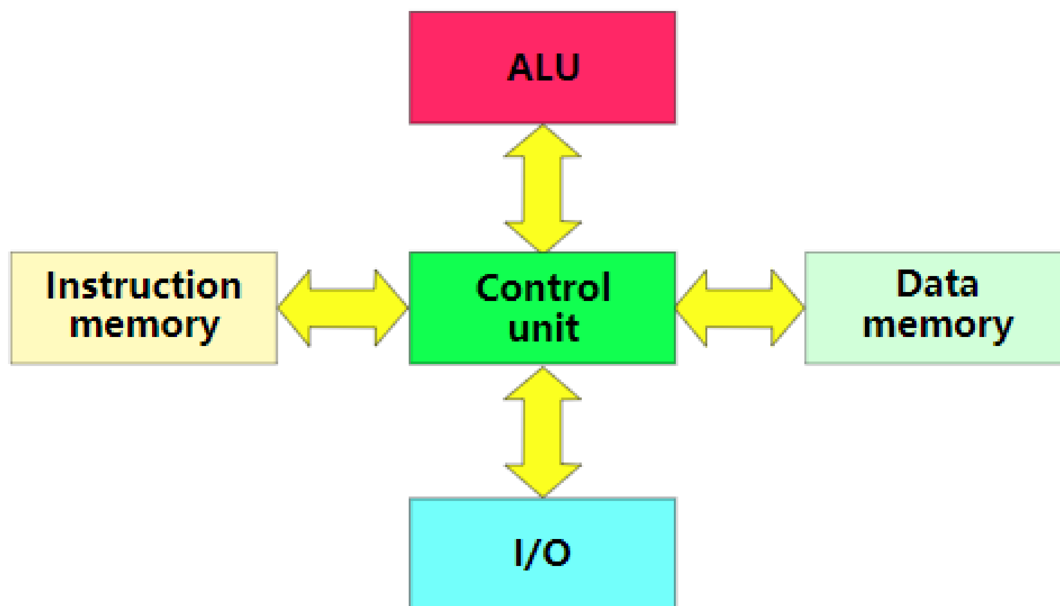


**哈佛结构是一种将程序指令存储和数据存储分开的存储器结构，它的主要特点是将程序和数据存储在不同的存储空间中**
**即程序存储器和数据存储器是两个独立的存储器，每个存储器独立编址、独立访问，目的是为了减轻程序运行时的访存瓶颈。**

**哈佛架构的中央处理器典型代表 ARM9/10 及后续 ARMv8 的处理器，例如：华为鲲鹏 920 处理器。**

# 主流 CPU 发展路径

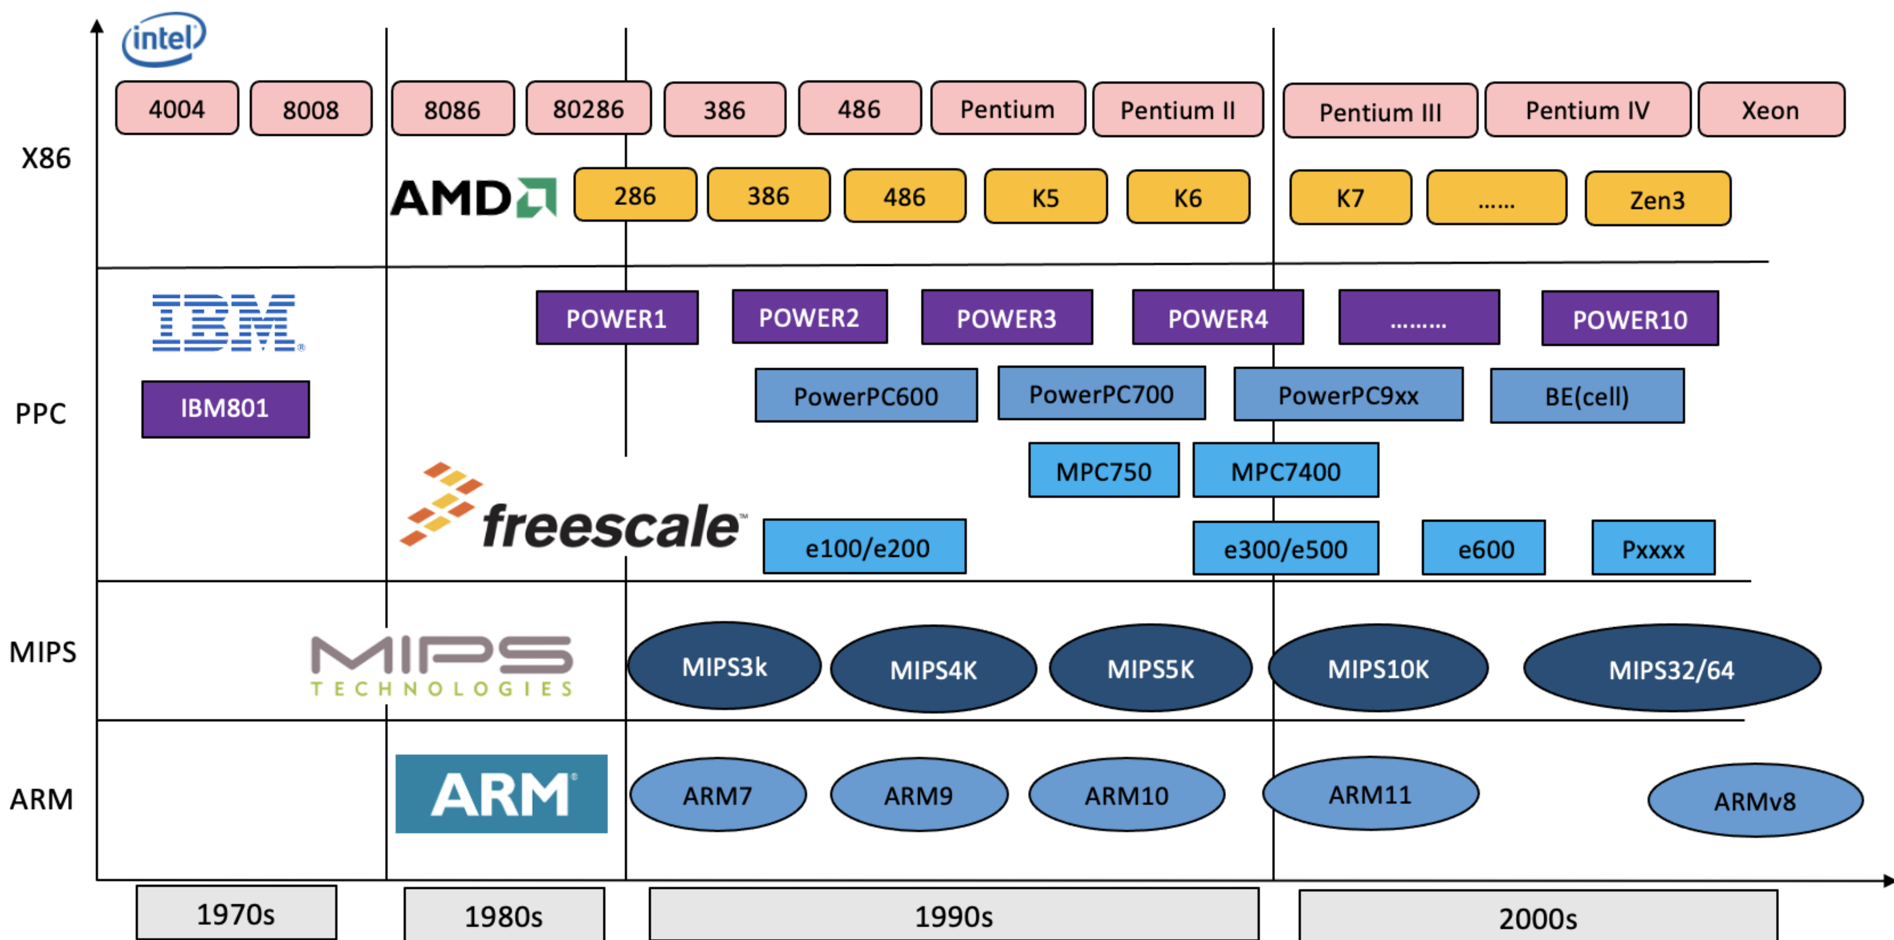

# ARM 提供更多计算核心

- 工艺、主频遇到瓶颈后，开始通过增加核数的方式来提升性能；
- 芯片的物理尺寸有限制，不能无限制的增加；
- ARM 的众核横向扩展空间优势明显。

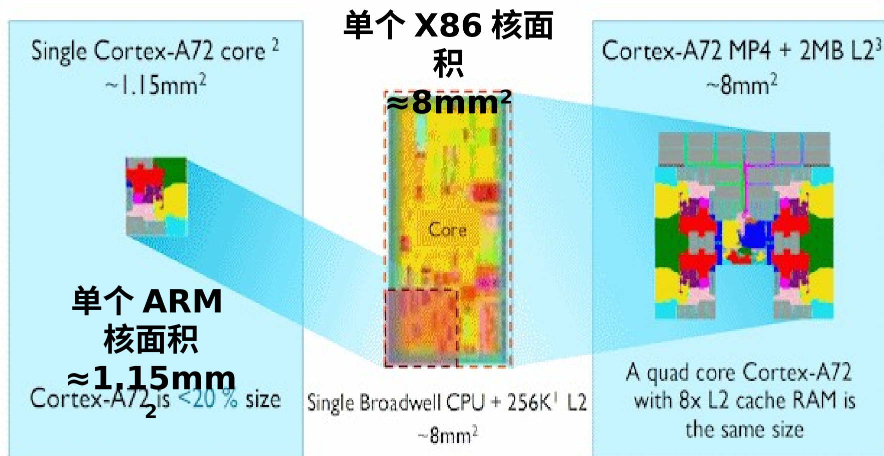


