

## 2.5 プロキシサーバの評価

### 2.5.1 電子図書館とプロキシサーバ

今日、研究や開発が行われている電子図書館システムはネットワーク環境、特にインターネット環境に大きく依存している。世界をくまなく覆い、名実ともに世界最大のコンピュータネットワークとなったインターネットは電子図書館においても、そのアクセスを支える手段として非常に重要である。

このインターネット上のアプリケーションとして、現在もっとも多くのデータ交換が行われているのは World Wide Web と呼ばれるシステムであり、電子メールや ftp などと並んでインターネットの基本アプリケーションの一つに数えられている。

WorldWideWeb(Web)はインターネットを利用したハイパーテキストであり、物理学者のデータ手段として1989年に開発された。地球上をくまなく覆うようなハイパーテキスト環境はハイパーテキストの生みの親であるテッド・ネルソンのザナドゥという構想が最初であり、それを踏襲するように、Webはインターネットとともに、世界中へと広がってきている。

Webはインターネットにハイパーテキストとともにグラフィカルなユーザインターフェース、マルチプラットフォームの環境を実現したこともあり急速に広まっている。現在ではインターネット上でももっとも多く利用されるシステムとなっている。現在のWebのトラフィックはインターネット全体のトラフィックの80パーセントあるいはそれ以上を占めるに至り、初期のころには発生しなかったさまざまな問題が発生している。

一方、電子図書館のインターフェースとしてWebを用いることはその初期段階より広く行われており、本学でも1994年のプロトタイプ段階から現在稼働しているシステムに至るまで一貫してユーザのインターフェースとしてはWebを採用している。

Webのトラフィックが多量になるにつれ、サーバへの接続がうまく行かないなどのトラブルが発生するようになってきている。これを解決する一つのアイデアとして proxy サーバが考案された。proxy サーバは複数のクライアントの代理となってサーバへの接続を行う。この時に、一度アクセスされた情報を保持するなどの手法によりアクセスを集約することが出来るため、結果的にネットワーク上のトラフィックを削減したり、サーバへの接続コストを減らすことが可能となる。

さらに、インターネットの企業や組織での利用が進むにつれ、セキュリティの観点から Firewallなどを構築する場合が増えている。この場合には、組織内部のネットワークは間接的にしかインターネットにつながっておらず、何らかの手段でアクセスを中継してやる必要がある。そのため、Webのアクセスにおける proxy サーバの重要性はますます増している。

電子図書館のインターフェースとしてWebを利用している場合には、組織などからのアクセスを行う場合には、proxy サーバを経由することが一般的である。さらに、この proxy サーバでは全てのWebに関するトラフィックが集約されるために、電子図書館をふくめた全てのサービスの品質を決める重要な要素であるといえる。

特に、現在では出版社が自らデータを保存し、パスワードなどによりアクセスを制限す

るオンラインジャーナル方式が一般化しており、ますますネットワークを介した遠隔サーバへのアクセスの需要は高まって来ている。また、今後は多数の電子図書館が世界中に構築され、それらの相互接続によるサービスが一般化されると想定できるため、この Web のアクセスパフォーマンスの問題は電子図書館のユーザビリティの項目として非常に重要なものとなる。

しかしながら、オンラインジャーナルを含めたインターネット上の資源へのアクセスに重要な役割をはたす proxy サーバの性能に関しては十分な解析がなされているとはいえ、大部分の組織ではネットワーク全体の管理者が勘と経験を元に管理をしているにすぎない。そのため、過剰な設備を用意したり、組織の接続に十分なサーバを用意できていなかったりする場合が多い。

外部資源に対するユーザへの快適なアクセスの提供は十分な外部接続のための回線容量と、proxy サーバの性能の 2 つに依存すると言える。そこで、今回はこの回線容量と proxy サーバの性能の 2 つの関係に対し、実験および考察を行った。

### 2.5.2 WWW におけるプロキシサーバの位置付け

初期の WWW は データを保持するサーバとユーザの操作によりデータの取得、表示を行うクライアントの 2 つにより構成されていた。その後、トラフィックの削減や、Firewall の通過といった目的から WWW 専用のアプリケーションゲートウェイが用いられるようになった。このアプリケーションゲートウェイはクライアントの近傍におかれ、それぞれのクライアントプログラムの代理としてサーバにアクセスを行うため、proxy サーバと呼ばれる。現在では、組織などの単位で proxy サーバに情報を一時蓄積し、キャッシュとして利用することが一般的に行われている。また、Firewall 構築やセキュリティ上の問題、倫理上の問題などで全ての WWW アクセスをプロキシ経由のみに限る場合も増えて来ている。WWW は現在のインターネット上でもっとも広く用いられている情報検索システムであり、インターネット上のトラフィックの大半を占めている。よって proxy サーバは組織などがインターネットに接続し、情報を検索する上では非常に重要な部分を占めているという事ができる。

proxy サーバはアプリケーションゲートウェイとして動作し、クライアントおよびサーバの両方に対して、コネクションを維持する必要がある。通常、クライアントは LAN などの比較的高速な回線で接続されている場合が多いが、サーバ側はインターネットであり、通常は LAN ほどの帯域は用意されていない。

この非対象性により、proxy サーバは多大な負荷をうけることが容易に想像できるが、現在のところこのような帯域の非対象性を考えた性能評価は行われていない。

### 2.5.3 非対象なリンクにおける性能の評価

非対象なリンクを用いた場合には、対象なリンクとは違う振るまいを示すと考えられる。これは、帯域が制限された側のリンク (対外リンク) は回線速度が遅いため、データの転送に時間がかかるため、内部側のリンクも同様の待ち時間を必要とすることになる。しかしながら、内部リンクは高速なため、要求が次々とプロキシに到着することになる。

