

第二部分 分布式算法

汪炆

中国科学技术大学计算机系
国家高性能计算中心（合肥）

Ch.1 导论

§ 1.1 分布式系统

- **Def:** 一个分布式系统是一个能彼此通信的单个计算装置的集合（计算单元：硬——处理器；软——进程）

包括：紧耦合系统----如共享内存多处理机

松散系统-----cow、Internet

- 与并行处理的分别(具有更高层次的不确定性和行为的独立性)
 - 并行处理的目标是使用所有处理器来执行一个大任务
 - 而分布式系统中，每个处理器一般都有自己独立的任务，但由于各种原因（为共享资源，可用性和容错等），处理机之间需要协调彼此的动作。
- 分布式系统无处不在，其作用是：
 - ①共享资源
 - ②改善性能：并行地解决问题
 - ③改善可用性：提高可靠性，以防某些成分发生故障

§ 1.1 分布式系统

分布式系统软件实例简介

- ElcomSoft Distributed Password Recovery 是一款俄罗斯安全公司出品的分布式密码暴力破解工具
- 能够利用Nvidia显卡使WPA和WPA2无线密钥破解速度提高100倍
- 还允许数千台计算机联网进行分布式并行计算


§ 1.1 分布式系统

系统适用范围

- ElcomSoft 的密码恢复软件主要是面向 Office，包括（Word, Excel, Access, Outlook, Outlook Express, VBA, PowerPoint and Visio)
- 其他的面向微软的产品有（Project, Backup, Mail, Schedule+), archive products (including ZIP, RAR, ACE and ARJ files)等

§ 1.1 分布式系统

演示界面-支持的文件类型




A screenshot of a file type selection menu. The title bar at the top is blue and contains the text "All Supported Documents". Below the title bar, a list of file types is displayed in a monospaced font. Each entry consists of a name followed by the supported file extensions in parentheses. The list includes: crypt() Password Hashes (*.crypt), Domain Cached Credentials (security; secu, Intuit Quicken (*.qdf), MD5 Password Hashes (*.md5), Lotus Notes (*.id; admindata.xml), PWDUMP Password Hashes (*.pwdump; lmnt.ls, Microsoft Office (*.doc; *.dot; *.xls; *.xl, OpenDocument (*.odt; *.ott; *.odg; *.otg; *.), Oracle Password Hashes (*.orc), Adobe PDF (*.pdf), Personal Information Exchange (*.pfx; *.p, PGP (*.pgp; *.pgd; *.exe; *.skr; *.wde; secri, SYSKEY (sam; system; sam.bak; system.bak; sa, WPA-PSK Hashes and Handshakes (*.cap; *.w, and All Files (*.*) at the bottom.

All Supported Documents

- crypt() Password Hashes (*.crypt)
- Domain Cached Credentials (security; secu
- Intuit Quicken (*.qdf)
- MD5 Password Hashes (*.md5)
- Lotus Notes (*.id; admindata.xml)
- PWDUMP Password Hashes (*.pwdump; lmnt.ls
- Microsoft Office (*.doc; *.dot; *.xls; *.xl
- OpenDocument (*.odt; *.ott; *.odg; *.otg; *.
- Oracle Password Hashes (*.orc)
- Adobe PDF (*.pdf)
- Personal Information Exchange (*.pfx; *.p
- PGP (*.pgp; *.pgd; *.exe; *.skr; *.wde; secri
- SYSKEY (sam; system; sam.bak; system.bak; sa
- WPA-PSK Hashes and Handshakes (*.cap; *.w
- All Files (*.*)

§ 1.1 分布式系统


演示—主界面



§ 1.1 分布式系统

最终破解效果

- DOC加密的文档，8位数字型密码小于1分钟即可成功解密



The screenshot displays a software interface with a left-hand navigation menu and a main content area. The navigation menu includes icons and labels for 'Recovery', 'Agents', 'Connection', 'Alerts', and 'Cache And Log'. The main content area features a table with system information, a summary bar, and a detailed statistics section.

host name	ip-address	benchmark	cpu	gpu	administration	version	time to live	status
PC-200901022324	127.0.0.1	?	-	-	locally	2.71.195	1 min.	working

total : 1, working : 1, free : 0, off hours : 0, not responded : 0, disabled : 0


	items processed	processor time usage
today :	34 714 930	00:02:12 (00.394 %)
yesterday :	432 631 514	00:27:05 (01.882 %)
this week :	1 010 694 308	0 d. 01:42:48 (02.106 %)
this month :	1 010 694 308	0 d. 01:42:48 (02.106 %)
this year :	1 010 694 308	0 d. 01:42:48 (00.208 %)
total :	1 010 694 308	0 d. 01:42:48 (37.710 %)

Reset Statistics

	cpu(s)	gpu(s)
active :	-	-

§ 1.1 分布式系统

Agents工作界面



§ 1.1 分布式系统

NASA SETI寻找外星人计划

- SETI (搜寻外星智慧) 是一个寻找地球外智慧生命的科学性实验计划，使用射电望远镜来监听太空中的窄频无线电信号。假设这些讯号中有些不是自然产生的，那么只要我们侦测到这些讯号就可以证明外星科技的存在。
- 射电望远镜讯号主要由噪声 (来自天体的发射源与接收者的电子干扰) 与像电视转播站、雷达和卫星等等的人工讯号所组成。现代的 Radio SETI 计划会分析这些数字信息。有更强大的运算能力就可以搜寻更广泛的频率范围以及提高灵敏度。因此，Radio SETI 计划对运算能力的需求是永无止尽的。
- 原来的 SETI 项目曾经使用望远镜旁专用的超级计算机来进行大量的数据分析。1995年，David Gedye 提议射电 SETI 使用由全球联网的大量计算机所组成的虚拟超级计算机来进行计算，并创建了 SETI@home 项目来实验这个想法。SETI@home 项目于1999年5月开始运行。

§ 1.1 分布式系统

NASA SETI寻找外星人计划

SETI@home - Windows Internet Explorer

http://setiathome.berkeley.edu/index.php

SETI@home Needs your Help

Donate to SETI@home

Click Here for More Information

SETI@home 是什么?

SETI@home 是一项利用全球互联网的计算机共同搜寻地外文明 (SETI) 的科学实验计划。你可以通过运行一个免费程序下载并分析从射电望远镜传来的数据来加入这个项目。

参与

- 下载
- 帮助信息
- 邀请好友
- 捐助
- 移植与优化
- ... 更多

关于

- 关于 SETI@home
- 关于 Astropulse
- 科学报导
- 技术新闻
- 服务器状态
- 研究状态
- 赞助商
- ... 更多

社区

- 留言板
- 问题解答
- 用户档案
- 检索用户
- 团队
- 网站和 IRC
- 图片与音乐

您的帐户

- 您的帐户
- 参数设置
- 计算证书

统计信息

- 用户排名
- 主机排名
- 团队排名
- Top GPU models

站点搜索:

语言

开始计算

- 1 阅读我们的规定和政策
- 2 下载, 安装并运行 SETI@home 使用的 BOINC 软件。在程序提示输入网址时, 请输入 <http://setiathome.berkeley.edu>

如果您有问题希望得到解答或者需要其它帮助, 请通过 [BOINC 在线帮助系统](#)来联系我们的志愿者。

特别说明:

- 连续 SETI@home 项目 (即 SETI@home Classic) 的用户
- 使用命令行版本或早于 5.0 版本的客户端的用户。

参加其它基于 BOINC 的项目 - 在 SETI@home 暂时没有计算任务的时候, 您的计算机就不至于闲着了。

今日用户

David Missal

18:39:m a conservative who grew up watching Star Trek and Lost in Space

新闻

Network routing problems have been fixed

For the last few months, network routing issues have been interfering with the connectivity of some participants. The actual problem turned out to be a lack of sufficient memory in our router at the [PAIX](#) in Palo Alto. Two days ago we increased the memory in that router by a factor of four. This fixed the problem.

We would like to thank [Hurricane Electric](#), [Packet Clearing House](#), and [CENIC](#) for their great technical help in diagnosing and fixing this problem.

21 Oct 2011 | 17:50:51 UTC · [评论](#)

Fall Funding Drive

Our annual fall funding drive has started. If you haven't gotten our message in your email, you can see it [here](#). Please help us keep SETI@home going by [donating today](#).

9 Oct 2011 | 18:27:45 UTC · [评论](#)

Another way to support SETI@home

In addition to crunching, you can provide some support to SETI@home by using [GoodSearch](#) and [GoodShop](#). These search engines redirect a half their advertising to revenues to charity. Just be sure to choose "University of California - SETI@home" as your charity of choice.

12 Sep 2011 | 20:38:21 UTC · [评论](#)

more data on the way

Internet | 保护模式: 禁用

20:19

2011/10/28

§ 1.1 分布式系统

- 分布式系统面临的困难
 - 异质性：软硬件环境
 - 异步性：事件发生的绝对、甚至相对时间不可能总是精确地知道
 - 局部性：每个计算实体只有全局情况的一个局部视图
 - 故障：各计算实体会独立地出故障，影响其他计算实体的工作。

§ 1.2 分布式计算的理论

- 目标：针对分布式系统完成类似于顺序式计算中对算法的研究
 - 具体：对各种分布式情况发生的问题进行抽象，精确地陈述这些问题，设计和分析有效算法解决这些问题，证明这些算法的最优性。
- 计算模型：
 - 通信：计算实体间msg传递还是共享变量？
 - 哪些计时信息和行为是可用的？
 - 容许哪些错误
- 复杂性度量标准
 - 时间，空间
 - 通信成本：msg的个数，共享变量的大小及个数
 - 故障和非故障的数目

§ 1.2 分布式计算的理论

- 否定结果、下界和不可能的结果

常常要证明在一个特定的分布式系统中，某个特定问题的不可解性。

就像NP-完全问题一样，表示我们不应该总花精力去求解这些问题。

当然，可以改变规则，在一种较弱的情况下去求解问题。

- 我们侧重研究：
 - 可计算性：问题是否可解？
 - 计算复杂性：求解问题的代价是什么？

§ 1.3 理论和实际之关系

主要的分布式系统的种类，分布式计算理论中常用的形式模型之间的关系

- 种类

- 支持多任务的OS：互斥，死锁检测和防止等技术在分布式系统中同样存在。
- MIMD机器：紧耦合系统，它由分离的硬件运行共同的软件构成。
- 更松散的分布式系统：由网络（局域、广域等）连接起来的自治主机构成

特点是由分离的硬件运行分离的软件。实体间通过诸如TCP/IP栈、CORBA或某些其它组件或中间件等接口互相作用。

§ 1.3 理论和实际之关系

- 模型

模型太多。这里主要考虑三种，基于通信介质和同步程度考虑。

- ① 异步共享存储模型：用于紧耦合机器，通常情况下各处理机的时钟信号不是来源于同一信号源
- ② 异步msg传递模型：用于松散耦合机器及广域网
- ③ 同步msg传递模型：这是一个理想的msg传递系统。该系统中，某些计时信息（如msg延迟上界）是已知的，系统的执行划分为轮执行，是异步系统的一种特例。
该模型便于设计算法，然后将其翻译成更实际的模型。

- Dijkstra E W. Co-operating Sequential Process. In programming Language. F. Genyus(ed.). [S.I.]: Academic Press, 1968, 43-112;
- Owicki S, Gries D. Verifying Properties of Parallel Programs: An Axiomatic Approach. Communication ACM 19, 5(1976), 279-285;

§ 1.3 理论和实际之关系

- 错误的种类
 - 初始死进程
指在局部算法中没有执行过一步。
 - **Crash failure**崩溃错误(损毁模型)
指处理机没有任何警告而在某点上停止操作。
 - **Byzantine failure**拜占庭错误
一个出错可引起任意的动作, 即执行了与局部算法不一致的任意步。拜占庭错误的进程发送的消息可能包含任意内容。

Ch.2 消息传递系统中的基本算法

本章介绍无故障的msg传递系统，考虑两个主要的计时模型：同步及异步。

定义主要的复杂性度量、描述伪代码约定，最后介绍几个简单算法

§ 2.1 消息传递系统的形式化模型

§ 2.1.1 系统


1.基本概念

- 拓扑：无向图 结点——处理机
边 ——双向信道

§ 2.1.1 系统

- 算法：由系统中每个处理器上的局部程序构成
 - 局部程序 执行局部计算——本地机器
 发送和接收msg——邻居
 - 形式地：一个系统或一个算法是由 n 个处理器 $p_0, p_1, \dots, p_{n-1}$ 构成，每个处理器 p_i 可以模型化为一个具有状态集 Q_i 的状态机（可能是无限的）

§ 2.1.1 系统



- 状态（进程的局部状态）
由 p_i 的变量， p_i 的 `msgs` 构成。
 p_i 的每个状态由 $2r$ 个 `msg` 集构成：
 - `outbufi[ $l$ ]` ($1 \leq l \leq r$): p_i 经第 l 条关联的信道发送给邻居，但尚未传到邻居的 `msg`。
 - `inbufi[ $l$ ]` ($1 \leq l \leq r$): 在 p_i 的第 l 条信道上已传递到 p_i ，但尚未经 p_i 内部计算步骤处理的 `msg`。
- 模拟在信道上传输的 `msgs`

§ 2.1.1 系统

- 初始状态:
 - Q_i 包含一个特殊的初始状态子集：每个 $\text{inbuf}_i[l]$ 必须为空，但 $\text{outbuf}_i[l]$ 未必为空。
- 转换函数(transition):

处理器 p_i 的转换函数(实际上是一个局部程序)

 - 输入： p_i 可访问的状态
 - 输出： 对每个信道 l ，至多产生一个msg输出
 - 转换函数使输入缓冲区($1 \leq l \leq r$)清空。

§ 2.1.1 系统

- 配置：配置是分布式系统在某点上整个算法的全局状态

向量= $(q_0, q_1, \dots, q_{n-1})$, q_i 是 p_i 的一个状态

一个配置里的outbuf变量的状态表示在通信信道上传输的信息，由del事件模拟传输

一个初始的配置是向量= $(q_0, q_1, \dots, q_{n-1})$, 其中每个 q_i 是 p_i 的初始状态，即每个处理器处于初始状态

§ 2.1.1 系统

- 事件：系统里所发生的事情均被模型化为事件，对于msg传递系统，有两种：
comp(i)——计算事件。代表处理器 p_i 的一个计算步骤。
其中， p_i 的转换函数被用于当前可访问状态
del(i,j,m)——传递事件，表示msg m从 p_i 传送到 p_j
- 执行：系统在时间上的行为被模型化为一个执行。它是一个由配置和事件交错的序列。该序列须满足各种条件，主要分为两类：

§ 2.1.1 系统

① Safety条件: (安全性)

表示某个性质在每次执行中每个可达的配置里都必须成立

在序列的每个有限前缀里必须成立的条件

例如: “在leader选举中, 除了 $p_{\max}$ 外, 没有哪个结点宣称自己是leader”

非形式地: 安全性条件陈述了“尚未发生坏的情况” “坏事从不发生”

§ 2.1.1 系统

②liveness条件：(活跃性)

表示某个性质在每次执行中的某些可达配置里必须成立。

必须成立一定次数的条件(可能是无数次)

例如：条件：“ p_1 最终须终止”，要求 p_1 的终止至少发生一次；“leader选举， $p_{\max}$ 最终宣布自己是leader”

非形式地，一个活跃条件陈述：“最终某个好的情况发生”

对特定系统，满足所有要求的安全性条件的序列称为一个执行；若一个执行也满足所有要求的活跃性条件，则称为容许(合法的)(admissible)执行

第二部分 分布式算法

汪炆

第二次课

中国科学技术大学计算机系
国家高性能计算中心（合肥）

§ 2.1.1 系统

2.异步系统

- 异步：msg传递的时间和一个处理器的两个相继步骤之间的时间无固定上界

例如，Internet中，email虽然常常是几秒种到达，但也可能要数天到达。当然msg延迟有上界，但它可能很大，且随时间而改变。

因此异步算法设计时，须使之独立于特殊的计时参数，不能依赖于该上界。

- 执行片断

一个异步msg传递系统的一个执行片断 α 是一个有限或无限的序列：

$C_0, \Phi_1, C_1, \Phi_2, C_2, \Phi_3, \dots, (C_0 \text{ 不一定是初始配置})$

这里 C_k 是一个配置， Φ_k 是一个事件。若 α 是有限的，则它须结束于某个配置，且须满足下述条件：

§ 2.1.1 系统

- 若 $\Phi_k = \text{del}(i, j, m)$ ，则 m 必是 C_{k-1} 里的 $\text{outbuf}_i[l]$ 的一个元素，这里 l 是 p_i 的信道 $\{p_i, p_j\}$ 的标号

从 C_{k-1} 到 C_k 的唯一变化是将 m 从 C_{k-1} 里的 $\text{outbuf}_i[l]$ 中删去，并将其加入到 C_k 里的 $\text{inbuf}_j[h]$ 中， h 是 p_j 的信道 $\{p_i, p_j\}$ 的标号。

即：传递事件将 msg 从发送者的输出缓冲区移至接收者的输入缓冲区。

- 若 $\Phi_k = \text{comp}(i)$ ，则从 C_{k-1} 到 C_k 的变化是

①改变状态：转换函数在 p_i 的可访问状态(在配置 C_{k-1} 里)上进行操作，清空 $\text{inbuf}_i[l]$ ， $(1 \leq l \leq r)$

②发送 msg ：将转换函数指定的消息集合加到 C_k 里的变量 outbuf_i 上。(Note:发送 send ，传递 delivery 之区别)

即： p_i 以当前状态(在 C_{k-1} 中)为基础按转换函数改变状态并发出 msg 。

§ 2.1.1 系统

- 执行：一个执行是一个执行片断 $C_0, \Phi_1, C_1, \Phi_2, \dots$ ，这里 C_0 是一个初始配置。
- 调度：一个调度(或调度片段)总是和执行(或执行片断)联系在一起的，它是执行中的事件序列： $\Phi_1, \Phi_2, \dots$ 。

