


 万水 Linux 技术丛书

WWW 服务器技术

—— Apache 使用指南与实现原理



牛锦中 牛锦宇 李锦涛 等编著



中国水利水电出版社
www.waterpub.com.cn

万水 Linux 技术丛书

WWW 服务器技术

——Apache 使用指南与实现原理

牛锦中 牛锦宇 李锦涛 等编著

中国水利水电出版社

内 容 提 要

本书全面介绍了当前 Internet 上最为流行的开放源代码的 WWW 服务器——Apache。不仅全面介绍了 Apache 服务器的操作与使用,满足了广大读者的普遍性需求;更有特色的是,它深入剖析了 Apache 服务器的工作原理与实现技术,对其中使用的数据结构和方法调用进行了详细的阐述。而且面向实际,给出了一个基于 Apache 服务器并结合 Java Servlet 技术的分布式、负载平衡、可容错的网站实施方案。

本书共 9 章,前 5 章介绍 Apache 的安装与使用,6~8 章为 Apache 的工作原理与实现机制,第 9 章则全面描述了 HTTP1.1 协议。

本书特别适合希望了解掌握 Internet 应用层核心技术的广大教师、学生及电脑爱好者,对使用 Apache 服务器建设网站或进行网络服务器应用开发的工程技术人员尤其具有重要的阅读和参考价值。

图书在版编目(CIP)数据

WWW 服务器技术: Apache 使用指南与实现原理/牛锦中等编著. —北京:中国水利水电出版社, 2002

(万水 Linux 技术丛书)

ISBN 7-5084-1016-5

I. W… II. 牛… III. 因特网—服务器—应用软件, Apache IV. TP393.4

中国版本图书馆 CIP 数据核字(2002)第 016149 号

书 名	WWW 服务器技术——Apache 使用指南与实现原理
作 者	牛锦中 牛锦宇 李锦涛 等编著
出版、发行	中国水利水电出版社(北京市三里河路 6 号 100044) 网址: www.waterpub.com.cn E-mail: mchannel@public3.bta.net.cn (万水) sale@waterpub.com.cn 电话: (010) 68359286 (万水)、63202266 (总机)、68331835 (发行部)
经 售	全国各地新华书店
排 版	北京万水电子信息有限公司
印 刷	北京蓝空印刷厂
规 格	787×1092 毫米 16 开本 25.75 印张 564 千字
版 次	2002 年 3 月第一版 2002 年 3 月北京第一次印刷
印 数	0001—4000 册
定 价	40.00 元

凡购买我社图书,如有缺页、倒页、脱页的,本社发行部负责调换

版权所有·侵权必究

前 言

网络的兴起使计算机世界焕然一新。在网络技术的发展中,除了 TCP/IP 协议的诞生就应属 WWW (World Wide Web) 的影响巨大。WWW 面向终端用户,提供了在 Internet 上共享信息的友好且充分的手段。很多网络技术在出现后,由于灵活性或适应性的不足,很快便销声匿迹;与之相反,WWW 技术则由于其极强的扩展能力和符合人们获取信息的习惯,成为 Internet 应用层的主宰,是呈几何级数增长的网络知识空间的基础。

WWW 服务器是网上信息的“集散地”、WWW 世界的“神经中枢”,从而也是 WWW 知识共享模式中的要害,因此 WWW 服务器的性能至关重要,尤其是那些异常繁忙的门户网站;另一方面,Internet 是公认的自由世界,有众多的“大虾”、“虫虫”希望拥有自己的一片天地,选择并用好 WWW 服务器是日后在网上“扬名”的重要一环。这一切都需要有对 WWW 技术尤其是 WWW 服务器技术的深刻理解。

但是关于 WWW 服务器的书籍并不很多,能够深入到技术内部的更是少之又少。本书的问世即想为各位读者在这方面提供一定的帮助。本书的最大特点:它是中国科学院计算技术研究所家庭网络课题组实际工作成果的总结,并对 WWW 服务器进行了清晰透彻的分析,特别适合于希望了解网络软件核心技术的广大爱好者及学生和科研人员。

