

Администрирование Linux

Лекция 11

Обзор Apache httpd 2.x

Иртегов Д.В.

Новосибирский гос. Университет

2014

Немного про протокол HTTP

- HyperText Transmission Protocol
- Первоначально разработан для передачи гипертекстовых документов HTML
- Используется для
 - Передачи статического и динамического контента веб-страниц,
 - Взаимодействия пользователей с веб-приложениями
 - Взаимодействия клиентских JavaScript программ с серверами
 - Взаимодействий сервер-сервер (гл. обр. XML/JSON RPC)
 - WebDAV, SVN over http, да тыщи их...

Логика работы протокола

- Логика, в основе своей, простая
 - Запрос-ответ
 - Данные и метаданные («заголовок»)
 - Основные типы запросов
 - GET uri ver – получить содержимое страницы
 - HEAD uri ver – получить метаданные страницы
 - POST uri ver – передать данные, например, заполненную форму
 - Основные типы ответов
 - 200 OK (далее идет заголовок и тело страницы)
 - 2?? – ответы с дополнительным сообщением, например
 - 204 No content
 - 206 Partial content
 - 3?? – «предупреждение»: запрос валидный, но что-то не так, например
 - 301 – Moved permanently (HTTP redirect)
 - 4?? – ошибочный запрос,
 - 404 – страница не найдена
 - 5?? – ошибка сервера
 - 500 – internal server error

Версии протокола

- HTTP 0.9 – до сих пор где-то ездят,
 - например, lynx(1)/links(1) рапортуют 0.9
 - Конкретно links можно мозги вправить
- HTTP 1.0 – считается устаревшей, но поддержка обязательна
 - На каждую пару запрос-ответ надо устанавливать соединение TCP
- HTTP 1.1
 - Connection pooling – много запросов в одном соединении
 - Набор обязательных полей в заголовке
 - Докачка (Range:)
- SPDY (HTTP 2.0 draft)
 - Request queueing
можно слать новые запросы, не дожидаясь окончания ответа
 - Фреймы: к какому запросу какая часть ответа относится
 - Теперь это, фактически, бинарный протокол
из телнета валидный диалог не проведешь
 - Header compression

Ключевые понятия – URL и URI

- Uniform Resource Locator

<схема>://<логин>:<пароль>@<хост>:<порт>/<путь>?<парам>#<якорь>

- Uniform Resource Identifier

/<путь>?<парам>#<якорь>

- Идентификатор ресурса в пределах сервера
- Выглядит как путь в файловой системе:
каталоги, разделенные прямыми слэшами
- НЕ ОБЯЗАТЕЛЬНО является путем в файловой системе
- Может содержать параметры (обычно у динамических ресурсов) и якорь

Ключевые понятия - заголовок

- HTTP header (метаданные)
- Основные поля запроса
 - host – должен совпадать с <хост> из URL, обязательно в 1.1
 - userAgent – тип браузера
 - Referer – откуда получена ссылка
 - Желательная кодировка и язык документов
 - Authorization
 - Cookie
- Основные поля ответа
 - MIME тип данных
 - text/html, image/jpeg, application/msword
 - MIME кодировка
 - KOI8, UTF-8, application/gzip
 - Дата модификации,
 - TTL, pragma: no cache – управление кэшированием
 - Длина (не обязательно)
 - Cookie

Ключевые понятия - прокси

- Прoxy – по русски, посредник
- Прямой HTTP proxy
 - вместо URI получает полный URL
 - Перенаправляет его целевому хосту
- Используются для
 - Кэширования
 - Снижения нагрузки на фаерволлы и NAT
 - Фильтрации трафика

Обратный прокси

- Стоит перед сервером или серверами
 - Клиент обычно не знает о его существовании
 - Получает URI и заголовок host
 - Перенаправляет его на определенный сервер или сервера
- Используются для
 - Кэширования
 - Балансировки загрузки
 - Доступа к серверам интранета
 - Интеграции веб-приложений, размещенных на разных серверах, в единый сайт

Популярные веб-серверы

- Apache httpd
 - Why Linux is like a wigwam?
 - All patches and feathers, apache inside
 - LAMP stack (Linux, Apache, MySQL, PHP)
- NGINX
- MS IIS
- Да тыщи их, на самом деле

Что умеет apache

- Раздавать статические ресурсы
 - Uri = имя файла относительно DocumentRoot
- Раздавать динамические ресурсы
 - CGI – Common Gateway Interface
 - Запуск на сервере практически произвольной программы с параметрами
 - Модули – расширения apache в виде специальных .so файлов
 - Например, интерпретаторы php, perl
 - FastCGI – протокол для общения со специальным сервером для запуска скриптов
 - fastcgiwrapper – довольно тупая запускатка
 - PHP FHM – довольно умная запускатка для скриптов PHP
- Делать всякие фокусы
 - Виртуальные директории
 - Виртуальные хосты
 - Mod_rewrite
 - Proxy redirect