并非每个事件序列都是调度。例如， $\text{del}(1,2,m)$ 不是调度，因为此事件之前， p_1 没有步骤发送(send)m。

若局部程序是确定的，则执行(或执行片断)就由初始配置 C_0 和调度(或调度片断) σ 唯一确定，可表示为 $\text{exec}(C_0, \sigma)$ 。

§ 2.1.1 系统

- 容许执行：(满足活跃性条件)

异步系统中，若某个处理器有无限个计算事件，每个发送的msg都最终被传递，则执行称为容许的。

Note: 无限个计算事件是指处理器没有出错，但它不蕴含处理器的局部程序必须包括一个无限循环
非形式地说：一个算法终止是指在某点后转换函数不改变处理器的状态。

- 容许的调度：
若它是一个容许执行的调度。

§ 2.1.1 系统

3.同步系统

在同步模型中，处理器按锁步骤(lock-step)执行：

执行被划分为轮，每轮里，①每个处理器能够发送一个msg到每个邻居，这些msg被传递。②每个处理器一接到msg就进行计算。

虽然特殊的分布系统里一般达不到，但这种模型对于设计算法非常方便，因为无需和更多的不确定性打交道。当按此模型设计算法后，能够很容易模拟得到异步算法。

- 轮：在同步系统中，配置和事件序列可以划分成不相交的轮，每轮由一个传递事件(将outbuf的消息传送到信道上使outbuf变空)，后跟一个计算事件(处理所有传递的msg)组成。

§ 2.1.1 系统

- 容许的执行：指无限的执行。
因为轮的结构，所以
 每个处理器执行无限数目的计算步，
 每个被发送的msg最终被传递
- 同步与异步系统的区别
 在一个无错的同步系统中，一个算法的执行只取决于初始配置
 但在一个异步系统中，对于相同的初始配置及无错假定，因为处理器步骤间隔及消息延迟均不确定，故同一算法可能有不同的执行。

§ 2.1.2 复杂性度量

- 分布式算法的性能：msg个数和时间。
最坏性能、期望性能
- 终止：假定每个处理器的状态集包括终止状态子集，每个的 p_i 的转换函数对终止状态只能映射到终止状态

当所有处理机均处于终止状态且没有msg在传输时，称系统(算法)已终止。

- 算法的msg复杂性(最坏情况)：算法在所有容许的执行上发送msg总数的最大值(同步和异步系统)

§ 2.1.2 复杂性度量

- 时间复杂度

①同步系统：最大轮数，即算法的任何容许执行直到终止的最大轮数。

②异步系统：假定任何执行里的msg延迟至多是1个单位的时间，然后计算直到终止的运行时间

- 计时执行(timed execution)

指：每个事件关联一个非负实数，表示事件发生的时间。时间起始于零，且须是非递减的。但对每个单个的处理器而言是严格增的。

若执行是无限的，则执行的时间是无界的。因此执行中的事件可根据其发生时间来排序

不在同一处理器上的多个事件可以同时发生，在任何有限时间之前只有有限数目的事件发生。

§ 2.1.2 复杂性度量

- 消息的延迟

发送msg的计算事件和处理该msg的计算事件之间所逝去的时间

它主要由msg在发送者的outbuf中的等待时间和在接收者的inbuf中的等待时间所构成。

- 异步算法的时间复杂性

异步算法的时间复杂性是所有计时容许执行中直到终止的最大时间，其中每个msg延时至多为1。

§ 2.1.3 伪代码约定

在形式模型中，一个算法将根据状态转换来描述。但实际上很少这样做，因为这样做难于理解。

实际描述算法有两种方法：

- ①叙述性：对于简单问题
- ②伪码形式：对于复杂问题

§ 2.1.3 伪代码约定

- 异步算法：对每个处理器，用中断驱动来描述异步算法。
在形式模型中，每个计算事件1次处理所有输入缓冲区中的msgs。而在算法中，一般须描述每个msg是如何逐个处理的
异步算法也可在同步系统中工作，因为同步系统是异步系统的一个特例。
一个计算事件中的局部计算的描述类似于顺序算法的伪代码描述。
- 同步算法：逐轮描述
- 伪代码约定：
 - 在 p_i 的局部变量中，无须用 i 做下标，但在讨论和证明中，加上下标 i 以示区别。
 - “//”后跟注释

§ 2.2 生成树上的广播和汇集

信息收集及分发是许多分布式算法的基础。故通过介绍这两个算法来说明模型、伪码、正确性证明及复杂性度量等概念。

由于分布式系统中，每个节点并不知道全局拓扑，但某些算法需要在特定结构下才能达到最优，比如广播/敛播在树结构下才能达到消息复杂度最优，因此构造生成树是必要的，是其他算法的基础。


§ 2.2.1 广播(Broadcast)

假定网络的生成树已给定。某处理器 p_r 希望将消息 M 发送至其余处理器。


假定生成树的根为 p_r ，每个处理器有一个信道连接其双亲(p_r 除外)，有若干个信道连接其孩子。

§ 2.2.1 广播

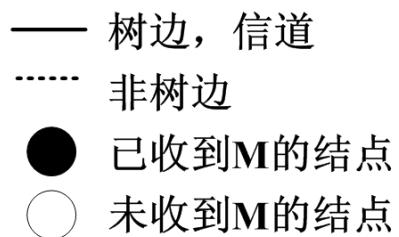
- 根 p_r 发送 M 给所有孩子。(a)
- 当某结点收到父结点的 M 时，发送 M 到自己的所有孩子(b)。



(a)



(b)



§ 2.2.1 广播

1. 伪码算法

Alg2.1 Broadcast

p_r : //发动者。假设初始化时M已在传输状态

1. upon receiving no msg: // p_r 发送M后执行终止
2. terminate; //将terminated置为true。

$p_i (i \neq r, 0 \leq i \leq n-1)$:

3. upon receiving M from parent:
4. send M to all children;
5. terminate;

2. 用状态转换来分析算法

- 每个处理器 p_i 包含状态

- 变量 $parent_i$: 表示处理器 p_i 双亲结点的标号或为nil(若 $i=r$)
- 变量 $children_i$: p_i 的孩子结点标号的集合
- 布尔变量 $terminated_i$: 表示 p_i 是否处于终止状态

§ 2.2.1 广播

- 初始状态
 - parent和children的值是形成生成树时确定的
 - 所有terminated的值均为假
 - $\text{outbuf}_r[j]$, $j \in \text{children}_r$ 持有消息M, 注意j不是信道标号, 而是r的邻居号。(任何系统中, 均假定各节点标号互不相等)
 - 所有其他结点的outbuf变量均为空。
- comp(i)的结果

若对于某个k, M在 $\text{inbuf}_i[k]$ 里, 则M被放到 $\text{outbuf}_i[j]$ 里, $\forall j \in \text{children}_i$

§ 2.2.1 广播

- p_i 进入终止状态

将 $terminated_i$ 置为true; 若 $i=r$ 且 $terminated_r$ 为false, 则 $terminated_r$ 立即置为true, 否则空操作。

- 该算法对同步及异步系统均正确, 且在两模型中, msg 和时间复杂度相同。

- Msg 复杂度

无论在同步还是异步模型中, msg M 在生成树的每条边上恰好发送一次。

因此, msg 复杂性为 $n-1$ 。

§ 2.2.1 广播

- 时间复杂性:

①同步模型: 时间由轮来度量。

Lemma2.1 在同步模型中, 在广播算法的每个容许执行里, 树中每个距离 p_r 为 t 的处理器在第 t 轮里接收消息 M 。

pf: 对距离 t 使用归纳法。

归纳基础: $t=1$, p_r 的每个孩子在第1轮里接收来自于 p_r 的消息 M

归纳假设: 假设树上每个距 p_r 为 $t-1 \geq 1$ 的处理器在第 $t-1$ 轮里已收到 M 。

归纳步骤: 设 p_i 到 p_r 距离为 t , 设 p_j 是 p_i 的双亲, 因 p_j 到 p_r 的距离为 $t-1$, 由归纳假设, 在第 $t-1$ 轮 p_j 收到 M 。由算法描述知, 在第 t 轮里 p_i 收到来自于 p_j 的消息 M

Th2.2 当生成树高度为 d 时, 存在一个消息复杂度为 $n-1$, 时间复杂度为 d 的同步广播算法

§ 2.2.1 广播

②异步模型

Lemma 2.3 在异步模型的广播算法的每个容许执行里，树中每个距离 p_r 为 t 的处理器至多在时刻 t 接收消息 M 。

pf: 对距离 t 做归纳。

对 $t=1$ ，初始时， M 处在从 p_r 到所有距离为1的处理器 p_i 的传输之中，由异步模型的时间复杂性定义知， p_i 至多在时刻1收到 M 。

$p_i \in \{\text{距 } p_r \text{ 为 } t \text{ 的处理器}\}$ ，设 p_j 是 p_i 的双亲，则 p_j 与 p_r 的距离为 $t-1$ ，由归纳假设知， p_j 至多在时刻 $t-1$ 收到 M ，由算法描述知， p_j 发送给 p_i 的 M 至多在 t 时刻到达。

Th 2.4 同Th 2.2

下次继续！

第二部分 分布式算法



第三次课

中国科学技术大学计算机系
国家高性能计算中心（合肥）

§ 2.2.2 convergecast(汇集, 敛播)

与广播问题相反, 汇集是从所有结点收集信息至根。为简单起见, 先考虑一个特殊的变种问题:

假定每个 p_i 开始时有一初值 x_i , 我们希望将这些值中最大者发送至根 p_r 。



§ 2.2.2 convergecast(汇集, 敛播)

- 算法

每个叶子结点 p_i 发送 x_i 至双亲。//启动者

对每个非叶结点 p_j , 设 p_j 有 k 个孩子 $p_{i1}, \dots, p_{ik}$, p_j 等待 k 个孩子的msg $v_{i1}, v_{i2}, \dots, v_{ik}$, 当 p_j 收到所有孩子的msg之后将 $v_j = \max\{x_j, v_{i1}, \dots, v_{ik}\}$ 发送到 p_j 的双亲。

换言之: 叶子先启动, 每个处理器 p_i 计算以自己为根的子树里的最大值 v_i , 将 v_i 发送给 p_i 的双亲。

- 复杂性

Th2.5 当生成树高为 d 时, 存在一个异步的敛播方法, 其msg复杂性为 $n-1$, 时间复杂度为 d 。(与Th2.2相同)

- 广播和敛播算法用途: 初始化某一信息请求(广播发布), 然后用敛播响应信息至根。


§ 2.3 构造生成树

上节算法均假设通信网的生成树已知。本节介绍生成树的构造问题。


1. Flooding算法(淹没)

■ 算法

设 p_r 是特殊处理器。从 p_r 开始，发送 M 到其所有邻居。当 p_i 第1次收到消息 M （不妨设此msg来自于邻居 p_j ）时， p_i 发送 M 到除 p_j 外的所有邻居。



(a)



(b)

§ 2.3 构造生成树

- msg复杂性

因为每个结点在任一信道上发送M不会多于1次，所以每个信道上M至多被发送两次(使用该信道的每个处理器各1次)。

在最坏情况下：M除第1次接收的那些信道外，所有其他信道上M被传送2次。因此，有可能要发送 $2m-(n-1)$ 个msgs。这里m是系统中信道总数，它可能多达 $n(n-1)/2$ 。

- 时间复杂性： $O(D)$ D—网直径

2.构造生成树

对于flooding稍事修改即可得到求生成树的方法。

§ 2.3 构造生成树

①基本思想

- 首先， p_r 发送M给所有邻居， p_r 为根
- 当 p_i 从某邻居 p_j 收到的M是第1个来自邻居的msg时， p_j 是 p_i 的双亲；若 p_i 首次收到的M同时来自多个邻居，则用一个comp事件处理自上一comp事件以来的所有已收到的msgs，故此时， p_i 可在这些邻居中任选一个邻居 p_j 做双亲。
- 当 p_i 确定双亲是 p_j 时，发送<parent>给 p_j ，并向此后收到发来M的处理器发送<reject>msg

§ 2.3 构造生成树



①基本思想

- 因为 p_i 收到 p_j 的 M 是第1个 M ，就不可能已收到其他结点的 M ，当然可能同时收到(说明 p_i 与这些邻居间不是父子关系，或说它们不是生成树中的边)；同时 p_i 将 M 转发给其余邻居，这些邻居尚未发 M 给 p_i ，或虽然已发 M 给 p_i ，但 p_i 尚未收到。
- p_i 向那些尚未发 M 给 p_i (或已发 M 但尚未到达 p_i)的邻居转发 M 之后，等待这些邻居发回响应msg: $\langle \text{parent} \rangle$ 或 $\langle \text{reject} \rangle$ 。那些回应 $\langle \text{parent} \rangle$ 的邻居是 p_i 的孩子。
- 当 p_i 发出 M 的所有接收者均已回应($\langle \text{parent} \rangle$ 或 $\langle \text{reject} \rangle$)，则 p_i 终止。将parent和children边保留即为生成树。

§ 2.3 构造生成树

②图示

p_i 若认为 p_j 是其双亲，则 p_i 向 p_r 发出M，而 p_r 仍会向 p_i 发reject，但因为此前 p_r 向 p_i 发出过M，故 p_i 收到M时仍会向 p_r 发reject。(可以改进？)



§ 2.3 构造生成树

③算法: Alg2.2 构造生成树 (code for p_i $0 \leq i \leq n-1$)

初值: $\text{parent} = \text{nil}$; 集合 children 和 other 均为 ϕ

upon receiving no message:

if $i=r$ and $\text{parent} = \text{nil}$ then { //根尚未发送M

send M to all neighbors;

$\text{parent} := i$; } //根的双亲置为自己

upon receiving M from neighbor p_j :

if $\text{parent} = \text{nil}$ then { // p_i 此前未收到过M, M是 p_i 收到的第1个msg

$\text{parent} := j$;

send $\langle \text{parent} \rangle$ to p_j ; // p_j 是 p_i 的双亲

send M to all neighbors except p_j ;

} else // p_j 不可能是 p_i 的双亲, p_i 收到的M不是第1个msg

send $\langle \text{reject} \rangle$ to p_j ;

upon receiving $\langle \text{parent} \rangle$ from neighbor p_j :

$\text{children} := \text{children} \cup \{j\}$; // p_j 是 p_i 的孩子, 将j加入孩子集

if $\text{children} \cup \text{other}$ 包含了除 parent 外的所有邻居 then terminate;

upon receiving $\langle \text{reject} \rangle$ from neighbor p_j :

$\text{other} := \text{other} \cup \{j\}$; // 将j加入other, 通过非树边发送的msg。

if $\text{children} \cup \text{other}$ 包含了除 p_i 的双亲外的所有邻居 then terminate;

§ 2.3 构造生成树

④分析

Lemma 2.6 在异步模型的每个容许执行中，算法2.2构造一棵根为 p_r 的生成树。(正确性)

Pf: 算法代码告诉我们两个重要事实

- a) 一旦处理器设置了 parent 变量，它绝不改变，即它只有一个双亲
- b) 处理器的孩子集合决不会减小。

因此，最终由 parent 和 children 确定的图结构 G 是静止的，且 parent 和 children 变量在不同结点上是一致的，即若 p_j 是 p_i 的孩子，则 p_i 是 p_j 的双亲。

下述证明结果图 G 是根为 p_r 的有向生成树。

§ 2.3 构造生成树

- 为何从根能到达每一结点？(连通)

反证：假设某结点在 G 中从 p_r 不可达，因网络是连通的，若存在两个相邻的结点 p_i 和 p_j 使得 p_j 在 G 中是从 p_r 可达的(以下简称 p_j 可达)，但 p_i 不可达。因为 G 里一结点从 p_r 可达当且仅当它曾设置过自己的parent变量(Ex2.4证明)，所以 p_i 的parent变量在整个执行中仍为nil，而 p_j 在某点上已设置过自己的parent变量，于是 p_j 发送M到 p_i (line9)，因该执行是容许的，此msg必定最终被 p_i 接收，使 p_i 将自己的parent变量设置为j。矛盾！

§ 2.3 构造生成树

- 为何无环？(无环)

假设有一环， $p_{i1}, \dots, p_{ik}, p_{i1}$ ，若 p_i 是 p_j 的孩子，则 p_i 在 p_j 第1次收到 M 之后第1次收到 M 。因每个处理器在该环上是下一处理器的双亲，这就意味着 p_{i1} 在 p_{i1} 第1次接收 M 之前第1次接收 M 。矛盾！

- 复杂性

显然，此方法与淹没算法相比，增加了msg复杂性，但只是一个常数因子。在异步通信模型里，易看到在时刻 t ，消息 M 到达所有与 p_r 距离小于等于 t 的结点。因此有：

Th2.7 对于具有 m 条边和直径 D 的网络，给定一特殊结点，存在一个msg复杂性为 $O(m)$ ，时间复杂性为 $O(D)$ 的异步算法找到该网络的一棵生成树。

§ 2.3 构造生成树

Alg2.2在同步模型下仍可工作。其分析类似于异步情形。然而，与异步不同的是，它所构造的生成树一定是一棵广度优先搜索(BFS)树。

Lemma2.8 在同步模型下，Alg2.2的每次容许执行均构造一棵根为 p_r 的BFS树。

Pf: 对轮 t 进行归纳。即要证明：在第 t 轮开始时刻

①根据parent变量构造的图 G 是一棵包括所有与 p_r 距离至多为 $t-1$ 结点的BFS树；

②而传输中的消息 M 仅来自于与 p_r 距离恰为 $t-1$ 的结点。

由此构造的树是一棵根为 p_r 的BFS

§ 2.3 构造生成树


当 $t=1$ 时，所有 parent 初值为 nil ， M 从 p_r 传出。

假设引理对第 $t-1 \geq 1$ 轮为真，在该轮里，从距离 $t-2$ 的结点传出的 M 被接收，任何接收 M 的结点与 p_r 的距离不超过 $t-1$ (恰为 $t-1$ 或更短)，那些 parent 值非空的接收结点显然与 p_r 的距离不超过 $t-2$ ，他们既不改变 parent 的值也不转发 M ；而与 p_r 距离为 $t-1$ 的结点在 $t-1$ 轮里收到 M ，因为它们的 parent 为 nil ，故将其置为合适的双亲并转发 M 。距离 p_r 大于 $t-1$ 的结点不会收到 M ，因此也不会转发 M 。因此有如下定理：