说到 WWW 服务器技术,则不能不说 Apache。在诸多 WWW 服务器产品中,Apache 无疑是最著名的一个,有相当多的门户网站如新浪网等均采用 Apache 作为其运行平台,足见其魅力,其市场份额超过 60%,极具代表性。Apache 的模块化设计提供了规范扩展接口,其在进程与线程管理、内存空间的分配等方面均匠心独具,开放源代码的特点更使其性价比极高。

本书以 Apache 服务器为对象,对 WWW 服务器的使用与实现原理进行了详细阐述和深入分析。全书共 9 章。第 1、2 章分别描述了 WWW 服务器和 Apache 的概貌;第 3、4 章则对 Apache 服务器的安装、使用、运行、访问等进行了介绍;Apache 服务器的配置管理、配置命令的使用集中在第 5 章;第 6 章概括性地阐述了 Apache 的整体设计思想——模块化结构,希望在 Apache 服务器上增加额外功能的读者通过阅读本章,可以了解扩展模块的开发及运作的基本步骤;第 7 章在本书所占篇幅最大,详细讨论了 Apache 服务器的具体实现,读者按照本章脉络,对 Apache 源代码进行分析,可以深刻体会前面各章对 Apache 的概念性描述,并对什么是好的软件体系结构将有一个身临其境的感受;鉴于 Perl 和 Java Servlet 是近年来较为流行的服务器端编程技术,第 8 章介绍了 Apache 的扩展模块 mod_perl 和 mod_jserv,并给出了一个基于 Java Servlet 的分布式、可扩展、能容错和动态负载平衡的大型站点设计的例子,极具实用参考价值;WWW 服务器从根本上说是 HTTP 协议的服务器端实现,第 9 章

则是一个完整的 HTTP 协议规范，任何涉及该协议的开发均可参考本部分。

很久以来，一般都认为缺乏管理上的规范化进而实现规模化是中国软件业的主要问题。我们在实际工作中则深刻体会到，作为软件开发者的个体对软件技术的把握，特别是在已实现正确功能的前提下对软件可用性或说能用性的把握，也是尤为重要问题之一。实际上，在软件组织结构上具有的高水平，通常自然地产生对软件开发过程规范化的深刻理解。现在还很少能看到由中国人完成的软件核心技术的创新，希望通过本书对 Apache 服务器实现原理的介绍，对我国计算机技术人员集中精力钻研核心技术并进而有一定创新起到推动作用。

作者

2001 年 1 月 15 日

目 录

前言

第 1 章 概述	1
1.1 WWW 的发展历史	1
1.2 什么是 WWW	2
1.3 WWW 服务器及其技术	2
1.3.1 概貌	2
1.3.2 信息的组织	5
1.3.3 工作方式	7
1.4 Proxy 服务器技术	11
1.4.1 概貌	11
1.4.2 应用级 Proxy	13
1.4.3 若干技术问题	14
第 2 章 Apache 服务器简介	17
2.1 Apache 服务器的特点	17
2.2 对 WWW 服务器的调查	17
2.3 各流行 WWW 服务器的比较	20
第 3 章 Apache 服务器的安装、运行和控制	28
3.1 Apache 服务器软件的安装	28
3.1.1 基于 Apache 源码的编译和安装	28
3.1.2 基于 Apache 可执行代码的安装	29
3.2 Apache 服务器的运行	33
3.2.1 服务模式	33
3.2.2 控制台窗口模式	34
3.3 Apache 配置文件的查找	34
3.4 以信号方式控制运行中的 Apache	35
3.4.1 终止	35
3.4.2 重启	36
3.5 Apache 服务器的目录结构	36
第 4 章 访问 Apache 服务器	37
4.1 使用 WWW 服务	37