CGI, FastCGI, модули

- Как выбрать способ запуска в конкретном случае?
 - CGI
 - Исполняются в отдельном процессе на том же сервере
 - + Можно исполнять что угодно например, скриптовые языки, для которых нет интерпретатора-модуля
 - + Если процесс помрет, серверу ничего не будет
 - + Можно использовать suexec запуск от имени владельца файла со скриптом используется в разделяемом хостинге, или если разрешают скрипты в домашних каталогах
 - - Запуск и уничтожение процесса – дорогая операция
 - - Инициализация среды исполнения происходит при каждом запуске
 - - Вместо падения, процесс может заиклиться или сожрать всю память
 - В юниксе есть квоты процессорного и астрономического времени, памяти и пр., но все это надо настраивать

CGI, FastCGI, модули

- Как выбрать способ запуска в конкретном случае?
 - Модули
 - Исполняются в контексте процесса Apache
 - + Инициализация среды исполнения происходит однократно
 - + Нет накладных расходов на запуск процесса
 - + Некоторые модули кэшируют скомпилированный код между запусками
 - - Код работает от имени пользователя apache
 - - Падение модуля убивает соответствующий процесс Apache умирает не весь Apache, а только один процесс, но
 - остальной апач это замечает не сразу,
 - перезапуск процесса – дорого,
 - поэтому частые падения снижают наблюдаемую производительность
 - - Утечки памяти в модуле жрут память процесса Apache
 - - Не все полезные программы доступны в виде модулей
 - - Не все модули совместимы с mpm_worker
 - - Некоторые модули имеют ограничения или другие отличия от автономной реализации

CGI, FastCGI, модули

- Как выбрать способ запуска в конкретном случае?
 - FastCGI
 - Исполняются в контексте отдельного постоянно запущенного процесса (или пула процессов), возможно на другом сервере
 - + Инициализация может происходить однократно
 - + Нет накладных расходов на запуск процесса
 - + Некоторые FastCGI серверы кэшируют скомпилированный код между запусками
 - + Некоторые серверы позволяют использовать аналог suexec
 - + Возможно распределение и даже динамическая балансировка загрузки
 - - Не все полезные программы доступны в виде умных FastCGI есть универсальный fcgiwrapper, но выгоды от него по сравнению с простыми CGI сомнительны

Конфигурация apache

- Состоит из
 - основного файла
в RHEL - /etc/httpd/conf/httpd.conf
 - Include-файлов
/etc/httpd/conf.d/*.conf
 - Файлов .htaccess в каталогах данных
- XML-like блочная структура
 - Сервер (верхний уровень)
 - VirtualHost
 - Directory[Match], Location[Match], Files[Match]
 - Условные директивы – IfDefine, IfModule

Демонстрация

- Файл `/etc/httpd/conf/httpd.conf` с настройками по умолчанию

Основные модули

- Core – собственно сервер
- Управление процессами и потоками
 - Prefork – apache 1.x совместимый много однопоточных процессов
 - Worker – многопоточные процессы
Выгоден по производительности,
но не все модули совместимы
(из популярных – mod_perl)

Настройки core

- ServerRoot – файлы с настройками
- DocumentRoot – файлы данных
- ScriptAlias – исполняемые файлы
- Listen – TCP порты
- User, Group
- LoadModule
- LoadFile – подгрузить .so, который сам не является модулем, но необходим для работы модуля
- TypesConfig, AddType – MIME типы содержимого
- AddHandler .ext – обработчик по расширению
- SetHandler – обработчик для всех файлов в каталоге, независимо от расширения
- LogLevel, LogFormat, CustomLog

Упражнение

- Поднять httpd с настройками по умолчанию
 - `yum install httpd`
 - `service httpd start`
 - `iptables -I INPUT 6 -p tcp --dport 80 -j ACCEPT`
- Открыть корневой документ в браузере
- Найти DocumentRoot в настройках сервера
- Подложить туда .html файл и открыть его в браузере

Настройки MPM

- MaxClient – количество одновременно обрабатываемых соединений TCP
 - Каждое соединение требует один
 - процесс (prefork)
 - нить (worker)
- ListenBacklog – очередь непринятых запросов TCP (если не указано, используется системное значение)
- StartServers, ServerLimit
- ThreadsPerChild (worker)
- MinSpareServers, MaxSpareServers – количество незанятых серверов
- MaxRequestsPerChild – после обработки такого количества запросов, процесс сервера перезапускается (защита от утечек памяти, в т.ч. в модулях)