Th2.9 对于具有 m 条边直径为 D 的网络，给定一个特殊结点，存在一个同步算法在 msg 复杂性为 $O(m)$ ，时间复杂性为 $O(D)$ 内找到一棵BFS树。

§ 2.3 构造生成树

- 异步系统里，Alg2.2能构造BFS树？
例如，考虑5个顶点的完全连通图



◆ P_0 为根，假定M消息按 P_0 到 p_1 ， P_1 到 P_2 ， P_2 到 P_3 ， P_3 到 P_4 的次序快速传播，而M在其它路径上传播较慢。结果生成树是从 P_0 到 P_4 的链，它不是BFS树。虽然此图直径 $D=1$ ，生成树的高度 $d=4$ ，但是算法的运行时间仍然为 $O(D)$ 而不是 $O(d)$ 。理解： P_0 到 P_4 的M在1个时间内到达，即 $P_0 \rightarrow P_1 \rightarrow P_2 \rightarrow P_3 \rightarrow P_4$ 的时间之和不超1。

§ 2.3 构造生成树

- 信息的请求和收集

将算法2.2(求生成树)和汇集算法组合即可完成。组合算法的时间复杂性在同步和异步模型中不同,设网是完全图

- 求生成树算法: 同步和异步均为 消息复杂性 $O(m)$

时间复杂性 $O(D)$

- 汇集算法: 同步和异步均有 $\text{msg } n-1$

$\text{time } d // \text{生成树高}$

- 组合算法

- ①同步: 组合算法的msg复杂性 $O(m+n)$; BFS树中,
 $d=1, d \leq D$, 故时间复杂性 $O(D+d)=O(D)=O(1)$ 。

- ②异步: 组合算法的msg复杂性 $O(m+n)$; 生成树高
 $d=n-1$, 所以时间复杂性 $O(D+d)=O(d)=O(n)$ 。

1-time复杂性的组合算法 $T(n)=O(D)$ 。

§ 2.4 构造DFS生成树(指定根)

构造DFS树时每次加一个结点，而不像Alg2.2那样，试图在树上同时增加同一层的所有结点。

Alg2.3 构造DFS生成树，为 P_r 为根

Code for processor P_i , $0 \leq i \leq n-1$

```
var    parent: init nil;
```

```
children:    init  $\phi$  ;
```

```
unexplored:    init all the neighbors of  $P_i$ 
               //未访问过的邻居集
```

1: upon receiving no msg:

2: if ($i=r$) and ($\text{parent}=\text{nil}$) then { //当 P_i 为根且未发送M时

```
3:   parent := i; //将parent置为自身的标号
```

4: $\forall v_i \in \text{unexplored};$

5: 将 P_i 从unexplored中删去; //若 P_r 是孤立结点,4-6应稍作修改

6: send M to P_j ;

```
//endif
```

§ 2.4 构造DFS生成树(指定根)

```
7: upon receiving M from neighbor  $P_j$ :
8:   if parent=nil then { //  $P_i$  此前未收到M
9:     parent := j; //  $P_j$  是  $P_i$  的父亲
10:    从unexplored中删  $P_j$ 
11:    if unexplored  $\neq \emptyset$  then {
12:       $P_k \in$  unexplored;
13:      将  $P_k$  从unexplored中删去;
14:      send M to  $P_k$ ;
15:    } else send <parent> to parent;
        //当  $P_i$  的邻居均已访问过, 返回到父亲
16: } else send <reject> to  $P_j$ ; //当  $P_i$  已访问过时
```

§ 2.4 构造DFS生成树(指定根)

```
17: upon receiving <parent> or <reject> from neighbor  $P_j$ :
18:   if received <parent> then add  $j$  to children;
      //  $P_j$  是  $P_i$  的孩子
19:   if unexplored =  $\phi$  then { //  $P_i$  的邻居均已访问
20:     if parent  $\neq i$  then send <parent> to parent;
      //  $P_i$  非根, 返回至双亲
21:     terminate; // 以  $P_i$  为根的DFS子树已构造好!
22:   } else { // 选择  $P_i$  的未访问过的邻居访问之
23:      $P_k \in \text{unexplored}$ ;
24:     将  $P_k$  从 unexplored 中删去;
25:     send  $M$  to  $P_k$ ;
    }
```

§ 2.4 构造DFS生成树(指定根)

引理2.10 在异步模型里的每个容许执行，Alg2.3构造一棵以 P_r 为根的DFS树。证明留作练习。

Th2.11 对于一个具有 m 条边， n 个结点的网络，以及给定的特殊顶点，存在一个时间复杂性和消息复杂性均为 $O(m)$ 的异步算法找到一棵DFS树。

Pf: 每个结点在其邻接边上至多发送 M 一次，每个结点至多生成一个msg(<reject>或<parent>)作为对每个邻接边上收到的 M 的响应。因此Alg2.3至多发送 $4m$ 个消息(其实大部分没有4倍)，即算法的msg复杂性为 $O(m)$ 。

时间复杂性证明留作练习。

如何改进使msg的复杂性不是 $4m$?

注意：上述算法msg复杂性较好，但时间复杂性太差。可降至 $O(n)$ 。

下次继续！

第二部分 分布式算法

第四次课

中国科学技术大学计算机系
国家高性能计算中心（合肥）

§ 2.5 不指定根时构造DFS生成树

算法2.2和2.3构造连通网络的生成树时，必需存在一个特殊的结点作为启动者(Leader)。当这样的特殊结点不存在时，如何构造网络的一棵生成树？但本节算法须假定：各结点的标识符唯一，不妨设是自然数，§ 3.2仍需此假定。

不指定根构造DFS生成树，和后面的领导者选举问题一样，都是破对称问题。


1. 基本思想

- 每个结点均可自发唤醒，试图构造一棵以自己为根的DFS生成树。若两棵DFS树试图链接同一节点(未必同时)时，该节点将加入根的id较大的DFS树。
- 为了实现上述思想，须做：
 - 每个结点设置一个leader变量，其初值为0，当 P_i 唤醒自己时， $leader_i = id_i$ ；


§ 2.5 不指定根时构造DFS生成树

- 当一结点自发唤醒时，它将自己的 $\text{id}(\text{leader})$ 发送给某一邻居；
- 当一结点 P_i 收到来自邻居 P_j 的标识符 y 时， P_i 比较 y 和 leader_i ：

①若 $y > \text{leader}_i$ ，则 y 可能是具有最大标识符结点的DFS子树的标记。因此，将 leader_i 置为 y ，并令 P_j 是 P_i 的双亲。从 P_i 开始继续生成标记为 y 的DFS树。Note：要修改原 P_i 所在的DFS子树中所有结点的 leader 。



§ 2.5 不指定根时构造DFS生成树



- ② 若 $y < \text{leader}_i$ ，则标记为 y 的DFS树中最大 $\text{id}(y)$ 小于目前所看到的最大标识符。此时无须发送msg，停止构造标记为 y 的DFS。等待最终某个更大的id的leader消息到达标记为 y 的树中结点时，再将该节点连接到树中。(至少标记为 leader_i 的msg会到达标记为 y 的树)
- ③ 若 $y = \text{leader}_i$ ，则 P_i 已属于标记 y 的DFS树中。

§ 2.5 不指定根时构造DFS生成树

2. 算法

Alg2.4 构造生成树，不指定根

Code for Processor P_i $0 \leq i \leq n-1$

Var parent: init nil;

 leader: init 0;

 children: int ϕ ;

 unexplored: init all neighbors of P_i ;

1: upon receiving no msg: //wake up spontaneously

2: if parent = nil then {

 //若非空，则 P_i 在某子树上，则 P_i 失去竞选机会

3: leader := id; parent := i; //试图以自己为根构造树

4: $P_j \in \text{unexplored}$;

5: 将 P_j 从unexplored中删去;

6: send <leader> to p_j ;

 }

§ 2.5 不指定根时构造DFS生成树

想像：有 m 个人竞选领袖， id 是他自身的素质分，不想竞争人的 id 不参与比较。

竞争规则：将自己的 id (如讲演片)传递给一个熟悉的人，由他再传给另一人(一次只能送一人。)

7: upon receiving $\langle \text{new-id} \rangle$ from neighbor P_j :

8: if leader $\langle \text{new-id} \rangle$ then { //将 P_i 所在树合并到 P_j 所在树中

9: leader := new-id; parent := j;

//令 P_i 的双亲为 P_j ，可能是修改，而非对 nil 赋值

//并不一定能停止较差的竞选者传播msg

10: unexplored := all the neighbors of P_i except P_j ;

//重置未访问的邻居集

11: if unexplored $\neq \emptyset$ then {

//因为new-id大，使原 P_i 所在DFS树修改各自id

12: $P_k \in \text{unexplored}$;

13: 将 P_k 从unexplored中删去;

§ 2.5 不指定根时构造DFS生成树

```
14:    send <leader> to  $P_k$ ;  
15:  }else send <parent> to parent; // unexplored =  $\phi$   
    }else // leader  $\geq$  new-id  
16:  if leader=new-id then send <already> to  $P_j$ ;  
    //表示自己已经传出过此录像带，无需重传。已在同一树中  
    //若leader>new-id，则new-id所在DFS停止构造  
    //以前收到的竞选者优于new-id，不传送，使之停止传播。  
  
17: upon receiving <parent> or <already> from neighbor  $P_j$ :  
18:  if received <parent> then add j to children;  
19:  if unexplored =  $\phi$  then { //无尚未访问的邻居  
20:    if parent  $\neq$  i then send <parent> to parent //返回  
21:    else terminates as root of the DFS tree; //根终止  
22:  }else { //有尚未访问的邻居
```

§ 2.5 不指定根时构造DFS生成树

```
23:    $\forall_k \in \text{unexplored};$   
24:   将 $P_k$ 从 $\text{unexplored}$ 中删去;  
25:   send <leader> to  $P_k$ ;  
   }
```

3. 分析:

- 只有生成树的根显式地终止, 其它结点没有终止, 始终在等待msg。但可修改此算法, 使用Alg2.1从根结点发送终止msg

- 正确性

该算法比前面的算法更复杂, 这里只给出粗略的证明。

设 P_m 是所有自发唤醒结点中标识符最大者, 其标识符为 id_m 。消息 id_m 总是被传播, 而一旦一个结点收到 id_m , 则该节点(P_m 除外)上所有msgs被忽略。因为消息 id_m 的处理和Alg2.3求DFS树一致, 因此产生的parent和children变量的设置是正确的。因此有:

§ 2.5 不指定根时构造DFS生成树

Lemma2.12 设 P_m 是所有自发唤醒结点中具有最大标识符的结点。在异步模型的每次容许执行里，算法2.4构造根为 P_m 的一棵DFS树。

Note: 因为在容许执行中，网络里的所有自发唤醒结点中最大标识符结点最终会自发启动，故建立的DFS树的根是 P_m

可通过广播算法从 P_m 发出终止msg，即使不广播，所有非 P_m 结点最终也会因为收到 P_m 的标识符而停止。因此，不可能构造一棵根不是 P_m 的生成树。

Lemma2.13 在异步模型的每个容许执行里，只有一个处理器终止作为一生成树的根。

§ 2.5 不指定根时构造DFS生成树

— 复杂性

定理：对于一个具有 m 条边和 n 个节点的网络，自发启动的节点共有 p 个，其中ID值最大者的启动时间为 t ，则算法的消息复杂度为 $O(pn^2)$ ，时间复杂度为 $O(t+m)$ 。

消息复杂性：简单地分析，最坏情况下，每个处理器均试图以自己为根构造一棵DFS树。因此，Alg2.4的msg复杂性至多是Alg2.3的 n 倍： $O(m*n)$

时间复杂性：类似于Alg2.3的msg复杂性 $O(m)$ 。

§ 2.5 不指定根时构造DFS生成树

Ex.

- 2.1 分析在同步和异步模型下，convergecast算法的时间复杂性。
- 2.2 证明在引理2.6中，一个处理器在图G中是从 P_r 可达的，当且仅当它的parent变量曾被赋过值
- 2.3 证明Alg2.3构造一棵以 P_r 为根的DFS树。
- 2.4 证明Alg2.3的时间复杂性为 $O(m)$ 。
- 2.5 修改Alg2.3获得一新算法，使构造DFS树的时间复杂性为 $O(n)$ 。

补充

§ 2.6 小结

§ 补充 构造最小生成树

考虑每个信道都有权重，代表了信道的通信成本，这样最小生成树能够使得执行广播算法总开销最小。假设每个信道的权重都已存储在其两端的节点的局部内存中。

基本思想：

每个节点都有一个所属树的变量编号，用来判断两个节点是否属于一棵树。刚开始时，每个节点独立成一棵树，其ID值为树的编号，每棵树并发的搜索自己权值最小的出边，并把这些边加入到生成森林中，同时几棵树也就合并为一棵树，取其中编号较大的一个为合并之后的树的编号，更新树中各节点的树编号变量。直至所有的树都被合并为一棵树，此即为最小生成树。

§ 补充 构造最小生成树

可能出现的4个问题:

- 产生环

可以证明, 如果边的权值不相等,
那么图G只有唯一的最小生成树。



利用三元组, 将边表述为

$\{1, i, j\}, \{1, j, k\}, \{1, i, k\}$

当权相同时, 按照 i, j, k 的字典序来排序

假设 $i < j < k$, 则有 $\{1, i, j\} < \{1, i, k\} < \{1, j, k\}$

这样就可以避免出现环



§ 补充 构造最小生成树

可能出现的4个问题：

- 不平衡

由于异步系统的消息延迟，可能会出现不平衡构造树，从而导致更多的消息。

极端的例子：每次都是一个节点数目很多的树，去合并一个单节点的树，这样对于节点数目大的树来说，每次查找权最小的出边花去的代价太大。

解决办法：给每棵树设置一个level层变量，刚开始时，单节点树的level为0，如果一棵树的权值最小出边所连的另一棵树的level变量大于或等于自己的level变量，则两棵树通过这条边合并，否则等待。所合并的树的level取决于两棵树中level较大者，若两棵树level相同为L，则新合并的树的level=L+1。

(level的含义：好比游戏中的练级)

§ 补充 构造最小生成树

可能出现的4个问题:

- 错误判断出边

异步系统中,可能出现在判断一条边是否是出边时,边连接的两点已经处在一棵树当中了,但由于消息延迟导致树编号的更新消息还未传到,因而导致因为两节点的树编号不同而产生的错误。

解决方法:

在合并之前,树中节点按边的权值由小到大的顺序开始探测此边是否是出边,当确认某条边是出边之后便停止探测其他边,并将结果敛播给根节点,由根节点确定通过哪一条边进行合并。

当两棵树合并时,合并后的树的编号以及根节点取level值较大的那棵树的根和树编号。若level值相同,取树编号较大的树的根和树编号。然后由根执行广播操作,更新所有树编号和level值,并通知寻找权值最小的出边。

(确定 P_i 和 P_j 是否属于一棵树)

①如果 P_i 和 P_j 编号相同,则肯定属于一棵树;

②如果编号不同,但 P_j 的level和 P_i 一样大,则肯定不属于一棵树,因为每棵树在一层中不可能有两个树编号,且当 P_i 在寻找其权值最小的出边的时候,其树编号是最新的;

③如果 P_j 的树编号与 P_i 不同且 P_j 的层数严格小于 P_i ,那么节点 P_j 就延迟回答 P_i 直到他更新到其level值上升到至少和 P_i 一样大。

(可以证明,这个新增的延迟将不会构成节点间的死锁)

§ 补充 构造最小生成树

可能出现的4个问题:

- 存在干扰

不同层的邻接树同时寻找权值最小的出边有可能发生相互干扰。具体来说，当层低的树 T 合并到层高的树 T' ，而 T' 正在确定其权值最小出边时可能会发生此情况。

§ 补充 构造最小生成树

算法框架:

Code for Every Tree T

Begin

While (系统中的子树个数大于1) do

(1) 根节点广播ID(T)和level(T), 命令各节点寻找权值最小的边;

(2) 按权值由小到大顺序寻找权值最小的出边, 找到之后敛播给根节点;

(3) 根节点收到所有节点的权值最小出边后, 确定整棵树的最小出边e, 边e连接树T'。

/*level(T)≤level(T')*/

(4) $T'' = T \cup T' \cup e$

(5) if level(T')>level(T) then

(5.1) $ID(T'') \leftarrow ID(T')$

(5.2) $level(T'') \leftarrow level(T')$

else // level(T')=level(T)

(5.3) $ID(T'') \leftarrow \max\{ID(T), ID(T')\}$

(5.4) $level(T'') \leftarrow level(T'') + 1$

end if

end while

end

§ 补充 构造最小生成树

消息复杂度:

每个level为k的树中的节点数至少为 2^k , level最大为 $\log(n)$ (n为节点数)。因为每个节点都从边的权值从小到大开始探测此边是否是出边, 当确定某边是出边后就停止探测并广播给根节点, 直到根确认这条边是这棵树的最小边, 并进行合并操作, 并更新level值, 然后继续探测。

消息分两类: ①每个节点探测自己的一条边是否是出边而得到否认消息, 这些消息数目为 $O(m)$; ②每一层中在树T中各种消息的传递, 其消息数目为 $O(|T|)$, $|T|$ 表示树的

节点数, 此总数目为
$$\sum_{k=0}^{\log n} \sum_{\text{level}(T)=k} |T| \leq \sum_{k=0}^{\log n} n = O(n \log n)$$