4.2 使用 Proxy 服务.....	38
第 5 章 Apache 服务器的配置	40
5.1 配置命令说明	40
5.1.1 注意事项	40
5.1.2 格式说明	41
5.2 配置命令介绍	43
5.2.1 mod_core 配置（基本功能）	43
5.2.2 mod_proxy 配置（代理服务器）	65
5.2.3 mod_cgi 配置（CGI 脚本）	73
5.2.4 mod_access 配置（访问控制）	74
5.2.5 认证模块配置（身份认证控制）	76
5.2.6 mod_log_config 配置（日志）	84
5.2.7 mod_status 配置（服务器状态信息反馈）	85
5.2.8 mod_headers 配置（头域定制）	86
5.2.9 mod_info 配置（服务器模块信息反馈）	87
5.3 配置命令使用	87
5.3.1 proxy（代理服务器）	87
5.3.2 auth（访问控制）	88
5.3.3 log（日志）	90
5.3.4 virtual hosts（虚拟主机或服务器）	91
第 6 章 Apache 服务器的模块结构	100
6.1 模块接口结构概述	100
6.2 Apache 服务器 API	101
6.2.1 基本概念	101
6.2.2 请求处理方法的工作方式	104
6.2.3 资源分配和资源池	109
6.2.4 配置命令	112
6.3 Apache 各模块配置接口定义	117
6.3.1 http_core	117
6.3.2 mod_proxy	123
6.3.3 mod_header	125
6.3.4 mod_info	126
6.3.5 mod_status	127
6.3.6 mod_access	128
6.3.7 mod_digest	128

6.3.8	mod_auth	129
6.3.9	mod_anon_auth	130
6.3.10	mod_log_config	131
6.3.11	mod_alias	132
6.3.12	mod_dir	133
6.3.13	mod_log_agent	134
6.3.14	mod_log_referer	135
6.3.15	mod_mime	136
6.3.16	mod_userdir	137
6.3.17	mod_so	138
第 7 章	Apache 服务器实现原理	140
7.1	概述	140
	源代码的组织	140
7.2	主控程序——Apache 控制处理流程	143
7.2.1	主程序	143
7.2.2	单进程模式——worker_main	146
7.2.3	单进程模式的核心（线程体）——child_sub_main	149
7.2.4	多进程模式前奏	150
7.2.5	多进程模式的核心——master_main	153
7.3	重要的数据结构	159
7.3.1	资源池结构	159
7.3.2	数组结构	162
7.3.3	表结构	163
7.3.4	cleanups	165
7.3.5	子进程信息	168
7.3.6	server_rec 结构	169
7.3.7	command_rec 结构	171
7.3.8	cmd_parms 结构	171
7.3.9	模块接口控制块	172
7.3.10	处理方法句柄的简捷组织结构	175
7.3.11	listen_rec 结构	178
7.3.12	工作任务队列	178
7.3.13	BUFF 结构	179
7.3.14	conn_rec 结构	186
7.3.15	request_rec 结构	186

7.3.16 handler_rec 结构	188
7.4 主控程序的实现	188
7.4.1 主执行程序的形态	189
7.4.2 http_main.c	189
7.4.3 http_protocol.c	191
7.4.4 http_request.c	195
7.4.5 http_config.c	198
7.4.6 http_log.c	204
7.4.7 http_vhost.c	205
7.5 core 模块	208
7.5.1 mod_core 的数据结构	208
7.5.2 mod_core 中的处理方法	209
7.6 proxy 模块	223
mod_proxy 的实现	223
7.7 CGI 模块	241
7.7.1 CGI 原理	242
7.7.2 CGI 程序的编写	245
7.7.3 环境变量配置	249
7.7.4 Apache 中的 CGI 错误日志文件	250
7.7.5 mod_cgi 的实现	252
7.8 access 模块	255
mod_access 的实现机制	255
7.9 auth 模块	258
7.9.1 HTTP 认证机制	259
7.9.2 MD5 算法	265
7.9.3 实现机制	269
7.10 log 模块	279
7.10.1 概述	279
7.10.2 日志文件格式	280
7.10.3 多个日志文件的使用	282
7.10.4 mod_log_config 的实现	282
7.11 status 模块	288
7.11.1 mod_status 的使用	288
7.11.2 mod_status 的实现	289
7.12 headers 模块	291

