

基幹系 WWW キャッシュサーバの運用実験について

5 T-7

鍋島 公章

NTTソフトウェア研究所

1. はじめに

WWWにおいても、情報の複製によるスケーラビリティの向上が求められている。このための一つの機構として、キャッシュサーバが注目され、広く使われている。しかし、次のような項目が課題として残っている。本運用実験では、これらを確立することを目標にしている。

- 運用上のノウハウ。
- キャッシングに必要な計算機資源の予測方法。
- OS, サーバソフトウェアの最適化方法。
- キャッシュサーバの定量的な有効性評価方法。
- 有効なキャッシュサーバ間の協調運用法。

本稿では、今までの実験で得られた運用上のノウハウと、キャッシングに必要な計算機資源についての解析の中間報告を行う。

2. 実験環境

実験用のサーバ(cache.imnet.ad.jp)は Sun Sparc Station-20 71(OS は SunOS 4.1.4)を使用し、512 MB のメモリとキャッシュ用ディスク 20GB(4GB SCSI-I ディスク5台)を用意した。使用したキャッシュサーバ・ソフトウェアは Squid Internet Object Cache [2]である。これを IMnet (Inter-Ministry research information network) 大手町 NOC の FDDI リングに接続した。

SunOS は、標準だとプロセスあたりの使用可能ファイルディスククリプタ(FD)数は 256 個である。これがボトルネックとなり、ユーザからの HTTP アクセスが頻繁にタイムアウトしていた。そのため、Sun DBE を導入し、使用可能最大 FD 数を 2048 個にした。これと同時に、OS 内部変数の一部を変更した。MAXUSER(この値を増やすことにより、各種 OS 内領域が大きくなる)の値を 64 から 128 に増加させ、UDP パケット処理のオーバフローを抑制した。また、SOMAXCONN(ソケットコネクション待ち最大数)は標準の 5 から 64 にまで大きくした。

An Experiment on Global WWW Cache Server Operation
Masaaki NABESHIMA (nabe@slab.ntt.co.jp)
NTT Software Laboratories

本研究は、科学技術庁の平成 9 年度科学技術振興調整費による「生活工学アプリケーション研究」の一環として行われている。

ただし、TCP チューニングとしてよく行われる TCP 送受信バッファサイズの拡張は行わなかった。これは、OS 内部メモリ(mbuf)管理テーブルがあふれ、通信ができなくなる可能性があるためである。標準の大きさのバッファサイズでは、確立された TCP コネクション数が 700 強、標準の 6 倍の大きさだと、TCP コネクション数が 100 強でバッファテーブルあふれが発生した。

3. 統計

ここでは、97 年 7 月 17 日の 1 日分のアクセスに関する統計情報を示す。Squid の使用していたプロセスサイズは 276MB であった。このうち、128MB はアクセスの中継と、メモリ上でのオブジェクト(本稿におけるオブジェクトとは HTTP アクセスによって得られる情報をさす)のキャッシュに使われていた。この 128MB の領域も、アクセスが多い日は使い切る場合があった。キャッシュディスク使用量は 17GB で、iostat コマンドにより計測したキャッシュ用ディスクの使用率はピークで 18%程度であった。1 日のアクセス総数は ICP¹:84 万アクセス、HTTP:40 万アクセス(3.7GB)であり、ヒット率は、ICP ベースで 24%, HTTP ベースで 48%であった。また、オブジェクトのキャッシュ内での生存時間は約 1 週間であり、キャッシュ量とトラフィック量のバランスは良好であると思われる。

グラフ 1 のように、ピーク時では、30 個程度の HTTP コネクション開始要求が待ち行列に入り、ファイルディスククリプタは 300 個程度使用していた。ICP リクエストの処理数は毎秒 18 リクエスト程度、HTTP リクエストは毎秒 8 リクエスト(80KB/秒)程度処理していた。これが、この実験サーバの限界であると思われる。

また、グラフ 2 のように、サーバ負荷のピーク時でも、キャッシュサーバ上で動いている HTTP サーバに、直接アクセスするのに必要な時間は 0.1 秒程度である。しかし、この HTTP サーバにキャッシュサーバ経由でアクセスすると、平均 3 秒以上必要としている。負荷の増加とともにキャッシュサーバでの中継レイテンシ(キャ

¹ Inter Cache Protocol: Cache サーバ間の問合わせプロトコル

クッシュサーバでオブジェクトがヒットした場合は、厳密には、中継は行わないが、本稿ではこれも中継レイテンシと呼ぶ)の増加は非常に大きいといえる。

4. 実験によって得られたこと

ここでは、今まで得られた運用上の注意点について述べる。

- Squid はログファイルを切替える際に、プロセスサイズの倍以上の仮想記憶領域を必要とする。
- 何らかの原因でサーバをリスタートした時に、キャッシングディスクからオブジェクトのメタ情報を再構築するのに約 12 時間かかる。この処理は重く、処理中はキャッシングサーバにおける HTTP 中継レイテンシが大きくなる。
- OS の限界付近で動いているため、不安定になりやすい。そのため、FDDI リングのような環境で使うには、マシンのダウンによるリング切断のリスクが大きい。
- Squid には、サーバ間で協調しあう機能があるが、現在、負荷を考慮したキャッシングサーバの選択機能がない。そのため、中継レイテンシが大きいが、アクセスは正常に受けるキャッシングサーバは、それと協調して動いている他のキャッシングサーバにとって、大きなボトルネックになる。つまり、その中継レイテンシの大きいキャッシングサーバからオブジェクトを取り出すより、元の WWW サーバから直接オブジェクトを取り出す方が速い場合でも—ICP により、情報がそのキャッシングサーバにあることがわかると—squid は無条件にそのキャッシングサーバからオブジェクトを取得する。キャッシングサーバの負荷に注意を払い、中継レイテンシを小さく押さえ続ける必要がある。

5. おわりに

この実験により、チューニングの余地はまだ残っているが、ある程度キャッシングサーバの処理限界が把握できた。Sun Sparc Station-20 71 の場合、HTTP 処理は毎秒 8 アクセス(80KB/秒)程度が限界である。このため、例えば外部に対して T1 リンク(180KB/秒)を持つ組織に必要なキャッシングサーバは本実験で使用したサーバの3倍の処理能力が必要であるといえる(4 割のトラフィックがヒットすると仮定した場合、キャッシングサーバが処理しなければならない流量は約 250KB/秒であるため)。


今後は、サーバのモニタリングの精度を高め、キャッシングサーバにおける中継レイテンシが何を要因にして大きくなるかを明らかにする予定である。

この実験の最新の情報は、cache.imnet.ad.jp のホームページ[1]を参照されたい。


謝辞

不安定な実験サーバの面倒をみてくださる IMnet 東京 NOC チームの方々、三上リーダーをはじめとするソ設グループ IMnet チームの方々に感謝します。

グラフ1：アクセス



グラフ2：負荷と中継レイテンシ



参考文献

- [1] 鍋島 公章, cache.imnet.ad.jp ホームページ, <http://cache.imnet.ad.jp/>
- [2] Duane Wessels, Squid Internet Object Cache, <http://squid.nlanr.net/Squid/>
- [3] Adrian Cockcroft (日本サンマイクロシステムズ監訳), Sparc & Solaris パフォーマンスチューニング