故消息总数为 $O(m+n \log n)$

§ 补充 构造最小生成树

时间复杂度：

系统中所有节点，其所在的树的level值都变成k 时所需的时间为 $O(kn)$ ，又因为k的最大值为 $\log(n)$ ，所以总时间为 $O(n\log n)$ 。

§ 2.6 小结

Introduction to distributed alg

- 分类：
 - 单源alg：一个启动者。又称centralized alg。
 - 多源alg：任意进程(结点)子集均可可是启动者，又称decentralized alg
 - 启动者(initiator)：自发地执行局部算法，即由一内部事件激发其执行
 - 非启动者：由接收一个msg(外部事件)触发其执行局部进程。
- 复杂性：
 - Msg复杂性：msg总数目
 - Bit复杂性：发送msg中bit的总数目，当msg在发送过程中其长度随时间增长时

§ 2.6 小结

— 时间复杂性

① 一个分布式算法的时间复杂性是满足下述两个假定的一个计算所耗费的最大时间

T1: 一个进程在零时间内可计算任何有限数目的事件

T2: 一个msg的发送和接受之间的时间至多为1个时间单位

缺点:针对一算法的所有计算, 其结果可能是极不可能发生的计算。

② 一个分布式算法的**one-time**复杂性是满足下述假定的一个计算的最大时间

O1: 同T1

O2: 发送和接收一个msg之间的时间恰好是1个单位时间

缺点: 某些计算可能被忽略, 而其中可能有极其耗时的计算

§ 2.6 小结

表面上，1-time 复杂性至少等于时间复杂性，因为T2假定下的最坏时间不会高于O2假定下的时间。但事实并非如此，而往往O1和O2假定之下的1-time 复杂性是前一种时间复杂性的一个下界。

例如：在echo算法里1-time 复杂性是 $O(D)$ ，时间复杂性是 $\Theta(N)$ ，即使直径为1的网络。

③ 两种复杂性的折中： α -复杂性

假定每个msg延迟介于 α^{-1} 之间($\alpha \leq 1$ 常数)

对echo 算法 α 复杂性为 $O(\min(N, D/\alpha))$

④ 概率分析：msg延迟服从某种概率分布，由此可获得精确的时间复杂性度量

§ 2.6 小结

⑤ 基于msg chains的分析

任何计算中最长消息链的长度。

链上msgs: $m_1, m_2, \dots, m_k$ 序列中, m_i 因果关系领先于 m_{i+1} 。

- 先验知识: 邻居的id, 全局id等。链路FIFO假定等

下次继续！

第三章 环上选举算法

汪 炆

本章提纲

- Leader选举问题
- 匿名环
- 异步环
- 同步环

- 问题
在一组处理器中选出一个特殊结点作为 leader
- 用途
 - ① 简化处理器之间的协作；
有助于达到容错和节省资源。
例如，有了一个 leader，就易于实现广播算法
 - ② 代表了一类破对称问题。
例如，当死锁是由于处理器相互环形等待形成时，
可使用选举算法，找到一个 leader 并使之从环上删去，即可打破死锁。

§ 3.1 leader选举问题

Leader选举问题:

问题从具有同一状态的进程配置开始, 最终达到一种配置状态。每个处理器最终确定自己是否是一个leader, 但只有一个处理器确定自己是leader, 而其他处理器确定自己是non-leader。

算法的作用:

如果要执行一个分布式算法, 且没有一个优先的优选人做为算法的初始进程, 就要进行进程选举。(例如指定根的DFS树的生成问题)

§ 3.1 leader选举问题

选举算法的定义：

- (1) 每个处理器具有相同的局部算法；
- (2) 算法是分布式的，处理器的任意非空子集都能开始一次计算；
- (3) 每次计算中，算法达到终止配置。在每一可达的终止配置中，只有一个处理器处于领导人状态，其余均处于失败状态。（**此项有时可以弱化**）


一个算法解决了leader选举问题需满足(根据形式化模型)：

- ① 终止状态被划分为两类：选中和未选中状态。一旦一个处理器进入选中(或未选中)状态，则该处理器上的转换函数将只会将其变为相同的状态；
- ② 在每个容许执行里，只有一个处理器进入选中状态，其余处理器进入非选中(non-selected)状态。

本章只讨论系统的拓扑结构是环的情况。

§ 3.1 leader选举问题

- 环的形式化模型
对每个 i , $0 \leq i \leq n-1$,
 P_i 到 P_{i+1} 的边标号为1, 称为左(顺时针)
 P_i 到 P_{i-1} 的边标号为2, 称为右(逆时针)
这里的标号加减均是mod n 的



环网络之所以吸引了如此多的研究, 是因为它们的行为易于描述; 且从环网络推导出的下界, 可应用于具有任意拓扑结构的网络算法设计

§ 3.2 匿名环 (anonymous)

- 匿名算法：若环中处理器没有唯一的标识符，则环选举算法是匿名的。更形式化的描述：每个处理器在系统中具有相同的状态机，在这种算法里，msg接收者只能根据信道标号来区别。
- （一致性的）uniform算法：若算法不知道处理器数目，则算法称之为uniform，因为该算法对每个n值看上去是相同的。
- non-uniform算法：算法已知处理器数目n
- 形式化描述：在一个匿名、一致性的算法中，所有处理器只有一个状态机；在一个匿名、非一致性的算法中，对每个n值（处理器数目）都有单个状态机，但对不同规模有不同状态机，也就是说n可以在代码中显式表达。

§ 3.2 匿名环 (anonymous)

- 对于环系统，不存在匿名的选举算法。
为简单起见，我们只证明
非均匀（非一致性）算法：非均匀算法（ n 已知）
的不可能性 $\Rightarrow$ 均匀（ n 未知）算法的不可能性。
Ex3.1 证明同步环系统中不存在匿名的、一致性的
领导者选举算法。

同步算法：同步算法的不可能性 $\Rightarrow$ 异步算法的不可能性。（同步是异步的一种特例）

Ex3.2 证明异步环系统中不存在匿名的领导者选举算法。

§ 3.2 匿名环

- 同步算法的不可能性

在同步系统中，一个算法以轮的形式进行。每轮里所有待发送msg被传递，随后每个处理器进行一步计算。

一个处理器的初始状态包括在outbuf里的任何msg。这些消息在第一轮里被传递到某处理器的左和右邻居。

不可能性：

①在一个匿名环中，处理器间始终保持对称，若无某种初始的非对称(如，标识符唯一)，则不可能打破对称。在匿名环算法里，所有处理器开始于相同状态。

②因为他们执行同样的程序(即他们的状态机相同)，在每轮里各处理器均发送同样的msg，所以在每一轮里各处理器均接收同样的msg，改变状态亦相同。

因此，若选中一个处理器，则其他所有处理器亦被选中。因此，不可能有一个算法在环中选中单个处理器为leader。

§ 3.2 匿名环

假设 R 是大小为 $n>1$ 的环（非均匀）， A 是其上的一个匿名算法，它选中某处理器为 $leader$ 。因为环是同步的且只有一种初始配置，故在 R 上 A 只有唯一的合法执行。

- **Lemma 3.1** 在环 R 上算法 A 的容许执行里，对于每一轮 k ，所有处理器的状态在第 k 轮结束时是相同的。

Pf. 对 k 用归纳法

$K=0$ (第一轮之前)，因为处理器在开始时都处在相同的初始状态，故结论是显然的。

设引理对 $k-1$ 轮成立。因为在该轮里各处理器处在相同状态，他们都发送相同的消息 m_r 到右边，同样的消息 m_l 到左边，所以在第 k 轮里，每处理器均接收右边的 m_l ，左边的 m_r 。因此，所有处理器在第 k 轮里接收同样的消息，又因为它们均执行同样的程序，故第 k 轮它们均处于同样的状态。

§ 3.2 匿名环

上述引理蕴含着：若在某轮结束时，一个处理器宣布自己是leader(进入选中状态)，则其它处理器亦同样如此，这和A是一个leader选举算法的假定矛盾！因此证明：

- **Th3.2** 对于同步环上的leader选举，不存在非均匀的匿名算法。

+

+

同步环 → 异步环

非一致性 → 一致性算法

↓↓

对于环系统，不存在匿名的选举算法

§ 3.3 异步环

本节将讨论异步环上leader选举问题的msg复杂性上下界。

由Th3.2知，对环而言没有匿名的leader选举算法存在。因此以下均假定处理器均有唯一标识符。

当一个状态机(局部程序)和处理器 P_i 联系在一起时，其状态成分变量 id_i 被初始化为 P_i 的标识符的值，故各处理器的状态是有区别的。

- 环系统：通过指派一个处理器列表按顺时针(从最小标识符起)指定环。注意是通过 id 排列，不是通过 P_i 的下标 i 来排列($0 \leq i \leq n-1$)，假定 id_i 是 P_i 的标识符。
(因为下标 i 通常是不可获得的)

§ 3.3 异步环

- 在非匿名算法中，均匀（一致性）和非均匀（非一致性）的概念稍有不同
 - ① 均匀算法：每个标识符 id ，均有一个唯一的状态机，但与环大小 n 无关。而在匿名算法中，均匀则指所有处理器只有同一个状态。（不管环的规模如何，只要处理器分配了对应其标识符的唯一状态机，算法就是正确的。）
 - ② 非均匀算法：每个 n 和每个 id 均对应一个状态机，而在匿名非均匀算法中，每个 n 值对应一个状态机。（对每一个 n 和给定规模 n 的任意一个环，当算法中每个处理器具有对应其标识符的环规模的状态机时，算法是正确的。）

下面将讨论msg复杂性： $O(n^2) \rightarrow O(n \log n) \rightarrow \Omega(n \log n)$

 **下界**

§ 3.3.1 一个 $O(n^2)$ 算法


Le Lann、Chang和Roberts给出，LCR算法

- 基本思想
 - ① 每个处理器 P_i 发送一个msg(自己的标识符)到左邻居，然后等其右邻居的msg
 - ② 当它接收一个msg时，检验收到的 id_j ，若 $id_j > id_i$ ，则 P_i 转发 id_j 给左邻，否则没收 id_j (不转发)。

§ 3.3.1 一个 $O(n^2)$ 算法

- ③ 若某处理器收到一个含有自己标识符的msg，则它宣布自己是leader，并发送一个终止msg给左邻，然后终止。
- ④ 当一处理器收到一个终止msg时，向左邻转发此消息，然后作为non-leader终止。

因为算法不依赖于 n ，故它是均匀的。



i—表示id 单向

§ 3.3.1 一个 $O(n^2)$ 算法

Code for P_i

init var: asleep $\leftarrow$ true, id $\leftarrow$ I

Begin

While (receiving no message) do

(1) if asleep do

(1.1) asleep $\leftarrow$ false

(1.2) send <id> to left-neighbor

end if

End while

While (receiving <i> from right-neighbor) do

(1) if id < i then send <i> to left-neighbor

end if

(2) if id = i then

(2.1) send <Leader, i> to left-neighbor

(2.2) terminates as Leader

end if

End while

While (receiving <Leader, j> from right-neighbor) do

(1) send <Leader, j> to left-neighbor

(2) terminates as non-Leader

End while

end

§ 3.3.1 一个 $O(n^2)$ 算法

- 分析

- ① 正确性

在任何容许执行里，只有最大标识符 $id_{\max}$ 不被没收，故只有具有 $id_{\max}$ 的处理器接受自己的标识符并宣布是leader，其他处理器不会被选中，故算法正确。


- ② msg复杂性

在任何容许执行里，算法绝不会发送多于 $O(n^2)$ 个msgs，更进一步，该算法有一个容许执行发送 $O(n^2)$ 个msgs：

§ 3.3.1 一个 $O(n^2)$ 算法

考虑处理器标识符为 0, 1, ..., $n-1$ 构成的环, 其次序如右图:

在这种配置里, $\text{id}=i$ 的处理器 msg 恰好被发送 $i+1$ 次, 即发送到 $i-1, i-2, \dots, 1, 0$, 直到 $n-1$ 时没收。因此, msg 总数为:




$$n + \sum_{i=0}^{n-1} (i+1) = \theta(n^2) \quad // \text{前一项为终止msg}$$

§ 3.3.2 一个 $O(n \lg n)$ 算法

仍然是绕环发送id，但使用更聪明的方法。保证最大id在环上周游且返回。

- **k邻居**

一个处理器 P_i 的k邻居是一个处理器集合：该集合中的任一处理器与 P_i 在环上的距离至多是k，一个处理器的k-邻居集中恰用 $2k+1$ 个处理器。



$k=3$ ，共有7个结点

§ 3.3.2 一个 $O(n \lg n)$ 算法

- 基本思想

算法按阶段执行，在第 l 阶段一个处理器试图成为其 2^l -邻接的临时leader。只有那些在 l -th阶段成为临时领袖的处理器才能继续进行到 $(l+1)$ th阶段。因此， l 越大，剩下的处理器越少。直至最后一个阶段，整个环上只有一个处理器被选为leader。


- 具体实现

- ① phase0: 每个结点发送1个probe消息(其中包括自己的id)给两个1-邻居，若接收此msg的邻居的id大于消息中的id，则没收此msg；否则接收者发回一个reply msg。若一个结点从它的两个邻居收到回答msg reply，则该结点成为phase0里它的1-邻居的临时leader，此结点可继续进行phase1。

§ 3.3.2 一个 $O(n \lg n)$ 算法

② phase l : 在 $l-1$ 阶段中成为临时leader的处理器 P_i 发送带有自己id的probe消息至它的 2^l 邻居。若此msg中的id小于左右两个方向上的 2×2^l 个处理器中任一处理器的id, 则此msg被没收。若probe消息到达最后一个邻居而未被没收, 则最后一个处理器发送reply消息给 P_i , 若 P_i 从两个方向均接收到reply消息, 则它称为该阶段中 2^l 邻居的临时leader, 继续进入下一阶段。

③ 终止: 接收到自己的probe消息的结点终止算法而成为leader, 并发送一个终止msg到环上。



§ 3.3.2 一个 $O(n \lg n)$ 算法

④ 控制probe msg的转发和应答

probe消息中有三个域：<prob, id, l , hop>

id-标识符

l -阶段数

hop-跳步计数器：初值为0，结点转发probe消息时加1.

若一结点收到的probe消息时，hop值为 2^l ，则它是 2^l 邻居中最后一个处理器。若此时msg未被没收也不能向前转发，而应该是向后发回reply消息。

§ 3.3.2 一个 $O(n \lg n)$ 算法

- 算法: Alg3.1 异步leader选举

var asleep init true;

upon receiving no msg:

if asleep then{

 asleep:=false;//每个结点唤醒后不再进入此代码

 send<probe, id, 0, 0> to left and right;

}

upon receiving <probe, j, l, d> from left (resp, right):

 if(j=id) then //收到自己id终止, 省略发终止msg

 terminate as the leader;

 if(j>id) and (d<2^l) then //向前转发probe msg

 send <probe, j, l, d+1> to right (resp, left)

§ 3.3.2 一个 $O(n \lg n)$ 算法

if($j > id$) and ($d \geq 2^l$) then //到达最后一个邻居仍未没收

 send $\langle \text{reply}, j, l \rangle$ to left(resp, right) // 回答

//若 $j < id$, 则没收probe消息

upon receiving $\langle \text{reply}, j, l \rangle$ from left (resp, right):

 if $j \neq id$ then

 send $\langle \text{reply}, j, l \rangle$ to right (resp, left); //转发reply

 else // $j = id$ 时, P_i 已收到一个方向的回答msg

 if already received $\langle \text{reply}, j, l \rangle$ from right (resp, left)

 then //也收到另一方向发回的reply

 send $\langle \text{probe}, id, l+1, 0 \rangle$ to left and right;

 // P_i 是phase l 的临时leader, 继续下一阶段

§ 3.3.2 一个 $O(n \lg n)$ 算法

- 分析

① 正确性：因为具有最大id的处理器 probe 消息是不会被任何结点没收的，所以该处理器将作为 leader 终止算法；另一方面，没有其他 probe 消息能够周游整个环而不被吞没。因此，最大 id 的处理器是算法选中的唯一的 leader。

② msg 复杂性（最坏情况下）
在 phase l 里：

◆ 一个处理器启动的 msg 数目至多为： $4 * 2^l$

◆ 有多少个处理器是启动者呢？

- $l=0$ ，有 n 个启动者（最多）

- $l \geq 1$ ，在 $l-1$ 阶段结束时成为临时 leader 的节点均是启动者

§ 3.3.2 一个 $O(n \lg n)$ 算法


Lemma 3.3 对每个 $k \geq 1$, 在phase k 结束时, 临时leader数至多为 $n/(2^k+1)$.

pf: 若一结点 P_i 在 k 阶段结束时是一临时leader, 则在 P_i 的 2^k -邻居里每个结点的id均小于 P_i 的id。

在该阶段里, 距离最近的两个临时leader P_i 和 P_j 必满足:

P_i 的 2^k 邻居的左边恰好 P_j 的 2^k -邻居的右边, 即 P_i 和 P_j 之间有 2^k 个处理器。

因此, 在 phase k 里 临时leader的最大数目必是以上述方式分布的, 因为每 2^k+1 个结点至多有一个临时leader, 所以leader数至多是 $n/(2^k+1)$.



§ 3.3.2 一个 $O(n \lg n)$ 算法

Th3.4. 存在一个异步的leader选举算法，其msg复杂性为 $O(n \lg n)$.

Pf: 由lemma3.3知，知道phase $\lg(n-1)$ 时只剩下一个leader(最后的leader). msg总数:

$$4n + \sum_{l=0}^{\lg(n-1)} (4 \cdot 2^l) \frac{n}{2^{l-1} + 1} + n \leq 8n \lg n$$

i) phase $l=0$: msg数为 $4n$.

ii) 终止msgs: n .

Note: 双向通信. 该msg复杂性的常数因子不是最优的.