mod_headers 的实现方法	291
7.13 info 模块	292
7.13.1 mod_info 使用方法	292
7.13.2 mod_info 的实现	293
7.14 其他若干问题	295
7.14.1 事件控制	295
7.14.2 注册表项	296
7.14.3 服务运行模式	297
第 8 章 重要的 Apache 扩展模块	299
8.1 mod_perl 模块	299
8.1.1 什么是 Perl	299
8.1.2 什么是 mod_perl	299
8.1.3 编译和安装 mod_perl	301
8.1.4 在 mod_perl 上运行 Perl CGI	304
8.1.5 基于 mod_perl 写 Perl 模块	306
8.1.6 与 SSI 的结合使用	307
8.1.7 使用 Perl 来配置 Apache	308
8.1.8 安全性问题	311
8.2 Java Servlet 扩展模块	312
8.2.1 Servlet 基础	312
8.2.2 Servlet 的工作方式	313
8.2.3 编写 Servlet	314
8.2.4 用 servletrunner 来运行 Servlet	321
8.2.5 Apache JServ	324
8.2.6 如何在 WIN32 平台下安装 Apache JServ	325
8.2.7 Servlet 区	332
8.2.8 Apache JServ 状态查询	334
8.2.9 如何安装 Servlet	334
8.2.10 保证 Servlet 环境的安全	336
8.3 基于 Apache JServ 的可扩展性、负载平衡与容错	338
8.3.1 概述	338
8.3.2 特征	338
8.3.3 配置	345
8.3.4 内部实现	346
8.3.5 内部状态——管理任务	349

8.3.6	大型站点	350
8.3.7	需注意的问题	353
8.3.8	小技巧	353
第 9 章	HTTP 1.1 协议	355
9.1	概貌	355
9.1.1	HTTP 协议的特征	355
9.1.2	HTTP 基本术语和概念	356
9.1.3	操作概貌	357
9.2	HTTP 协议参数	359
9.2.1	HTTP 版本	359
9.2.2	统一资源标识符	359
9.2.3	日期和时间	361
9.2.4	内容编码	362
9.2.5	传输编码	363
9.2.6	媒体类型	364
9.2.7	多部类型	365
9.2.8	产品标识	365
9.2.9	实体标记	365
9.2.10	实体片段单位 (Range Units)	366
9.3	HTTP 消息	366
9.3.1	消息头域	366
9.3.2	消息体	367
9.3.3	消息长度	367
9.3.4	通用头域	368
9.3.5	请求消息	368
9.3.6	应答消息	371
9.4	实体	373
	实体头域	374
9.5	HTTP 连接	375
9.5.1	持续连接	375
9.5.2	有关消息传输的要求	376
9.6	HTTP 方法	378
9.6.1	安全和幂等方法	378
9.6.2	OPTIONS	378
9.6.3	GET	379

9.6.4 HEAD	379
9.6.5 POST	379
9.6.6 PUT	380
9.6.7 DELETE	380
9.6.8 TRACE	381
9.7 状态码	381
9.7.1 提示类状态码——1xx	381
9.7.2 成功类状态码——2xx	381
9.7.3 重定向类状态码——3xx	382
9.7.4 客户端出错类状态码——4xx	384
9.7.5 服务器端出错类状态码——5xx	386
9.8 HTTP 访问身份认证	386
9.9 内容协商	387
9.9.1 服务器驱动的内容协商	387
9.9.2 用户软件驱动的内容协商	387
9.9.3 透明内容协商	388
9.10 HTTP 头域	388
9.11 与早期版本的兼容	398
参考资料	399

第 1 章 概述

WWW 是近几年 Internet 上最热门的话题，它以异乎寻常的速度迅猛发展，目前已经跃升为 Internet 上最主要的应用。其流量如此之大，因此经常造成某些区域网络甚至整个 Internet 的性能下降。如在北约轰炸南斯拉夫时，众多网民为获取快捷迅速的信息，将新浪网都“点”瘫痪了。

WWW 技术和应用，包括 HTML、HTTP、各种 Web 服务器软件，还有 Mosaic、Netscape 等客户端软件，以及飘香整个网络的 Java 等，都是 90 年代信息技术领域非常了不起的发明。WWW 的崛起为信息发现和获取带来了新的机遇和思路，它和其他计算机网络技术一道，必将进一步促进社会的网络化和网络的社会化，对人类社会的发展产生深远的影响。