О настройках MPM

- MaxClients – это количество одновременно активных соединений TCP. Оно определяется
 - Загрузкой сервера (hits per second)
 - Временем обработки одного запроса, которое определяется
 - Объемом передаваемых данных
 - Временем работы скриптов на сервере
 - Протоколом (HTTP 1.0, 1.1, SPDY)
 - Средней скоростью связи до клиента
 - Max – локальная сеть, интранет
 - Min – клиенты на GPRS/3G или на другом континенте
 - Если проблема в скорости до клиента, имеет смысл поставить NGINX
- Много клиентов – это много процессов/нитей, а каждый процесс и каждая нить потребляют память
 - По умолчанию, Linux/x64 – 8Мб стека на одну нить
- Также нити потребляют процессор
если загрузка процессора ~100%, добавлять процессы бессмысленно
- Увеличение количества нитей может упираться в какие-то другие лимиты, например, квоту на количество соединений с СУБД
- Мораль: универсальных рекомендаций нет, нужно мерить по ситуации

Поддержка SPDY

- В базовой поставке RHEL6 нету
- Нужно скачать модуль (.rpm) с сайта <http://code.google.com/p/mod-spdy/>
- Это не репозиторий yum, поэтому автоматического обновления не будет
- Работает только поверх https

Настройки директории

- Виртуальные каталоги
 - Alias URI `/directory/on/filesystem`
 - ScriptAlias URI `/directory/filesystem`
- Блоки
 - `<Directory shell-style wildcard>` - по файловой системе
 - `<DirectoryMatch regexp>`
 - `<Location wildcard>`, `<LocationMatch regexp>` - по URI
 - `<File wildcard>`, `<FileMatch regexp>`
- Директивы
 - AllowOverride – какие параметры можно менять в `.htaccess`
 - Order allow,deny
 - Allow/Deny all/IP[netmask]/domain name/env=value
 - DirectoryIndex (index.html)
 - Options FollowSymLinks, Indexes

Демонстрация

- Настройки директорий, виртуальные директории, локации и .htaccess в дефолтных настройках RHEL и на рабочих серверах

Redirect и ProxyPass

- По синтаксису похожи на Alias, но вместо пути указывается URL
- Redirect *URI URL* – http redirect
- ProxyPass *URI URL* – обратный прокси требует загруженного mod_proxy

Демонстрация

- Одинаковые директивы Redirect и ProxyPass в конфиге сервера, и разница в поведении браузера при открытии соответствующих URL

Виртуальные хосты

- <VirtualHost>: Port-based, IP-based
- <NameVirtualHost>: Name-based (HTTP 1.1)
- Виртуальный хост может иметь свои настройки
 - Свой DocumentRoot
 - Свой виртуальные каталоги
 - Почти все параметры можно поменять
 - Нельзя поменять список загруженных модулей
- Иногда вообще всю настройку сервера делают в виртуальном хосте (проще потом мигрировать с сервера на сервер)
- Настройка https делается только в виртуальном сервере
- Модуль vhost_alias обеспечивает генерацию виртуальных хостов по шаблонам

Демонстрация

- Описания виртуальных хостов на рабочих серверах

Обзор модулей

- Модули добавляют
 - Функциональность
 - Могут обрабатывать определенные файлы интерпретаторы языков, `imagemap`
 - Могут обрабатывать весь контент перекодировка, добавление полей в заголовок, кэширование
 - Могут сами генерировать контент `DirectoryIndex`, `ServerConfig`
 - Директивы конфигурации
 - Например, модули `auth*` добавляют директивы управления авторизацией

mod_rewrite

- распознает URL и поля запроса по шаблонам
- делает контекстные замены
- Может выполнять широкий набор действий по результатам распознавания
- Примеры
 - Прозрачная переделка статического сайта в динамический
`RewriteRule ^(.*)\.html$ $1.php`
 - Умная прозрачная переделка
`RewriteCond $1.php -f`
`RewriteCond $1.html !-f`
`RewriteRule ^(.*)\.html$ $1.php`
 - Защита от хотлинкинга картинок
`RewriteCond %{HTTP_REFERER} !^$`
`RewriteCond %{HTTP_REFERER} !www.example.com [NC]`
`RewriteRule \.(gif|jpg|png)$ /images/go-away.png [R,NC]`

Синтаксис

- RewriteRule *URIregex URIreplace [action/options]*
- *action*:
 - PT – passthrough, обработать результат замены как обычный URI
 - P,R – proxypass, redirect
 - F – forbidden (HTTP 403)
 - G – gone (HTTP 410)
 - CO – добавить к ответу cookie
- *options*
 - NC – nocase (шаблон не чувствительный к регистру)
 - B – escape backreferences
 - C – chain rule (следующие правила обрабатываются, только если текущее правило сработало. Аналог if)
 - N – next (после замены, правило выполняется еще раз. Аналог while. Как и настоящий while, может зациклиться)