下次继续！

第三章 环上选举算法

汪 炆

§ 3.3.3 下界 $\Omega(n \lg n)$

现证明对于uniform算法，异步环里任何leader选举算法至少发送 $\Omega(n \lg n)$ 个msgs。

我们的下界证明是针对leader选举问题的一个变种：

- 选中的leader必定是环上具有最大id的处理器。
- 所有处理器必须知道被选中leader的id，即每处理器终止前，将选中leader的id写入一个特殊变量。

• 基本思想。

设A是一个能解上述leader选举变种问题的均匀算法，证明存在A的一个允许执行，其中发送了 $\Omega(n \lg n)$ 个msgs，证明采用构造法。

§ 3.3.3 下界 $\Omega(n \lg n)$

对于大小为 $n/2$ 的环构造算法的一个耗费执行(指msg的耗费), 然后将两个大小为 $n/2$ 的不同环粘贴在一起形成一个大小为 n 的环, 将两个较小环上的耗费执行组合在一起, 并迫使 $\theta(n)$ 个附加msg被接收。

- 调度: 前面定义过调度是执行中的事件序列, 下面给出能够被粘贴在一起的调度。

这种扩展依赖于算法是一致的且对各种规模的环以相同的方式执行

- Def3.1 开调度

设 σ 是一个特定环上算法A的一个调度, 若该环中存在一条边 e 使得在 σ 中, 边 e 的任意方向上均无msg传递, 则 σ 称为是open, e 是 σ 的一条开边。

§ 3.3.3 下界 $\Omega(n \lg n)$

Note: 开调度未必是容许的调度，即它可能是有限的事件序列，环上的处理器不一定是终止的。

直观上，既然处理器不知道环的大小，我们可将两个较小的开调度粘贴为一个较大环的开调度，其依据是：算法是均匀的。

为简单起见，不放设 n 为2的整数次幂。

Th3.5 对于每个 n 及每个标识符集合(大小为 n)，存在一个由这些标识符组成的环，该环有一个A的开调度，其中至少接收 $M(n)$ 个消息，这里：

$$\begin{cases} M(2) = 1 & n = 2 \\ M(n) = 2M(\frac{n}{2}) + \frac{1}{2}(\frac{n}{2} - 1) & n > 2 \end{cases}$$

§ 3.3.3 下界 $\Omega(n \lg n)$

显然递归方程的解为 $M(n) = \theta(n \lg n)$ ，他蕴含了异步环选举问题消息复杂度下界。下面用归纳法证明之，其中

┌ 引理3.6是归纳基础($n = 2^1$)

└ 引理3.7是归纳步骤($n = 2^i, i > 1$)

Lemma 3.6 对每个由两个标识符构成的集合，存在一个使用这两个标识符的环 R ， R 有 A 的一个开调度，其中至少有一个msg被接受。（归纳基础）

pf: 假定 R 有两个处理器 P_0 和 P_1 ，其标识符分别为 x 和 y ，不妨设 $x > y$.

§ 3.3.3 下界 $\Omega(n \lg n)$


设 α 是A的一个容许执行，因为A是正确的，在 α 中，最终 P_1 定将 P_0 的标识符写入其中。因此， α 中至少须接收一个msg，否则 P_1 不知道 P_0 的标识符为x.

设 σ 是 α 的调度的最短前缀：它包括第一个接受msg的事件。因为没有接收第一条msg的边是开的，因此 σ 中只有一个msg被接收且有一条开边，故引理成立。故 σ 是满足引理的开调度。

Lemma 3.7 选择 $n > 2$ ，假定对每个大小为 $n/2$ 标识符集合，存在一个使用这些标识符的环，它有A的一个开调度，其中至少接收 $M(n/2)$ 个msgs(归纳假设)，那么对于 n 个标识符的每个集合，存在一个使用这些标识符集的环，它有A的一个开调度，其中接收至少 $2M(n/2) + (n/2 - 1)/2$ 个msgs(归纳步骤)。

§ 3.3.3 下界 $\Omega(n \lg n)$

pf: 设 S 是 n 个标识符的集合, 将 S 划分为两个集合 S_1 和 S_2 , 每个大小为 $n/2$, 由假设分别存在一个使用 S_1 和 S_2 中标识符的环 R_1 和 R_2 , 它们分别有 A 的一个开调度 σ_1 和 σ_2 , 其中均至少接收 $M(n/2)$ 个msgs, 设 e_1 和 e_2 分别是 σ_1 和 σ_2 的开边, 不妨设邻接于 e_1 和 e_2 的处理器分别是 p_1, q_1 和 p_2, q_2 , 将 e_1, e_2 删去, 用 e_p 链接 p_1 和 p_2 , e_q 链接 q_1 和 q_2 , 即可将两个环 R_1 和 R_2 粘贴在一起形成环 R 。



现说明如何在 R 上构造一个 A 的开调度 σ , 其中至少有 $2M(n/2) + (n/2 - 1)/2$ 个msg被接收。其想法是先让每个较小环分别执行“耗费”的开调度。

§ 3.3.3 下界 $\Omega(n \lg n)$

1) $\sigma_1\sigma_2$ 构成R上A的一个开调度

考虑从R的初始配置开始发生的事件序列 σ_1 ，因为 R_1 中的处理器由这些事件并不能区别 R_1 是一个独立的环还是R的一个子环，它们执行 σ_1 恰像 R_1 是独立的那样。考虑环R上后续事件序列 σ_2 (与上类似)，因为没有msg在 e_p 和 e_q 上传递，故 R_2 中处理器在 σ_2 中亦不能区别 R_2 是独立环还是R的子环。

因此， $\sigma_1\sigma_2$ 是一个调度，其中至少有 $2M(n/2)$ 个msgs被接收。

2) 现说明如何通过连通 e_p 和 e_q (但不是二者)来迫使算法接收 $(n/2-1)/2$ 个附加的msgs。

考虑每个形式为 $\sigma_1\sigma_2\sigma_3$ 的有限调度，因为 $\sigma_1\sigma_2$ 中 e_p 和 e_q 均为开的，若 σ_3 中存在一边上至少有 $(n/2-1)/2$ 个msg被接收，则 $\sigma_1\sigma_2\sigma_3$ 是要找的开调度，引理被证。

假设没有这样的调度，那么存在某个调度 $\sigma_1\sigma_2\sigma_3$ ，它导致相应执行中的一个“静止”配置。(配置：由全体结点状态构成)

一个处理器状态是“静止”的：若从该状态开始的计算事件序列中不send消息，即处理器接收一个msg之前不发送另一msg（即处理器的内部事件不引发send动作）

§ 3.3.3 下界 $\Omega(n \lg n)$

一个配置是“静止”的(关于 e_p 和 e_q): 若除开边 e_p 和 e_q 外, 没有msg处在传递之中, 每个处理器均为静止状态。

不失一般性, 假设 R 中最大id的处理器是在子环 R_1 中, 因为没有msg从 R_1 传到 R_2 中, R_2 中的处理器不知道leader的id, 因此 R_2 里没有处理器能够在 $\sigma_1\sigma_2\sigma_3$ 结束时终止。(在 $\sigma_1\sigma_2\sigma_3$ 结束时, R_2 里无结点终止)

我们断定在每个扩展 $\sigma_1\sigma_2\sigma_3$ 的容许调度里, 子环 R_2 里的每个处理器在终止前必须接收至少一个附加msg, 因为 R_2 里每一处理器只有接收来自 R_1 的msg才知道leader的id。

上述讨论清楚地蕴含在环 R 上必须接收 $\Omega(n/2)$ 个msg, 但因为 e_p 和 e_q 是连通的, 故调度未必是开的, 即两边上均可能传递msg。

但若能说明 e_p 或 e_q 只有一个连通的, 迫使通过它接收 $\Omega(n/2)$ 个msg, 即可证明。这就是下一断言。

§ 3.3.3 下界 $\Omega(n \lg n)$

Claim 3.8 存在一个有限的调度片断 σ_4 ，其中有 $(n/2-1)/2$ 个 msgs 被接收， $\sigma_1\sigma_2\sigma_3\sigma_4$ 是一个开调度，其中 e_p 或 e_q 是开的。

Pf: 设 $\sigma_1\sigma_2\sigma_3$ 是一个容许调度，因此所有的 msgs 在 e_p 和 e_q 上传递，所有结点终止。

因为 R_2 里，每个节点在终止前必须收到一个 msg，故在 A 终止前在 R_2 里至少接收 $n/2$ 个 msgs，设 σ_4 是 R_2 里接收 $n/2-1$ 个 msg 的最短前缀。

考虑 R_2 里在 σ_4 中所有已接收 msg 的结点，因为我们是从一个静止位置开始的，其中只有在 e_p 和 e_q 上有 msg 在传输，故这些结点形成了两个连续的结点集合 P 和 Q ：

P 包含由于连通 e_p 而被唤醒的结点，故 P 至少包含 p_1 和 p_2

Q 包含由于连通 e_q 而被唤醒的结点，故 Q 至少包含 q_1 和 q_2

§ 3.3.3 下界 $\Omega(n \lg n)$

因为 $P \cup Q$ 中至少包含 $n/2-1$ 个结点（由 σ_4 决定），且又因它们中的结点是连续的，所以 $P \cap Q = \Phi$ 。P 和 Q 这两个集合中有一个集合，其中的结点至少接收 $(n/2-1)/2$ 个msg,(因为 P , Q 中的结点共接收 $n/2-1$ 个msg),不失一般性，假定这样的集合是 P 。

设 σ_4 是 σ_4 的子序列， σ_4 只包含在 P 中结点上发生的事件，因为 e_4 里 P 中节点和Q中结点之间没有通信，故 $\sigma_1 \sigma_2 \sigma_3 \sigma_4$ 是一个调度。

因为 σ_4 里至少有 $(n/2-1)/2$ 各msg被接收，且由构造可知， e_q 上无msg传递，因此 $\sigma_1 \sigma_2 \sigma_3 \sigma_4$ 是一个满足要求的开调度。

§ 3.3.3 下界 $\Omega(n \lg n)$

总结：Th3.5的证明可分为3步：

- 1) 在 R1和R2 上构造2个独立的调度，每个接收 $2M(n/2)$ 各msg: $\sigma_1 \sigma_2$
 - 2) 强迫环进入一个静止配置: $\sigma_1 \sigma_2 \sigma_3$ （主要由调度片断 σ_3 ）
 - 3) 强迫 $(n/2-1)/2$ 个附加msg被接收，并保持ep或eq是开的: $\sigma_1 \sigma_2 \sigma_3 \sigma_4$ 。
- 因此我们已构造了一个开调度，其中至少有 $2M(n/2) + (n/2-1)/2$ 个msg被接收。

§ 3.4 同步环

研究同步环上leader选举问题的上、下界。

- 上界： 提出两个msg复杂性为 $O(n)$ 的算法，显然，这样的算法的msg复杂性是最优的。但运行时间并非只与环大小 n 有关，还与算法使用的非普通的id相关。(与id值相关)
- 下界： 讨论
 - 1) 只基于标识符之间比较的算法
 - 2) 时间受限（即若干轮内终止，轮数只依赖于环大小,不依赖于id值）的算法当算法受限于上述两个条件时，至少需要 $\Omega(n \lg n)$ 个msgs.

§ 3.4.1 上界 $O(n)$

上节已证明在异步环上leader选举问题的msg复杂度下界为 $\Omega(n \lg n)$ ，其算法的关键是msg延迟是任意长的。

因为同步环上

- 1) msg延迟是确定的，故同步模型是否有较好的结果呢？
- 2) 获取info不仅来自于接收msg,在某轮里的内附件也能获取info

本节提出两个算法，msg复杂性上界为 $O(n)$,针对单向环，但是用于双向环

- 1) 非均匀的：要求环中所有的结点开始于同一轮，标准的同步模型 (需知道n)
- 2) 均匀的： 结点可开始于不同轮，弱同步模型 (无需知道n)

§ 3.4.1 上界 $O(n)$

Non-uniform Alg

■ 基本特征

选择环中最小id（各id互不相同）的结点作为leader，按Phase运行，每个阶段由n个轮组成。在Phase i ($i \geq 0$)，若存在一个id为i的结点，则该结点为leader，并终止算法，因此，最小id的结点被选为leader

显然，Phase数目取决于n个节点的标志符的取值。

■ 具体实现

Phase i 包括轮： $n \cdot i + 1, n \cdot i + 2, \dots, n \cdot i + n$

在第 i 阶段开始，若一个结点的id是 i ，且它尚未终止，则该节点绕环发送一个msg后作为一个leader终止；若一结点的id不是 i ，且它收到一个msg，则它转发此msg后作为non-leader终止。

§ 3.4.1 上界 $O(n)$

■ 分析

正确性：显然，只有最小的标志符被选中作为leader

Msg复杂性：恰有 n 个msg被发送，故复杂性为 $O(n)$ 。注意这 n 个msg均是在找到leader的那个Phase里发送的。

时间复杂性

依赖于环大小和环上最小标志符，不妨设环大小为 n ，最小标识符为 i ，则算法执行轮数为： $n \cdot (i+1)$ ，不妨设 $i \geq 0$ // 运行时间与环大小及标识符取值相关

缺点

必须知道环大小 n 和同步开始，下面算法克服了这些限制

①为什么id为 i 的结点要在phase i 发msg

∵各结点互不知道彼此的id值

∴只能在第 i phase，结点($id=i$)发自己的id

②为什么每个phase要 n 轮

§ 3.4.1 上界 $O(n)$

Uniform Alg

- 特点：①无须知道环大小，②弱同步模型

一个处理器可以在任意轮里自发地唤醒自己，也可以是收到另一个处理器的msg后被唤醒

- 基本思想

- ① 源于不同节点的msg以不同的速度转发

源于id为i的节点的msg，在每一个接收该msg的节点沿顺时针转发到下一个处理器之前，被延迟 $2^i - 1$ 轮

- ② 为克服非同时启动，须加一个基本的唤醒阶段，其中每个自发唤醒的结点绕环发送一个唤醒msg，该msg转发时无延迟

- ③ 若一个结点在算法启动前收到一个唤醒msg，则该结点不参与算法，只是扮演一个relay(转发)角色：即转发或没收msg

§ 3.4.1 上界 $O(n)$

■ 要点：在基本阶段之后，选举leader是在参与结点集中进行的，即只有自发唤醒的结点才有可能当选为leader。

■ 具体实现

① 唤醒：由一个结点发出的唤醒msg包含该结点的id，该msg以每轮一边的正常速率周游，那些接收到唤醒msg之前未启动的结点均被删除(不参与选举)

② 延迟：当来自一个id为i的节点的msg到达一个醒着的节点时，该msg以 2^i 速率周游，即每个收到该msg的节点将其延迟 2^{i-1} 轮后再转发。

Note: 一个msg到达一个醒着的节点之后，它要到达的所有节点均是醒着的。一个msg在被一个醒着的节点接收之前是处在1st阶段(唤醒msg，非延迟)，在到达一个醒着的节点之后，它就处于2nd阶段，并以 2^i 速率转发(非唤醒msg，延迟)

§ 3.4.1 上界 $O(n)$

③ 没收规则

- a) 一个参与的节点收到一个msg时，若该msg里的id大于当前已看到的最小(包括自己)的id，则没收该msg；
- b) 一个转发的节点收到一个msg时，若该msg里的id大于当前已看到的最小(不包括自己)的id，则没收该msg。

§ 3.4.1 上界 $O(n)$

■ 算法 Alg3.2 同步leader选举

```
var waiting : init  $\Phi$ ;
```

```
    asleep : init true; //加上relay更好 ?    : init false;
```

```
1: 设R是计算事件中接收msg的集合
```

```
2:  $s := \Phi$ ; // the msg to be sent
```

```
3: if asleep then {
```

```
4:   asleep:=false;
```

```
5:   if  $R = \Phi$  then { //  $p_i$ 未收到过msg, 属于自发唤醒
```

```
6:     min:=id; //参与选举
```

```
7:      $s := s + \{<id>\}$ ; // 准备发送
```

```
   }else{ //已收到过msg, 但此前未启动, 被唤醒故 $P_i$ 不参与
```

```
8:     min:= $\infty$ ; //选举, 置min为 $\infty$ , 使其变为relay结点
```

```
    // relay:=true; ?
```

```
  }
```

```
}
```

§ 3.4.1 上界 $O(n)$

```
9:  for each <m> in R do { // 处理完收到的m后相当于从R中删去
10:    if m < min then { // 收到的id较小时通过
11:      become not elected; // Pi未被选中
        //可用relay控制使转发节点不延迟?
12:      将<m>加入waiting且记住m何时加入; //m加入延迟转发
13:      min:=m;
        } // if m > min then it is swallowed
14:    if m=id then become elected; // Pi被选中
        } //endfor
15:  for each <m> in waiting do
16:    if <m> 是在 $2^m-1$ 轮之前接收的 then
17:      将<m>从waiting中删去并加入S
18:  send S to left;
```

§ 3.4.1 上界 $O(n)$

- 分析

下面证明，在第1个结点被唤醒之后的 n 轮，只剩下第二阶段的msg，只有参与的结点才有可能被选中。

(1) 正确性

对 $\forall i \in [0, n-1]$ ，设 id_i 是结点 p_i 的标识符， $\langle id_i \rangle$ 是源于 p_i 的msg

Lemma 3.9 在参与的节点中，只有最小id的节点才能收回自己的id。

pf: ①选中：设 p_i 是参与者中具有最小id的结点 (**Note:** 至少有1个结点须参与算法)，显然没有节点(无论是否参与)能没收 $\langle id_i \rangle$ ；另一方面，因为在每个节点上 $\langle id_i \rangle$ 至多延迟 2^{id_i} 轮，故 p_i 最终收回自己的id；
②唯一：除 p_i 外，没有别的节点 $p_j (j \neq i)$ 也收回自己的 $\langle id_j \rangle$ 。

若 p_j 收回自己的 $\langle id_j \rangle$ ，则 $\langle id_j \rangle$ 已通过 p_i 及其它所有结点，但 $id_i < id_j$ ，因为 p_i 是一个参与者，它将不会转发 id_j ，矛盾！

该引理蕴含着：恰有一个结点收回自己的msg，故它是唯一声明自己是leader的结点，即算法正确。

§ 3.4.1 上界 $O(n)$

(2) msg复杂性

在算法的一次容许执行里，发送的msg可分为三个类型：

第一类：第一阶段的msg(唤醒msg)

第二类：最终leader的msg进入自己的第二阶段之前发送的
第二阶段msg(其它结点发出的)

第三类：最终leader的msg进入自己的第二阶段之后发送的
第二阶段msg(包括leader发出的)

Note: 一个msg发送时，一开始是作为唤醒msg(非延迟)，当它到达的结点已唤醒时，msg就变为非唤醒msg(第二阶段，延迟msg)

§ 3.4.1 上界 $O(n)$

① 第一类msg总数(第一阶段的msg)


Lemma 3.10 第一类msg总数至多为 n

pf: 只要说明每个节点在第一阶段至多转发一个msg即可。

反证: 假设某结点 p_i 在其第一阶段转发两个msgs: 一个来自 p_j 的 $\langle id_j \rangle$, 一个来自 p_k 的 $\langle id_k \rangle$ 。不失一般性, p_j 比 p_k 更靠近 p_i (沿顺时针方向)。因此, $\langle id_k \rangle$ 到达 p_i 之前先到达 p_j 。

若 $\langle id_k \rangle$ 是在 p_j 自发唤醒及发送 $\langle id_j \rangle$ 之后到达 p_j , 则 $\langle id_k \rangle$ 以 2^{id_k} 速度作为第二阶段msg继续前进; 否则, p_j 不是参与结点, 不会发送 $\langle id_j \rangle$ 。

因此, 或者 $\langle id_k \rangle$ 是作为第二阶段msg到达 p_i , 或者 $\langle id_j \rangle$ 未被发送, 即: p_i 最多收到一个第一阶段msg, 矛盾!