在网络社会，WWW 站点正在并将至少在很长的时间内充当信息集散地的角色，而且不仅仅是简单的信息，逐渐地，各种商务活动、软件服务等形形色色的东西也将被囊括其中。而 WWW 服务器是 WWW 站点的基础软件平台，居于重要地位。本书介绍的 Apache 服务器就是一种最受欢迎的 WWW 服务器。

在了解具体的 WWW 技术和 Apache 服务器之前，我们首先来回顾一下历史，以便在学习 WWW 技术特别是 WWW 服务器技术时，能有一种顶天立地的感觉，能知过去将来事。

1.1 WWW 的发展历史

早在 1965 年，Ted Nelson 便首先提出了“超文本”的概念，并在 1967 年把相应的实现计划命名为 Xanadu。该项目于 1987 年才算完成，只设计出“一个运行于 SUN 工作站上的粗糙工具”（Conklin）。

欧洲粒子物理实验室（即 CERN）的 Tim Berners-Lee 受到 Nelson 的影响，提出一项计划，目的是使科学家们能很容易地查阅同行的文章。该项目从 1990 年 10 月开始到同年 12 月完成，结果出版了命令行方式浏览器和 NeXTStep 浏览器。该浏览器可用于浏览服务器超文本文件及 CERN 的 USENET。1992 年 7 月，WWW 在 CERN 内部广泛使用。到 1993 年 1 月为止，全世界共有 30 台 WWW 服务器，并有多种浏览器版本发行。

1993 年伊利诺斯大学 Urbana-Champaign 分校的国家超级计算应用中心 NCSA（National Center for Supercomputing Applications）发行了一个新的浏览器软件——Mosaic 浏览器。Mosaic 浏览器在继承前人成果的基础上，不仅能处理基本的文档共享和链接，而且还支持多种网络协议及 MIME 协议，用户在浏览器中能直接浏览图形甚至声音。这时的 WEB 已基本成熟。

尽管 WWW 的发展历史在浏览器的演进中更明显，但它们在“前台的表演”始终离不开“幕后的英雄”——WWW 服务器。

WWW 服务器中的两个“元老”——CERN 和 NCSA 服务器是几乎其他一切服务器软件的祖先。本书的主角 Apache 服务器便是源自于 NCSA 服务器的。

由此开始了各种商业和免费 WWW 服务器的纷争，Netscape 和 IE 两种主流浏览器龙虎斗，更使 WWW 在 Internet 中空前火爆，从此 WWW 进入了快速发展的阶段。

1.2 什么是 WWW

WWW (World Wide Web) 常称为全球网或万维网，简称 Web。WWW 实质上是用超链接 (hyperlink) 将互联网 (Internet) 上的所有信息连接在一起的机制。比如，电子邮件、远程登录、新闻阅读、gopher 资源、超文本文档等都可通过 WWW 的机制访问。通过 WWW 能访问的，除文本形式外，还有声音、图像、动画、数据库等其他形式。

WWW 采用的是客户机/服务器体系。用户所用的浏览程序为 WWW 的客户机，运行 WWW 服务的计算机为 WWW 服务器。用户用浏览器 (客户端程序) 浏览 WWW 服务器管理和提供的信息，它们之间是通过连接机制 (connection) 相互通信的。

用户浏览到的 WWW 信息资源以页 (Page) 为单位，其中用户所在网络的 WWW 服务器的第一页称为主页 (Homepage)。页实质上是一包含超链接的超文本文件 (Hypertext document)，用户从一页到另一页的浏览实质上是通过超链接进行的。

1.3 WWW 服务器及其技术

1.3.1 概貌

□ WWW 服务器系统构成

WWW 服务器的构成可以简单地用下述公式表达：

服务器 = 平台 + 软件 + 信息

WWW 服务器必须是一台连接到 Internet 上的计算机。计算机硬件、操作系统和网络通信软件构成了计算“平台”。WWW 服务器的第二部分组成是 WWW 服务器软件本身，即公式中的“软件”。而最重要的则是 WWW 服务器提供的信息服务！没有了信息，WWW 服务器就没有了存在的道理。