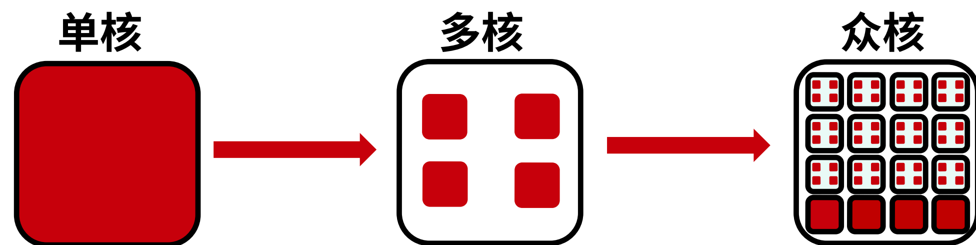

# ARM 公司授权体系

- ARM 目前在全球拥有大约 1000 个授权合作商、 320 家伙伴，但是购买架构授权的厂家不超过 20 家，中国有华为、飞腾获得了架构授权。

| 授权类型 | | 说明 |
|---|---|---|
| 架构 / 指令集授权 | | • 按照所授权的架构和指令集（如 ARMv8 ）自行编写代码、设计芯片。 |
| 处理器授权 | | • 提供 RTL 代码，处理器的核数、缓存可以自己配置。自主设计主频、工艺、代工厂等。 |
| 处理器优化包 / 物理 IP 包授权 （ POP ） | | • 只能按照 ARM 设计好的处理器类型、在指定的代工厂进行生产。 |

# 鲲鹏处理器

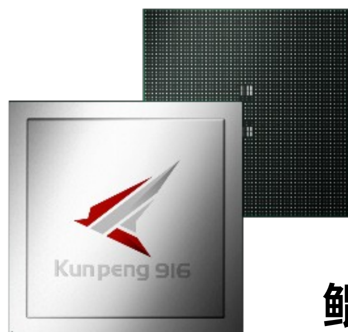


**鲲鹏 916**

### 支持多路互联的 ARM 处理器

- 32 核，2.4 GHz 主频
- SPECint 性能匹配业界中端，功耗低至 75 W
- 支持 4 通道 DDR4 控制器
- 支持 PCI-e 3.0 和 SAS/SATA 3.0
- 集成板载 GE/10 GE 网络
- 支持 2 路互联

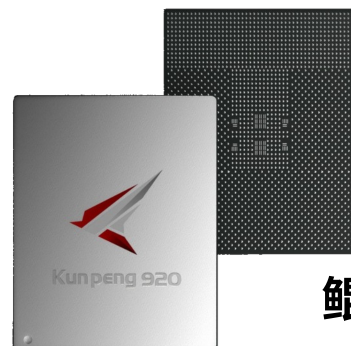


**鲲鹏 920**

### 7nm 制程，数据中心 ARM 处理

- 计算核数提升 1 倍，最多 64 核
- SPECint 性能提升超过 2 倍
- 内存通道数提升 1 倍，支持 8 通道 DDR4 控制器
- 支持 PCI-e 4.0 和 CCIX
- 集成板载 100 GE 网络和加密、压缩加速引擎
- 支持 2 路或 4 路互联