§ 3.4.1 上界 $O(n)$

② 第二类msg总数 (最终leader发出的msg进入自己的第二阶段之前发送的第二阶段msg)

为了求得第二类msg总数，首先说明第一个开始执行算法的结点启动之后的 n 轮，所有的msg均在自己的第二阶段中。

设 p_i 是最早开始执行算法的结点中的某一个，其启动轮数为 r 。

Lemma 3.11 若 p_j 距离 p_i 为 k (顺时针)，则 p_j 接收的第一阶段的msg不迟于第 $r+k$ 轮。

§ 3.4.1 上界 $O(n)$

pf: 对距离 k 归纳


基础: $k=1$, 因为 p_i 的左邻居在第 $r+1$ 轮接收到 p_i 的msg, 故引理成立。

假设: 设距离 p_i 为 $k-1$ 的结点接收第一阶段
的msg不迟于 $r+k-1$ 轮。

步骤

若距离 p_i 为 $k-1$ 的结点 p_t (顺时针)
接收第一阶段msg时已被唤醒, 则
 p_t 已发送了第一阶段msg给邻居 p_j ;

否则, p_t 至迟在第 $r+k$ 轮转发第
一阶段msg到 p_j 。




§ 3.4.1 上界 $O(n)$

Lemma 3.12 第二类msg总数至多为 n

pf: 由引理3.10可知, 在每边上至多只发送1个第一阶段的msg, 又因为到第 $r+n$ 轮, 每边上已发送了一个第一阶段msg, 故到第 $r+n$ 轮之后, 已无第一阶段的msg被发送。

Note: 第一阶段msg是唤醒msg, 即若在 p_i (第一个启动结点)发出唤醒msg绕环一周回到 p_i 之前已有某结点启动, 则该启动结点的msg在未收到 p_i 的msg之前已将自己的唤醒msg向前转发。

§ 3.4.1 上界 $O(n)$



i) 第二类msg经历的总轮数:

由引理3.11知，最终的leader(不一定是首个启动者)的msg进入自己的第二阶段的时刻是：算法的第1个msg被发送之后至多 n 轮(前 n 轮)，故第二类被发送的msg必是在首个启动结点的 n 轮之中。

ii) 在这 n 轮中，第二类msg数目。即第二类msg是算法启动的前 n 轮中非唤醒msg的总数：

§ 3.4.1 上界 $O(n)$

因为msg<i>在其第二阶段中，转发前须延迟 2^i-1 轮，所以若<i>是第二类msg，则它至多被发送 $n/2^i$ 次。

因为较小id被转发的次数较多，故可这样构造以使msg数目最大：

所有结点均参与选举，标识符均尽可能小：0, 1, ..., n-1（顺时针排列）。显然，因为id=0是leader，第二类msg中不包括leader的msg，故第二类msg总数至多是：

$$\sum_{i=1}^{n-1} \frac{n}{2^i} \leq n$$

§ 3.4.1 上界 $O(n)$

③第三类msg总数

(即: leader进入自己的第二阶段之后, 所有非唤醒msg)

Lemma 3.13 在 $\langle id_i \rangle$ 返回 p_i 之后, 没有msg被转发

pf:

设 p_i 是具有最小id的结点, 当一结点转发 $\langle id_i \rangle$ 之后, 该结点将不再会转发其它msg。

若 $\langle id_i \rangle$ 返回 p_i , 则所有结点均已转发过 $\langle id_i \rangle$, 故再也没有其它msg被转发。

§ 3.4.1 上界 $O(n)$

Lemma 3.14 第三类msg总数至多为 $2n$

pf: 设 p_i 是最终的leader, p_j 是某个参与的结点, 由引理3.9知, $id_i < id_j$, 由引理3.13知, 在 p_i 收回自己的 id_i 之后, 环上不再有msg在传输。

i) 第三类msg经历的总轮数: 因为在每个结点上, $\langle id_i \rangle$ 至多延迟 2^{id_i} 轮(在唤醒结点上不延迟, 故为至多), 所以 $\langle id_i \rangle$ 返回 p_i 至多经过 $n \cdot 2^{id_i}$ 轮。

ii) 在这 $n \cdot 2^{id_i}$ 轮中, 第三类msg数目: 第三类msg是在这 $n \cdot 2^{id_i}$ 轮中发送的所有第二阶段msg(非唤醒msg)。在这 $n \cdot 2^{id_i}$ 轮中, 一个非唤醒的msg $\langle id_j \rangle$ 被转发的次数至多为:

$$\frac{1}{2^{id_j}} \cdot n \cdot 2^{id_i} = n \cdot 2^{id_i - id_j}$$

§ 3.4.1 上界 $O(n)$

故有：第三类msg总数至多为(包括leader)

$$\sum_{j=0}^{n-1} \frac{n}{2^{id_j - id_i}}$$

基于引理3.12的同样理由，当所有结点参与选举，及标识符为 $0, 1, \dots, n-1$ 时有：

$$\sum_{j=0}^{n-1} \frac{n}{2^{id_j - id_i}} \leq \sum_{k=0}^{n-1} \frac{n}{2^k} \leq 2n$$

这里， $\forall id_i \in [0, n-1]$

Th3.15 存在一个同步的leader选举算法，其msg复杂度至多为 $4n$

pf: 由引理3.10, 3.12及3.14立即可得。

§ 3.4.1 上界 $O(n)$

(3) 时间复杂度

由引理3.13知，当leader接收到自己的id时，计算终止。
这发生在第一个启动算法的节点之后的 $O(n \cdot 2^i)$ 轮，其中 i
是leader的标识符。// 当 $i=0$ 时，为 $O(n)$ 轮
//运行时间与环大小及标识符取值相关

(4) 思考

为何非唤醒msg要延迟 $2^i - 1$ 轮？

如何修改算法3.2来改善时间复杂性？

第三章 环上选举算法

汪 炆

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

上节中的两个算法在同步环上最坏的msg复杂度为 $O(n)$ ，但两算法的缺陷为：

- ① 它们用一种非同寻常的方式使用id，即id决定msg延迟多长；
- ② 在每个容许的执行中，执行轮数依赖于id，而id相对于n而言可能是巨大的。(更主要的)

本节将说明：

时间复杂度会表现很差

- ① 这些性质对于基于消息的有效算法而言是固有的；
- ② 若一个算法中的标识符仅用于比较，则它需要 $\Omega(n \lg n)$ 个msgs；
- ③ 若一个算法中，限制轮数的上界，但独立于id，则它的msg复杂度亦为 $\Omega(n \lg n)$ 。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

同步的下界不可能从异步的下界导出

因为上节中的算法表明：同步模型中的附加假定是必不可少的。

同步的下界对于非均匀和均匀算法均成立，但异步的下界只对均匀算法成立。

但是从同步导出的异步结果是正确的，并且提供了一个非均匀算法的异步下界。

**异步通信模型中领导者选举问题
所需的消息数下界为 $\Omega(n \lg n)$ 且
算法不依赖于比较的或者限时的**

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

基于比较的算法的概念和定义

为了得到下界，假定所有处理器在同一轮开始执行
一个环是由结点表按顺时针方向指定的，结点表开始于最小标识符。

在同步模型里，算法的容许执行完全由初始配置定义，这是因为msg延迟及节点步骤的相对次序均无选择的可能。

系统的初始配置完全由环决定，即由节点标识符列表按上述规则来决定。当算法的选择可以从上下文判断清楚时，则将由环R确定的容许执行表示为 $\text{exec}(R)$ 。

- 匹配：若环 R_1 上的结点 p_i 和 R_2 上的 p_j 在各自的环里具有相同的位置，则称 p_i 和 p_j 是匹配的，即：匹配的结点在各自环上距其最小id的结点的距离相同。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

- 基于比较的算法

直观上，若一个算法在两个相对次序相同的环上具有相同的行为，则该算法是基于比较的，形式定义：

- 1) 序相同 (order equivalent)

两个环 $x_0, x_1, \dots, x_{n-1}$ 和 $y_0, y_1, \dots, y_{n-1}$ 是(次)序等价的，若对每个 i 和 j ， $x_i < x_j$ 当且仅当 $y_i < y_j$ 。

回忆一下环上的结点 p_i 的 k -邻居是 $2k+1$ 个结点的序列(下标是 $\text{mod } n$)：

$$p_{i-k}, \dots, p_{i-1}, p_i, p_{i+1}, \dots, p_{i+k}$$

序等价的概念很容易扩展到 k -邻居集(所有索引按模 n 计算)

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

2) 何谓行为相同(similar)?

直观上：在序等价的环 R_1 和 R_2 上的容许执行里，发送同样的msg做同样的决策。但一般情况下，算法发送的msg包含结点的id，因此， R_1 上发送的msg通常不同于 R_2 上发送的msg。然而，我们关注的是msg模式和决策。所谓msg模式(patten)是指：msg是何时何地发送的，而不是指其内容。

➤ 节点在第k轮里行为相似：考虑两个执行 α_1 ， α_2 和两个结点 p_i ， p_j ，我们说 p_i 在 α_1 的第k轮里的行为相似于 p_j 在 α_2 的第k轮里的行为，若下述条件成立：

① p_i 在 α_1 的第k轮里发送一个msg到其左(右)邻居当且仅当 p_j 在 α_2 的第k轮里发送一个msg到其左(右)邻居；

② p_i 在 α_1 的第k轮里作为一个leader终止当且仅当 p_j 在 α_2 的第k轮里作为一个leader终止。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

- 节点的行为相似：若 α_1 里 p_i 和 α_2 里 p_j 在所有的 $k \geq 0$ 轮里均相似，则称 α_1 里 p_i 和 α_2 里 p_j 的行为相似。
- 算法的行为相似：指每对匹配的结点行为相似

3) 定义

Def 3.2 一个算法是基于比较的，若对于每对序等价的环 R_1 和 R_2 ，每对匹配的节点在 $\text{exec}(R_1)$ 和 $\text{exec}(R_2)$ 里的行为均相似。

该定义说明，若一算法只与环上标识符之间的相对次序相关，而与具体id值无关，则该算法一定只是基于标识符的比较

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

2. 基于比较算法的下界

设A是一个基于比较的leader选举算法，证明时考虑的环就序模式而言具有高度的对称性。即：环里存在很多次序等价的邻域。

直观上，只要两个节点有序等价的邻域，它们在A里就有同样的行为。我们将通过在一个高度对称的环里执行A来导出下界。讨论若一结点在某轮里发送一个msg，则具有序等价邻域的所有结点也在同一轮里发送一个msg。

证明的关键是：区别获得信息的轮及没有获得信息的轮。

Note: 在同步环里，一个结点即使没有收到一个msg也会获得info，例如，在 § 3.4.1 里的非均匀算法中，若第1到第n轮里未接收到msg，实际上蕴含着信息：环里没有标识符为0的结点。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

下面的证明关键是观察：

若某一轮 r 里不存在 msg 也对于结点 p_i 是有用的(指可获取 $info$)，则仅当存在一个次序等价的不同环，在该环上的第 r 轮里已接收一个 msg

例如，在非均匀算法中，若环上某一个结点的 id 为 0 ，则在第 $1, 2, \dots, n$ 轮里均已收到 msg 。但对于一个次序等价的不同环(设最小 $id > 0$)，则它在前 n 轮里就没有任何 msg 存在。但同样认为前 n 轮对每个结点是有用的。

因此，若某一轮在任何次序等价的环上均无 msg 发送，则该轮是无用的，而有用的轮被称为是主动的(active)。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

Def 3.3 在一个环 R 上的一个执行里，某轮 r 称为是**active**的，若该执行的第 r 轮里，某一个结点发送一个msg。当 R 是从上下文已知时，用 r_k 表示第 k 个**active**轮。

Note: 一旦环 R 确定，整个容许执行就确定(因为系统同步)

由于一个基于比较的算法在等价环上的行为相似，因此：

对于序等价的环 R_1 和 R_2 ，一轮在 $\text{exec}(R_1)$ 里是主动的当且仅当它在 $\text{exec}(R_2)$ 里也是主动的。

因为消息中的信息在 k 个轮里只能在环上通过 k 个结点，所以一个结点在 k 轮之后的状态只依赖于它的 k -邻居。

然而一个更强的性质是：一个结点在第 k 个主动轮之后的状态只依赖于它的 k -邻居。这实际上告诉我们：信息只有在主动轮里才能获得。这一点在下面的引理中给出形式证明。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

Note: 该引理无需结点匹配(否则立即从定义3.2中可得结论), 但要求它们的邻居是相同的(**identical**)。该引理要求假设两个环是次序等价的, 原因是要确保考虑中的两个执行有相同的主动轮集合, 因此 r_k 是良定义的。

Lemma 3.16 设 R_1 和 R_2 是次序等价的两个环, 设 P_i 和 P_j 分别是 R_1 和 R_2 上具有相同 k -邻居的两个节点, 那么在 $\text{exec}(R_1)$ 的第1至第 r_k 轮里 P_i 所经历的转换序列和在 $\text{exec}(R_2)$ 的第1至第 r_k 轮里 P_j 所经历的转换序列相同。

//该引理蕴含: 在 k 个主动轮结束时, P_i 和 P_j 的状态相同

Pf: 非形式地, 该证明说明在 k 个主动轮之后, 一个结点可能只知道距离自己至多为 k 的那些结点。形式证明对 k 进行归纳。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

- ① 归纳基础: $k=0$, 因为两个具有相同0-邻居的结点有同样的id, 故它们的状态相同;
- ② 归纳假设: 假定每两个具有相同 $(k-1)$ -邻居的结点在 $(k-1)$ 个主动轮之后有相同的状态;
- ③ 归纳步骤: 因为 P_i 和 P_j 有相同的 k -邻居, 故它们亦有相同的 $(k-1)$ -邻居。因此由归纳假设知, P_i 和 P_j 在第 $(k-1)$ 个主动轮之后处在相同的状态。又因 P_i 和 P_j 各自的邻居有同样的 $(k-1)$ -邻居, 故由归纳假设知, 它们各自的邻居在第 $(k-1)$ 个主动轮之后也处在相同的状态。

两个主动轮之间可能有非主动轮。

因为在第 $(k-1)$ 主动轮和第 k 主动轮之间的轮(若有的话)里, 没有结点接收任何msg, 故 P_i 和 P_j 及各自的邻居均处在相同的状态(Note: P_i 在非主动轮里可能改变它的状态, 但因为 P_j 有同样的转换函数, 故它有同样的状态转换)。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

在第 k 个主动轮里：

- i) 若 P_i 和 P_j 均不接收msg，则它们在该轮结束时有相同的状态；
- ii) 因为 P_i 和 P_j 的邻居状态相同，若 P_i 接收右(左)邻的一个msg，则 P_j 也接收右(左)邻同样的msg。因此，在第 k 个主动轮结束之后， P_i 和 P_j 均处于相同的状态。□

下一引理将上述论断从具有相同 k -邻居的结点扩展至具有次序等价的 k -邻居的结点。这依赖于事实：**A**是基于比较的。

更进一步要求环 R 是有空隙的，即环 R 中，每两个id之间均有 n 个未使用的标识符。形式地，在大小为 n 的环上，若对于每一个标识符 x ，标识符 $x-1$ 到 $x-n$ 均不在环上，则该环称为有空隙的。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

引理3.16定义在两环上(P_i 和 P_j 的 k -邻居相同), 引理3.17是定义在同一个环上(P_i 和 P_j 的 k -邻居序等价)



Lemma3.17 设 R 是有空隙环, P_i 和 P_j 是 R 上具有序等价 k -邻居的两个结点。则 P_i 和 P_j 在 $\text{exec}(R)$ 的第1到第 r_k 轮里有相似的行为。

Pf: 我们构造满足下述条件的另一个环 R' :

- ① R' 中的 P_j 和 R 中 P_i 的有相同的 k -邻居;
- ② R' 中的标识符唯一
- ③ R' 和 R 序等价, R' 中的 P_j 匹配于 R 中的 P_j 。

因为 R 是有空隙环, 故我们能够构造 R' 。例如, 对于 $k=1$ 和 $n=8$ 有:

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$



① P_i 的1-邻居60, 90, 75

P_j 的1-邻居60, 90, 75

② R' 中id唯一

③ R 次序:

R' 次序:

10, 30, 20, 40, 60, 90, 75, 100

60, 90, 75, 91, 92, 94, 93, 95

P_j 与10距离为1,

P_j 与60距离为1

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

(1) R 上的 P_i 和 R' 上的 P_j 的前 k 个主动轮行为相似

因为 R 上 P_i 和 R' 上 P_j 的 k -邻居相同，由引理3.16知， P_i 和 P_j 在各自的 $\text{exec}(R)$ 和 $\text{exec}(R')$ 的1到 r_k 轮里所经历的转换序列相同，所以 P_i 和 P_j 在各自的执行 $\text{exec}(R)$ 和 $\text{exec}(R')$ 的1至 r_k 轮里的行为相似。 $P_i(R) \sim P_j(R')$

(2) R 上的 P_j 和 R' 上的 P_i 的前 k 个主动轮行为相似

因为算法是基于比较的，由定义3.2在两个序等价的环中，每对匹配的结点在各自执行中有相似的行为。而 R 里的 P_j 和 R' 里的 P_i 是匹配的，故 R 里的 P_j 在 $\text{exec}(R)$ 的1至 r_k 轮里的行为相似于 R' 里的 P_i 在 $\text{exec}(R')$ 的第1至 r_k 轮里的行为。 $P_j(R') \sim P_i(R)$

(3) R 上两节点的 k -邻居序等价，则其行为在前 k 个主动轮里相似

由(1)和(2)得： R 里的 P_i 和 P_j 在 $\text{exec}(R)$ 的1至 r_k 轮里的行为相似。 $P_i(R) \sim P_j(R)$ □

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

Th3.18 对于每个 $n \geq 8$ (n 是2的幂), 存在一个大小为 n 的环 S_n , 使得对每个基于比较的同步leader选举算法 A , 在 S_n 上 A 的容许执行里发送msg的数目为 $\Omega(n \lg n)$

Pf: 固定算法 A 。证明分2步:

(1) 构造1个高度对称(很多结点有很多序等价的邻居)的环 S_n ;


(2) S_n 上发送的msg总数。 R_m^{rev}

(1) 构造 S_n (分2步构造)

① 定义大小为 n 的环 R_n^{rev} :

对 $\forall i \in [0, n-1]$, 设 P_i 的id为 $\text{rev}(i)$, 这里 $\text{rev}(i)$ 是 i 的二进制表示的逆序列。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$



例如，当 $n=8$ 时有：

若将环 R_8^{rev} 划分为长度为 j (j 是 2 的方幂) 的连续片断，则所有这些片断是序等价的 (Ex3.9)。

片断数： n / j .