如图 1.1 所示，WWW 服务器软件将整个系统组合在一起，是连接包含信息的文档集合与计算平台的桥梁。

WWW 服务器软件的工作原理非常简单：接收浏览器对文档的请求，并进行解析以确定被请求的文档，进而取得该文档，通过建立的网络连接传回浏览器。下面来看一下 WWW 服务器软件是如何一步步工作的。

WWW 服务器软件持续运行，等待来自 Internet 上客户的请求。有请求时，创建网络连

接,接收该请求。那么 WWW 服务器软件是如何知道有请求的呢?实际上,Web 服务同底层网络的交互与 Internet 上的其他服务类似。计算机上的操作系统负责面对复杂多样的底层网络,对其进行简单的抽象,以便人与程序能更容易地理解和工作。例如:程序通过在两个端口(port)之间建立连接来实现网络通信。“端口”是一种抽象,为创建和使用网络连接提供简便、一致的方式。当一个程序连接另一个程序时,它会给后者的端口发送请求。该端口就确定了前者要连接的程序。在发送者的机器上,数据通过写端口被输出,到达接收程序的输入端口时被读取。




图 1.1

每个 WWW 服务器都被赋予一个用数字表示的端口。一个端口就表示与计算机系统的一个网络连接。浏览器,作为 WWW 客户端程序,就把 WWW 服务器的端口看作其在网络上的可访问点。当浏览器要请求 WWW 服务器时,便向 WWW 服务器被赋予的端口发请求。而对 WWW 服务器来说,数据就从该端口处进来。WWW 服务器软件只需要知道如何读写端口,而不需知道信息在网络上传输的具体细节。对客户与服务器间连接的复杂的管理是存在于两端口机器的操作系统和网络通信软件中的。这也正是 Internet 协议分层机制的突出优点。

当 WWW 服务器程序接收到请求时,它必须对请求进行解析,并做出响应。WWW 服务器程序必须定位目标文件,并把它从磁盘上拷贝到网络上传给客户。被请求的文档是按照名字即在 Web 文档树中的位置来指定的。要根据名字确定对应文档,服务器只需在文档树中搜索名字的各个部分,即逐步地确定文档位置。WWW 服务器软件实际上是把确定文件位置的工作交给操作系统完成的。然后该文件便会从磁盘上被读入并通过网络发送给客户。WWW 服务器程序实际上并不知道文档中有什么以及请求的文档是否正确。它知道的只是文件的名字,而且也只是将请求中指定的文件返回。

□ WWW 服务器模式

在计算机网络中, 服务器起着核心作用。在 WWW 中, 由客户向服务器提出请求, 而事务处理一般由服务器完成。

如果一个服务器一次只能收到一个请求, 并且在下一次客户发出请求、提交任务前有足够的时间和空间去响应这次请求的话, 那么服务器端的工作就简单了。但实际上, 服务器在同一时刻可能收到多个客户的请求, 从而产生“拥挤”, 此时如何响应客户的请求就成了一个问题。根据不同的解决方案, 可以把服务器的工作模式分为以下几种:

1. 阻塞模式 (Blocking Model)

阻塞模式下, 如果服务器在响应一个客户的请求, 则其他客户的请求均不被响应, 必须等到当前客户的请求被处理完毕之后。如果这样, 用户可能会花很长时间去等待服务器的响应, 所以负载较重的服务器一般都不采用这种模式。

2. 多路复用模式 (Multiplexing Model)

该模式下, 服务器可以同时为多个客户的请求服务, 不过, 服务器一般采取“平均制”的工作方式: 为第一个客户的请求服务一会儿, 又去为第二个客户的请求服务一会儿……。如果客户很多, 一个客户要得到完全的服务将要花很多时间, 这也是不合理的。

3. 派生模式 (Forking Model)

在派生模式下, 服务器按客户的请求派生出一个与自己一样的进程去响应用户的请求, 这样, 许多用户同时访问服务器, 也不会等待太长时间。我们知道服务器复制自己是需要时间的, 同样也会占用内存。内存是一个有限的资源, 尽管虚拟内存解决了一部分问题, 但是进程是不能在硬盘上运行的。所以进程需要在硬盘和内存之间调入调出, 这样也就降低了系统的效率。不过, 派生模式是 WWW 服务器常用的模式, CERN 和 NCSA 均采用这种模式。