# 鲲鹏 920 系列芯片架构——乐高架构

- TaiShan Core 独享 L1 Cache 和 L2 Cache， 4 个 Core 和 1 个 L3 Cache tag 组成一个 Cluster， 6~8 个 Cluster 组成一个 CPU Die， 合封后的两个 CPU Die 共

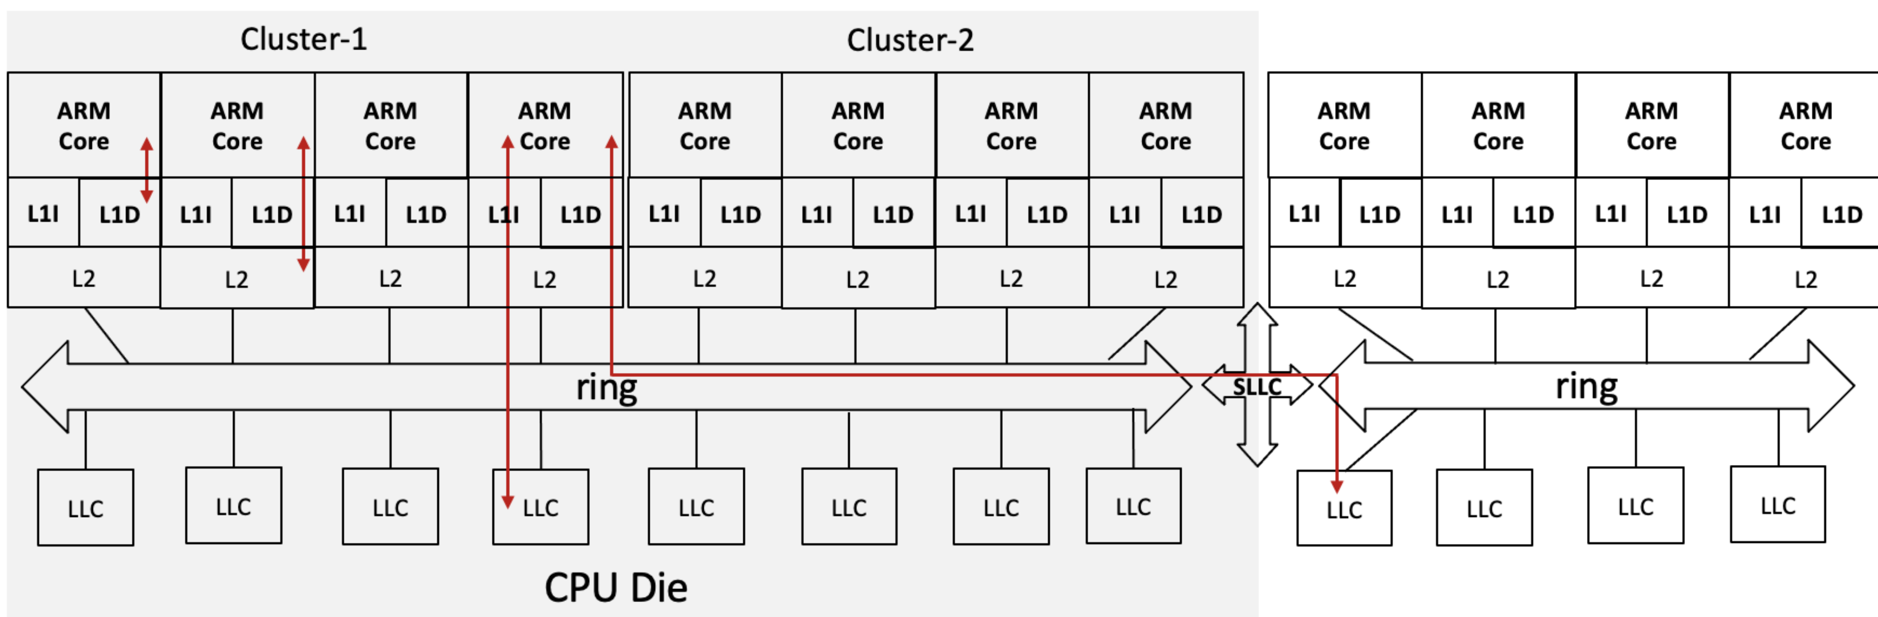

# OpenEuler 的 CPU 调度策略

- CFS(Completely Fair Scheduler) 调度
  - 每个进程一个队列
  - 结合时间片和优先级，引入虚拟运行时间
  - 按照当前系统负载和普通进程的优先级给进程分配 CPU 使用时间的比例，确保相对公平

# homework3