例如，4,2,6,1和5,3,7,0序等价

2,6,1,5和3,7,0,4序等价

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

② 从 R_n^{rev} 构造 S_n

将 R_n^{rev} 上每个id乘以 $(n+1)$ 再加上 n 所获得的 S_n 是有空隙环。
但这种变化不改变片断的序等价性。

(2) S_n 上发送的msg总数（分3步）

①求 S_n 中序等价的邻居集数目（引理3.19）

②由①证明算法里主动轮数目下界（引理3.20）

③由①求每个主动轮里发送msg数目的下界(引理3.21)

由②和③的组合即可获得算法的msg复杂性下界。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

Lemma 3.19 对所有 $k < n/8$ 以及每个 S_n 的 k -邻居集 N ，在 S_n 中与 N 序等价的 k -邻居集的个数(包括 N 本身)大于 $\frac{n}{2(2k+1)}$

Pf: N 由 $2k+1$ 个id构成，设 j 是大于 $2k+1$ 的2的最小方幂。将 S_n 划分为 n/j 个连续片断，使某一片段包含 N 。

由 S_n 的构造可知，上述划分所得的所有片段均是序等价的。因此，至少有 n/j 个邻居集和 N 是序等价的。

设 $j=2^i$ ， $\because 2^{i-1} < 2k+1 < 2^i$ ， $\therefore j < 2(2k+1)$

故与 N 序等价的邻居集数目 $> \frac{n}{j} > \frac{n}{2(2k+1)}$

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

Lemma 3.20 在 $\text{exec}(S_n)$ 里，主动轮的数目至少为 $n/8$ 。

Pf: 设主动轮数目 $T < n/8$ 。//反证法

设 P_i 是 $\text{exec}(S_n)$ 里被选为 leader 的结点，由引理 3.19 知，与 P_i 的 T-邻居集序等价的 T-邻居集个数大于

$$\frac{n}{2(2T+1)} > \frac{n}{2(2n/8+1)} = \frac{2n}{n+4}$$

$$\because n \geq 8, \quad \therefore \frac{2n}{n+4} > 1$$

因此，存在某个异于 P_i 的结点 P_j ， P_j 的 T-邻居集与 P_i 的 T-邻居集是序等价的。由引理 3.17 知， P_j 与 P_i 的行为相似，故 P_j 亦被选为 leader，这与 A 是正确的算法矛盾！ $\square$

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

Lemma 3.21 对于 $\forall k \in [1, n/8]$, 在 $\text{exec}(S_n)$ 的第 k 个主动轮里, 至少有 $n / 2(2k+1)$ 个 msg 被发送。

Pf: 考虑第 k 个主动轮, 因它是主动的, 故该轮里至少有一结点发送一个 msg , 不妨设 P_i 发送一个 msg 。

由引理 3.19 知, 与 P_i 的 k -邻居集序等价的 k -邻居集个数大于 $n / 2(2k+1)$, 因为每个 k -邻居集中至少有一个结点 ($k \geq 1$), 这也就是说至少有 $n / 2(2k+1)$ 个结点, 其 k -邻居集与 P_i 的 k -邻居集序等价。

因此, 由引理 3.17 知, 这些结点与 P_i 的行为相似, 即它们在第 k 个主动轮中发送 msg 。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

由引理3.20和3.21知，在 $\text{exec}(S_n)$ 里发送msg的总数至少为：

$$\sum_{k=1}^{n/8} \frac{n}{2(2k+1)} \geq \frac{n}{6} \sum_{k=1}^{n/8} \frac{1}{k} > \frac{n}{6} \ln \frac{n}{8}$$

即 $\Omega(n \lg n)$ ，Th3.18得证。□

注意：为了使上述定理成立，要求标识符是取自集合 $\{0, 1, \dots, n^2 + 2n - 1\}$ 。//该集合的势为 $n^2 + 2n$ 。

原因是 S_n 中最小标识符为 n ，最大标识符为 $n^2 + n - 1 = (n+1) * \text{rev}(n-1) + n$ 。

但是证明所用到的引理3.17要求算法在比 S_n 中最小标识符小 n 及最大标识符大 n 的所有标识符上是可以比较的。//有空隙环。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

3.时间受限算法的下界

下面的定义中，算法的时间不依赖于id，仅受限于环大小n，即使id可能是无界的(因为它们来自于自然数集合)。

Def3.4 若对任意的n，当标识符取自于自然数集合时，在所有大小为n的环上同步算法A的最坏时间是有界的，则称A为时间有界(或时间受限time-bounded)

证明时间受限的同步算法的msg复杂性的下界的基本思想是：

将时间受限算法映射为基于比较的算法。从而获得时间受限算法的msg复杂性下界 $\Omega(n \lg n)$

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

因为基于比较的算法的msg下界是针对 n 为2的方幂讨论的(虽然对所有 n 值成立), 故下面仍针对 n 为2的方幂情况来讨论。

为了将时间受限算法映射到基于比较的算法, 需要定义在某一时间界限内算法的行为。

Def3.5 设 R_1 和 R_2 是任意两个大小为 n 的序等价的环, 若每对匹配的结点在 $\text{exec}(R_1)$ 和 $\text{exec}(R_2)$ 的第1至 t 轮里有相似的行为, 则同步算法 A 对于环大小为 n 的标识符集合 S 是基于 t -比较的。

直观上, S 上的一个基于 t -比较的算法可看做这样一个算法:

它的行为与一个基于比较的算法的前 t 轮的行为相同, 只要基于比较算法的标识符也选自于 S ;

若算法在 t 轮内终止, 则它和 S 上基于比较的算法在所有轮上完全相同。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

首先要说明每个时限受限算法的行为和一个输入子集上的基于比较算法的行为相同(假设输入集合足够大)。为此须用Ramsey定理的有限版本。非形式地，Ramsey定理陈述：

设有一个集合 S ，若用 t 种颜色中的一种对每个大小为 k 的子集着色，则我们能够找到某个大小为 l 的子集使得它的所有大小为 k 的子集有相同的颜色。若将着色看做等价类划分(若两个大小为 k 的子集着相同颜色，则它们属于同一等价类)，则该定理说明存在一个大小为 l 的集合，其所有大小为 k 的子集是同一个等价类。

稍后，我们将对匹配结点行为相似的环着上相同颜色。

例：面试老师分为 t 组，每组有 k 个老师；面试学生集 S 中任何人可以到任何一组面试，则能找到某个 l 值，这 l 个学生中所有 k 个人的子集是在同一房间面试的。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

Ramsey's Theorem (finite version)

对所有正整数 k , l 和 t , 存在一个整数 $f(k, l, t)$ 使得对每一个大小至少为 $f(k, l, t)$ 的集合 S , 对 S 的 k -元子集的每一个 t -着色, S 的某一个 l -元子集中所有 k -元子集具有同样的颜色($l \geq k$)。(着色 $\Leftrightarrow$ 等价类划分)

在下面的引理中, 用Ramsey定理将任何时间受限算法映射到基于比较的算法上。

Lemma 3.22 设 A 是一个运行时间为 $r(n)$ 的时间受限的同步算法, 则对于每个 n , 存在一个具有 $n^2 + 2n$ 个id的集合 C_n , 使得 A 是 C_n 上的一个基于 $r(n)$ -比较的算法, 这里 n 是环大小。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

Pf: 固定 n 。设 Y 和 Z 是 N (自然数集合)的任意两个 n -元子集。

Y 和 Z 称为等价子集，若对于每对序等价的环 R_1 和 R_2 (R_1 和 R_2 中的标识符分别来自于 Y 和 Z)，匹配结点在 $\text{exec}(R_1)$ 和 $\text{exec}(R_2)$ 的第1至 $r(n)$ 轮里均有相似的行为。

该定义将 N 的 n -元子集划分为有限多个等价类，因为行为相似仅指是否发送和接收 msg ，是否终止。我们对 N 的 n -元子集着色使得两个 n -元子集颜色相同当且仅当它们在同一等价类中。

由Ramsey定理，若设 t 是等价类(颜色)的数目， l 为 n^2+2n ， k 为 n ，则因为 N 是无限集，存在一个势为 n^2+2n 的子集(N 的子集) C_n ，使得 C_n 的所有 n -元子集属于同一个等价类。// N 相当于定理中的 S

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

考虑大小为 n ，标识符来自 C_n 的两个序等价的环 R_1 和 R_2 ，设 Y 和 Z 分别是 R_1 和 R_2 的标识符集合， Y 和 Z 显然均是 C_n 的 n 元子集，所以它们属于同一个等价类。

由等价子集定义知：匹配的结点在 $\text{exec}(R_1)$ 和 $\text{exec}(R_2)$ 的第1至 $r(n)$ 轮里均有相似的行为。因此， A 是 C_n (环大小为 n)上的一个基于 $r(n)$ -比较的算法(由def3.5)□

Note: 因为上述引理中算法 A 中的标识符是特定的，故还不能直接用Th3.18导出其 msg 复杂性为 $\Omega(n \lg n)$ 。因此，须使用 A 来构造 A' ，使 A' 的复杂性与 A 相同，且 ids 来自于集合 $\{0, 1, \dots, n^2 + 2n - 1\}$ 。因为基于比较的算法的 ids 来自于该集合。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

Th3.23 对每个同步的时间有界的leader选举算法A，以及每个 $n > 8$ ， n 为2的方幂，存在一个大小为 n 的环R，使得A在R上的容许执行里发送 $\Omega(n \lg n)$ 个msgs。

Pf: 设A是运行时间为 $r(n)$ 且满足定理假设的算法。固定 n ，设 C_n 是满足引理3.22的标识符集合， $c_0, c_1, \dots, c_{n^2+2n-1}$ 是 C_n 中按递增序排列的元素。

下面构造算法A'是基于比较的，它所执行的环大小为 n ，标识符集为 $\{0, 1, \dots, n^2+2n-1\}$ ，它和A有同样的时间和msg复杂性。

§ 3.4.2 有限制算法的下界 $\Omega(n \lg n)$

在算法 A' 中，一个标识符为 i 的结点执行算法就好像 A 在标识符 C_i 上执行一样。因为 A 在 C_n 上是基于 $r(n)$ -比较的且 A 在 $r(n)$ 轮里终止，所以 A' 在大小为 n 的环上是基于比较的，且环上标识符来自于集合 $\{0, 1, \dots, n^2 + 2n - 1\}$ 。

由定理3.18，存在一个标识符来自于 $\{0, 1, \dots, n^2 + 2n - 1\}$ ，大小为 n 的环，算法 A' 在该环上发送的 msg 为 $\Omega(n \lg n)$ 。

由 A' 的构造方法知，在大小为 n 、标识符来自于 C_n 的环上，存在 A 的一次执行，它发送的 msg 个数与 A' 相同。故定理得证。□

Ex3.9 若将环 R_n 划分为长度为 j (j 是2的方幂)的连续片段，则所有这些片段是次序等价的。

第4章

分布式系统中的计算模型

2006.12.15

概述

- 分布式系统计算模型的复杂性
 - 系统由并发执行部件构成
 - 系统中无全局时钟
 - 必须捕捉系统部件可能的失效
- 对策
 - 因果关系（Causality）
 - 一致状态（Consistent states）
 - 全局状态

§ 4.1 基本知识

- 协议（Protocol）
- 协议中的控制语句

1.Send（destination, action; parameters）

destination: 处理器抽象。实用中是通信实体的地址：
机器名，机器的端口号(即1个socket地址)

action: 控制msg，希望接收者采取的动作

parameters: 参数集合

假定：

msg发送是无阻塞、可靠的（语义类似于TCP套接字）；
有时假定较弱的msg传递层（等价于UDP）。

TCP与UDP的区别：①基于连接与无连接②对系统资源的要求（TCP较多，UDP少）
③UDP程序结构较简单④流模式与数据报模式

●TCP保证数据正确性，UDP可能丢包

●TCP保证数据顺序，UDP不保证

§ 4.1 基本知识

2.接收msg

接收msg可推广至接收事件，引起事件的原因是：

外部msg、超时设定、内部中断

事件在处理前，一般是在缓冲区(如事件队列)中，若一处理器想处理事件，它必须执行一个声明处理这些事件的线程。

例如，一个节点通过执行下述代码等待事件 $A_1, A_2, \dots, A_n$

```
waiting for  $A_1, A_2, \dots, A_n$  : //声明
```

```
     $A_1$  (Source; parameters)
```

```
        Code to handle  $A_1$ 
```

```
    ....
```

```
     $A_n$  (Source; parameters)
```

```
        Code to handle  $A_n$ 
```

当p执行`send(q,  $A_1$ ; parameters)`且q执行上述代码时，q将最终处理由p发送的msg

§ 4.1 基本知识

3. 超时

当怀疑远程处理器失效时，可通过超时检测来判定：

- ① 当T秒后仍未收到P的类型为event的msg时，执行指定的动作
 waiting until P sends (event; parameters), timeout=T
 on timeout
 timeout action
- ② 仅当收到一个响应msg时才采取动作，超时不做任何动作
 waiting until P sends (event; parameters), timeout=T
 on timeout;
 if no timeout occurred
 { Successful response actions }

§ 4.1 基本知识

3. 超时

③ 处理器等待响应T秒

若处理器在等待开始后T秒内没响应，则等待结束，协议继续

waiting up to T seconds for (event; parameters) msgs

Event: < msg handling code >

§ 4.2 因果关系

分布式系统为何缺乏全局的系统状态？

1. 非即时通信

A和B同时向对方喊话

他们都认为是自己先喊话

C听到两人是同时喊话


结论：系统的全局状态依赖于观察点

原因：

传播延迟

网络资源的竞争

丢失msg重发



§ 4.2 因果关系

2. 相对性影响

假设张三和李四决定使用同步时钟来观察全局状态：

他们约定下午**5**点在某餐馆会面，张三准时到达，但李四在一个接近光速的日光系统中游览。

张三在等待李四1小时后离开餐馆，而李四在自己的表到达**5**点时准时达到餐馆，但他认为张三未达到。

因为大多数计算机的实际时钟均存在漂移，故相对速度不同，时钟同步仍然是一个问题。

结论：使用时间来同步不是一个可靠机制。

§ 4.2 因果关系

3. 中断

假设张三和李四在同一起跑线上赛跑，信号为小旗，前两个问题可以忽略，但是...