4. 进程池模式

进程池模式是对派生模式的改进。在派生模式下, 服务器产生了许多与自己一样的进程副本去响应用户的请求, 完成任务后就退出; 而在进程池模式下, 进程池服务器会创建一组子进程, 而非进程副本去快速响应客户的请求, 这样可大大减小系统对内存的要求。并且这样的子进程存在于整个服务器生存期间, 而不像进程副本那样频繁地创建、销毁进程。目前采用进程池模式的 WWW 服务器有 NCSA 的 HTTP 1.4、Netscape 的 NetSite 和本书介绍的 Apache 服务器等。

□ HTTP 协议

WWW 的实质是信息的传输: 从各个服务器到 Internet 的用户。但因其中涉及许多不同的计算机网络和连接方式, 所以任何两台计算机要通信必须有共同认定的标准和规定。在计算机网络领域用于通信的标准和规定, 称为协议。

WWW 所使用的协议是 HTTP 协议 (HyperText Transfer Protocol, 超文本传输协议)。HTTP 协议基于 TCP/IP 连接实现。WWW 服务器和客户端程序必须遵守 HTTP 协议的规定来通信。没有了 HTTP, WWW 也将不复存在。因此通常还将 WWW 服务器程序称为 httpd (HTTP

Daemon, HTTP 服务奴), 尤其在 UNIX 领域更是如此。

本书的第 9 章包含了 HTTP 协议规范的详细介绍, 对想了解 HTTP 协议细节或要实现 WWW 服务器或浏览器的读者将大有用处。在阅读本书前对 HTTP 一无所知的读者, 也请先读一下该规范的概貌部分, 以作为阅读本书其他部分的基础。另外, 还可以结合下一节的 WWW 服务工作过程部分来理解。

1.3.2 信息的组织

WWW 服务器上的文档是以层状或树型结构组织的。与传统的层次化文件系统类似, 文档树也有一个根及一些包含若干子目录和文件(文档)的目录。WWW 服务器上的每个文档都有一个惟一的名称。该名称取从根“/”开始的路径, 所以一个名为 `tree.html` 的文件将可能有一个类似于 `/some/where/in/the/tree.html` 的完整名称。

但是需要特别注意的是: 在 WWW 服务器上包含 Web 文档的文件实际上可能有许多不同的组织方式。Web 文档树只是反映了一个具有复杂结构的文档集的简单视图。这个简单视图作用重大: 它帮助人们在复杂的服务器系统中能查找所需要的东西!

WWW 服务器上的每个文档都是文档树的一部分。它们有各自的名称, 从而使浏览器可以对它们包含的信息提出请求。HTML 文档中的超链接, 使用文档名来指向对应的信息。链接可以是文档的完整名称, 如:

```
http://www.server.org/there/silly.html
```

或是相对于当前文档的名称, 如:

```
./silly.gif
```

第二种方式表明 `silly.gif` 与包含该链接的文档处于同一路径(除了文件名外)。也就是说, 如果链接存在于 `/there/silly.html` 中的话, `silly.gif` 的全名将是:

```
http://www.server.org/there/silly.gif
```

相对名称通常用于内嵌的图像。一般地, 一个文档所含的各个部分都在 WWW 服务器的同一个地方。

需要特别强调的是, Web 文档树并非反映了 Web 文档的真正组织结构。那么, Web 文档为什么不组织成简单的树型结构呢? 这有很多原因。比如, Web 文档是由若干小组分别制作的, 他们每个都有自己的工作区和存储区; 再如, Web 文档太多, 使得只放在一个文件系统中, 甚至一台计算机上都显得过于庞大; WWW 服务器的流行与飞速发展, 也使得它有必要把文档分布到若干台计算机上, 以提高整个 Web 系统的最大可承受负载。

图 1.2 给出了 WWW 服务器上文档组织的三种重要形式。所有文档可以是位于一台机器上, 构成一棵树, 也可分散到几台机器上, 还可以在不同机器上对同一文档树进行镜像。需要注意的是, 尽管内部组织方式不同, 但对用户请求来说, 则无半点区别。