即使可忽略其他影响，也不可能指望不同的机器会同时做出某些反应。因为现代计算机是一个很复杂的系统：**CPU** 竞争、中断、页错误等，执行时间无法预料。

结论：不可能在同一时刻观察一个分布式系统的全局状态
必须找到某种可以依赖的性质：

- 时间回溯
- 因果相关

§ 4.2 因果关系

- 假设分布式系统构成:

$P = \{P_1, P_2, \dots, P_n\}$: 处理器集合

$\mathcal{E}$: 全体事件的集合

$\mathcal{E}_p \subseteq \mathcal{E}$, $\mathcal{E}_p$ 表示发生在 p 上的所有事件

- 次序 $e_1 < e_2$: 事件 e_1 发生 e_2 在之前 (亦记: $e_1 \rightarrow e_2$)
 $e_1 <_I e_2$: 事件 e_1 发生 e_2 在之前, I 为信息源
- 定序 有些 $\mathcal{E}$ 中事件很容易定序:
 - 发生在同一节点 p 上的事件满足全序:
若 $e_1, e_2 \in \mathcal{E}_p$, 则 $e_1 <_p e_2$ 或 $e_2 <_p e_1$ 成立
 - e_1 发送消息 m , e_2 接收 m , 则 $e_1 <_m e_2$

§ 4.2 因果关系

- Happens-before关系 ($<_H$)

该关系是节点次序和消息传递次序的传递闭包：

—规则1：若 $e_1 <_p e_2$ ，则 $e_1 <_H e_2$

—规则2：若 $e_1 <_m e_2$ ，则 $e_1 <_H e_2$

—规则3：若 $e_1 <_H e_2$ ，且 $e_2 <_H e_3$ ，则 $e_1 <_H e_3$

在集合 X 上的二元关系 R 的传递闭包是包含 R 的 X 上的最小的传递关系。

$e_1 <_H e_3$ 表示存在1个事件因果链，使 e_1 发生 e_3 在之前

Note: $<_H$ 是一种偏序关系，即

存在 e 和 e' ，二者之间无这种关系

—并发事件：若两事件不能由 $<_H$ 定序

§ 4.2 因果关系

- Happens-before关系 ($<_H$)

- 规则1表述的是同一处理器上两个事件之间的因果关系;
- 规则2表述了不同处理器上两个事件之间的因果关系
- 规则3阐述了传递律

Note:

Happens-Before关系完整表述了执行中的因果关系。如果一个执行中的事件按照其相对顺序重新进行排序，而不改变他们的happens-before关系的话，那么其结果仍是一个执行，并且对处理器而言，该执行与原执行并无区别。

§ 4.2 因果关系

• 举例

1) 因事件 e_1 , e_4 和 e_7 均发生在 P_1 上, 故: $e_1 <_{P_1} e_4 <_{P_1} e_7$

2) 因 e_1 发送1个msg到 e_3 , 故: $e_1 <_m e_3$, 类似地 $e_5 <_m e_8$


3) 应用规则1和2得:

$$e_1 <_H e_4 <_H e_7, e_1 <_H e_3, e_5 <_H e_8$$

4) 由 $<_H$ 的传递闭包性质得:

$$e_1 <_H e_8$$

5) e_1 和 e_6 是并发的: e_1 和 e_6 之间无路径





§ 4.2 因果关系

- H-DAG

有时将Happens-before关系描述为一个有向无环图

- 顶点集 V_H 是事件集 $\mathcal{E}$: $e \in V_H$ 当且仅当 $e \in \mathcal{E}$

- 边集 E_H : 若 $(e_1, e_2) \in E_H$ 当且仅当 $e_1 <_p e_2$ 或 $e_1 <_m e_2$



§ 4.2.1 Lamport时间戳

- 系统有序性的重要性

若分布式系统中存在全局时钟，则系统中的事件均可安排为全序。例如，可以更公平地分配系统资源。

- 全序对事件的影响和由H关系确定的偏序对事件的影响是一致的
- 如何通过H关系确定的偏序关系来建立一个“一致”的全序关系？
 - 在 $<_H$ 的DAG上拓扑排序
 - On the fly: Lamport提出了动态即时地建立全序算法

§ 4.2.1 Lamport时间戳

- Lamport算法的思想

每个事件 e 有一个附加的时戳: $e.TS$

每个节点有一个局部时戳: my_TS

每个 msg 有一个附加时间戳: $m.TS$

节点执行一个事件时, 将自己的时戳赋给该事件;

节点发送 msg 时, 将自己的时戳赋给所有发送的 msg 。

§ 4.2.1 Lamport时间戳

- Lamport算法的实现

Initially: $\text{my_TS} = 0$;

On event e :

if (e 是接收消息 m) then

$\text{my_TS} = \max (m.\text{TS}, \text{my_TS});$

//取msg时戳和节点时戳的较大者作为新时戳

$\text{my_TS}++$;

$e.\text{TS} = \text{my_TS}$; //给事件 e 打时戳

if (e 是发送消息 m) then

$m.\text{TS} = \text{my_TS}$; //给消息 m 打时戳

§ 4.2.1 Lamport时间戳

- Lamport算法赋值的时戳是因果相关的
若 $e_1 <_H e_2$, 则 $e_1.TS < e_2.TS$
∵ 若 $e_1 <_P e_2$ 或 $e_1 <_M e_2$, 则的 e_2 时戳大于 e_1 的时戳
∴ 在因果事件链上, 每一事件的时戳大于其前驱事件的时戳
- 问题: 系统中所有事件已为全序?
不同的事件可能有相同的时戳 (并发事件)
- Lamport算法改进
因为并发事件的时戳可以任意指定先后
故可用节点地址作为时戳的低位

§ 4.2.1 Lamport时间戳

- 改进的Lamport时戳

事件标号：时戳. id

事件e8为4. 3:


$$\begin{aligned} \text{my_TS} &= \max(\text{m. TS}, \text{my_TS}) \\ &= \max(3, 1) = 3 \end{aligned}$$

按字典序得全序:

1. 1, 1. 2, 1. 3, 2. 1, 2. 2, 3. 1, 3. 2, 4. 3

- 算法特点：分布、容错、系统开销小

- Lamport算法的迷人之处在于：任何进程在发送消息前，先将自己的本地计数器累加1；接收进程总是计算自己的本地计数器和接受到计数器中较大值加上1的结果



§ 4.2.2 向量时间戳

- Lamport时戳缺点

若 $e_1 <_H e_2$ ，则 $e_1.TS < e_2.TS$ ；反之不然。

例如：1.3 < 2.1，但是 $e_6 < e_4$ 不成立

原因：并发事件之间的次序是任意的

不能通过事件的时戳判定两事件之间是否是因果相关

- 判定事件间因果关系的重要性

例子：违反因果关系检测

在一个分布式对象系统中，为了负载平衡，对象是可移动的，对象在处理器之间迁移是为了获得所需的调用的进程或资源。如下图：

§ 4.2.2 向量时戳

1) P1持有对象O，决定迁移到P2

为获取资源，P1将O装配在消息M1中发送给P2


2) P1收到P3访问O的请求

P1将O的新地址P2放在消息M2中通知P3

3) P3在M3中请求访问P2的O

当M3达到P2时，O不可用，故回答一个出错消息。

- 问题：当debug该系统时，会发现O已在P2上，故不知错在哪？



§ 4.2.2 向量时间戳

- 错误原因：违反因果序

P3请求O是发生在从P1迁移到P2之后，但该请求被处理是在迁移达到P2之前。形式地，

设： $s(m)$ 是发送 m 的事件

$r(m)$ 是接收 m 的事件

若 $s(m1) <_H s(m2)$ ，则称消息 $m1$ 因果关系上先于 $m2$ ，记做 $m1 <_C m2$

若 $m1 <_C m2$ ，但 $r(m2) <_P r(m1)$ ，则违反“因果关系”：

即，若 $m1$ 先于 $m2$ 发送，但在同一节点 P 上 $m2$ 在 $m1$ 之前被接收

例如，在上例中有：

$$M1 <_C M3, \text{ 但 } r(M3) <_{P2} r(M1)$$

§ 4.2.2 向量时间戳

- 违反因果序检测

- 定义：若时戳VT具有比较函数 $<_V$ 满足：

$$e1 <_H e2 \text{ iff } e1.VT <_V e2.VT$$

则我们能够检测出是否违反因果关系

- VT性质

- 1) 因 $<_H$ 是偏序，故 $<_V$ 也是偏序；

- 2) 因为必须知道在因果关系上每一节点中哪些事件是在事件 e 之前，故 $e.VT$ 中必须包含系统中每一个其它节点的状态。

这两个性质导致了向量时戳VT的引入

§ 4.2.2 向量时戳

- 向量时戳VT

VT是一个整数数组:

$e.VT[i]=k$ 表示在节点 i (或 P_i) 上, 因果关系上 e 之前有 k 个事件 (可能包括 e 自己)。


$e.VT=(3,6,4,2)$ 表示因果序:

在 $P1$ 上, 有3个事件须在 e 之前

在 $P2$ 上, 有6个事件须在 e 之前

在 $P3$ 上, 有4个事件须在 e 之前

在 $P4$ 上, 有2个事件须在 e 之前



§ 4.2.2 向量时间戳

- 向量时戳的意义

在因果关系上， $e1.VT \leq_v e2.VT$ 表示 $e2$ 发生在 $e1$ 及 $e1$ 前所有的事件之后。更精确的说，向量时钟的次序为：

$e1.VT \leq_v e2.VT$ iff $e1.VT[i] \leq e2.VT[i], i=1, 2, \dots, M$

$e1.VT <_v e2.VT$ iff $e1.VT \leq_{VT} e2.VT$ 且 $e1.VT \neq e2.VT$

- 向量时戳算法

my_VT: 每个节点有局部的向量时戳

e.VT: 每个事件有向量时戳

m.VT: 每个msg有向量时戳

节点执行一个事件时，将自己的时戳赋给该事件；

节点发送msg时，将自己的时戳赋给所有发送的msg。

**注意 $\leq_v, \leq_{VT}$ 以及 $<_v$ 之间的区别：
 v 代表因果序，
而 VT 代表时戳比较**

§ 4.2.2 向量时间戳

- 算法实现

Initially: $\text{my_VT}=[0,\dots,0]$;

On event e :

if (e 是消息 m 的接收者) then

 for $i=1$ to M do //向量时戳的每个分量只增不减

$\text{my_VT}[i] = \max(m.VT[i], \text{my_VT}[i]);$

$\text{my_VT}[\text{self}]++;$ //设变量 self 是本节点的名字

$e.VT=\text{my_VT};$ //给事件 e 打时戳

if (e 是消息 m 的发送者) then

$m.VT=\text{my_VT};$ //给消息 m 打时戳

§ 4.2.2 向量时间戳

- 算法性质

1) 若 $e <_H e'$, 则 $e.VT <_{VT} e'.VT$

∴ 算法确保对于每个事件满足:

若 $e <_p e'$ 或 $e <_m e'$, 则 $e.VT <_{VT} e'.VT$

2) 若 $e \not<_H e'$, 则 $e.VT \not<_{VT} e'.VT$

pf: 若 e 和 e' 因果相关, 则有 $e' <_H e$, 即 $e'.VT <_{VT} e.VT$

若 e 和 e' 是并发的, 则在 H-DAG 上, 从 e 到 e' 和从 e' 到 e 均无有向路径, 即得:

$$e.VT \not<_{VT} e'.VT \text{ 且 } e'.VT \not<_{VT} e.VT$$

当且仅当 $e.VT$ 和 $e'.VT$ 是不可比时, 称向量时戳是捕获并发的! ²⁷

§ 4.2.2 向量时戳

- 向量时戳比较

$$e1.VT=(5,4,1,3)$$

$$e2.VT=(3,6,4,2)$$

$$e3.VT=(0,0,1,3)$$

1) $e1$ 和 $e2$ 是并发的

$$\because e1.VT[1] > e2.VT[1]$$


$$e1.VT[2] < e2.VT[2]$$

$\therefore e1$ 到 $e2$ 及 $e2$ 到 $e1$ 均无路径

2) $e3$ 在因果序上先于 $e1$

即: $e3.VT <_V e1.VT$

$e1$ 的前驱事件见方框



§ 4.2.2 向量时戳

• 因果序检测

1) 消息时戳间比较

在P2上，先到达的M3的时戳为(3,0,3)，后到达的M1的时戳为(1,0,0)。但是：

$$\because (1,0,0) <_v (3,0,3)$$

$\therefore$ M1在因果序上先于M3


故M1后于M3到达违反因果序

2) 消息时戳和局部时戳比较

当时戳为(1,0,0)的M1到达P2时，P2的时戳是(3,2,3)。但：

$$\because (1,0,0) <_v (3,2,3)$$

$\therefore$ M1在因果序上应先于(3,2,3)对应的事件




§ 4.2.3 因果通信

- 如何保证通信不违反因果关系？

处理器不能选择msg达到的次序，但能抑制过早达到的msg来修正传递（指提交给应用）次序。

- FIFO通信（如TCP）

由msg传递协议栈里的一层负责确保FIFO通信



§ 4.2.3 因果通信

- FIFO通信


源处理器给每个发送的msg顺序编号，目的处理器知道自己所收到的msg应该有何顺序的编号，若目的处理器收到一个编号为x的msg但未收到较小编号的msg时，则延迟传递直至能够顺序传递为止。

- 因果通信

因果通信与FIFO通信类似

源：附上时戳

目的地：延迟错序msg



§ 4.2.3 因果通信

- 因果通信实现思想

- 抑制从P发送的消息m，直至可断定没有来自于其它处理器上的消息m'，使 $m' <_V m$.

- 在每个节点P上：

earliest[1..M]: 存储不同节点当前能够传递的消息时戳的下界

earliest[k]表示在P上，对节点k能够传递的msg的时戳的下界

blocked[1..M]: 阻塞队列数组，每个分量是一个队列

- Alg. Causal Msg delivery

定义时戳 1_k : 若使用Lamport时戳，则 $1_k = 1$;

若用向量时戳，则 $1_k = (0, \dots, 1, 0, \dots, 0)$ ， k^{th} 位为1

初始化

1: $\text{earliest}[k] = 1_k$, $k=1, \dots, M$

2: $\text{blocked}[k] = \{ \}$, $k=1, \dots, M$ //每个阻塞队列置空

§ 4.2.3 因果通信

3: On the receipt of msg m from node p :

4: $\text{delivery_list} = \{\}$;

5: if ($\text{blocked}[p]$ 为空) then

6: $\text{earliest}[p] = m.\text{timestamp}$;

7: 将 m 加到 $\text{blocked}[p]$ 队尾; // 处理收到的消息

8: while ($\exists k$ 使 $\text{blocked}[k]$ 非空 and 对每个 $i=1, \dots, M$ (除 k 和 self 外),
 $\text{not_earliest}(\text{earliest}[i], \text{earliest}[k], i)$) { // 处理阻塞队列
 // 对非空队列 k , 若其他节点 i 上无比节点 k 更早的 msg 要达到本
 // 地, 则队列 k 的队首可解除阻塞

9: 将 $\text{blocked}[k]$ 队头元素 m' 出队, 且加入到 delivery_list ;

10: if ($\text{blocked}[k]$ 非空) then

11: 将 $\text{earliest}[k]$ 置为 $m'.\text{timestamp}$;

12: else increment $\text{earliest}[k]$ by 1_k } // end while

13: deliver the msgs in delivery_list ; // 按因果序

§ 4.2.3 因果通信

- 向量时戳比较

```
not_earliest( proc_i_vts, msg_vts, i ) { //前者不早于后者时为真
    if ( msg_vts[i] < proc_i_vts[i] )
        return true;
    else return false;
}
```

- 分析 使用向量时戳较好，不会假定序。

1) 初始化：在本地节点（self）上，能够最早传递的来自于节点k的msg的时戳存储在本地的earliest[k]中，line1初始化正确

2) 处理接收的消息：当本地节点接收来自于p的消息m时

行5,6：若blocked[p]中无msg，则earliest[p]被置为m的时戳，这是因为从p上不会有更早的msg达到本地，更早的已处理过。

§ 4.2.3 因果通信


- 分析

行7：将m放入阻塞队列blocked[p]中，直到可安全传送为止。

3) 处理阻塞：因m的达到能够将earliest[p]中的时戳更新（变大），故可能会使若干个阻塞的msg变为非阻塞；当然m本身可能是安全的，可直接传递给应用。

最终，一个阻塞msg变为非阻塞msg后，也可能使其他阻塞msg变为非阻塞msg。

行8：while循环检查阻塞队列，对于非空队列k进行处理。



§ 4.2.3 因果通信

- 分析

什么样的msg是非阻塞的？

当阻塞队列k（指blocked[k]）非空时，检测其能否解除阻塞：

设队头msg是m，在self上若其他节点i（除self和k之外）无更早时戳earliest[i]（即比m.timestamp=earliest[k]更小）的msg可能被传递，则消息m是非阻塞的。此时，m可安全传递，m出队（行9）。

4) 问题

上述算法可能会发生死锁：若一节点长时间不发送你要的msg，会发生死锁。

因此，上述因果通信算法通常被用于组播的一部分。


§ 4.2.3 因果通信

• 算法执行例子（Causal Multicast）

因为协议只对发送事件的因果序感兴趣，故一节点只有发送msg时对向量时戳做增量操作。

①处理接收消息：当p3从p1接收m2时，修改earliest[1]为(1,1,0)，m2入阻塞队列blocked[1]；//line6, 7

②处理阻塞：blocked[1]≠Φ，故while循环中k=1，self=3，i=2，not_earliest(earliest[2], earliest[1], 2)，前者早于后者，表示p2上有一个更早的msg还没有达到p3，返回假。m2被阻塞




§ 4.2.3 因果通信

①处理接收消息：当p3从p2接收m1时， $\text{earliest}[2]$ 为(0,1,0)(不变)，m1入阻塞队列 $\text{blocked}[2]$ ；//line6, 7

②处理阻塞：while检测各阻塞队列是否有阻塞的msg。

$k=2$, $\text{blocked}[2] \neq \Phi$, 其中的m1不依赖其他事件，故放入传递表(行9)，m1出队后 $\text{blocked}[2] = \Phi$, $\text{earliest}[2][2]+1$ (行12)后 $\text{earliest}[2] = (0,2,0)$;

$k=1$, $\text{blocked}[1] \neq \Phi$, $\text{self}=3$, $i=2$, $\text{not_earliest}(\text{earliest}[2], \text{earliest}[1], 2)$, 前者不早于后者，表示p2上无更早的msg会达到p3，返回真。m2从 $\text{blocked}[1]$ 出队入传递表(行9), $\text{blocked}[1] = \Phi$, $\text{earliest}[1][1]+1$ (行12)后 $\text{earliest}[1] = (2,1,0)$ 。



接收m1

m2	m1	
(1,1,0)	(0,1,0)	//k=2, i=1
(1,1,0) >	(0,1,0)	(0,0,1)

deliver m1

m2		
(1,1,0)	(0,2,0)	//k=1, i=2
(1,1,0) <	(0,2,0)	(0,0,1)

deliver m2

(2,1,0)	(0,2,0)	(0,0,1)