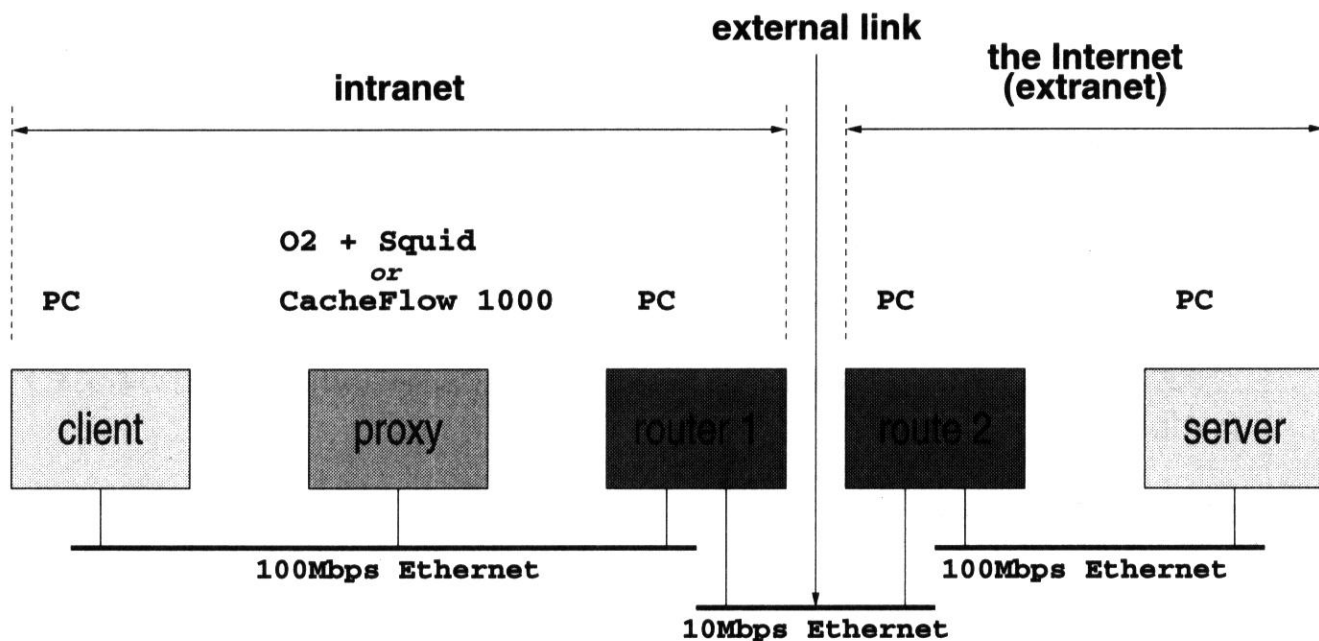


図 2.5.1 実験環境

これらの影響は、OS 内部の TCP/IP の QUEUE などに出ると考えられ、システム全体としてのスループットに影響が出ると思われる。

キャッシュサーバの定量評価を目的として Wisconsin Proxy Benchmark (WPB) や Web Porygraph といったベンチマークテストが開発されている。これらのベンチマークテストを用いることにより、キャッシュサーバの性能を比較することが可能になり、キャッシュサーバの定量的な指標の一つとして利用が考えられる。しかしながら、これらのシステムを用いた評価では、回線の帯域を考慮していない。

そこで本研究では、キャッシュサーバのベンチマークを行う場合において、均一でないネットワークを構築し、WAN と LAN をあわせもった環境を疑似的に構築することを提案する。不均一な帯域を持つネットワークを利用することにより、従来のベンチマークでは計測していない LAN と WAN のネットワーク帯域のギャップに起因する性能の劣化を発見できる。

#### 2.5.4 実験環境

実験環境を図 2.5.1 環境に示す。今回の実験では外部からの実験への影響を防ぐために、独立したネットワークを構築している。

イントラネット側に相当するセグメントには、クライアント用 PC とキャッシュサーバを 100BaseT のスイッチングハブを用いて接続した。

対外線に相当するネットワークの帯域を制限するために、FreeBSD 2.2.6 上に ALTQ を実装した PC を 2 台用意し、帯域制限ルータとしている。この 2 つのルータ上で CBQ を用いて帯域の制限を行った。CBQ はクラスベースの Queueing を行う機構であり、クラスご

との帯域を割り当てることが出来るため、今回はその機能を利用して帯域の制限を行っている。オリジンサーバ用 PC は 100BaseT によって帯域制限ルータに接続されており、クライアントおよびキャッシュサーバからは制限された帯域を利用してアクセスされる。オリジンサーバおよびクライアントの OS は FreeBSD 2.2.6 を用いた。

ベンチマークソフトウェアとしては WPB を元に変更を加えたものを利用した。WPB は専用のサーバ、クライアント、マスタープロセスの 3 つのパーツより成るベンチマークソフトウェアである。主な変更点としては、1) HTTP タイムアウト処理の追加、2) サーバプログラムのプリフォークとサーバ数の指定、3) 計測結果として 95percentile を利用の 3 点である。計測は SGI O<sub>2</sub> 上で動作する Squid および、CacheFlow1000 にて行い結果をグラフ化した。

### 2.5.5 結果および考察




図 2.5.2 Squid による取得時間

図 2.5.2 に O<sub>2</sub> で動作している Squid を用いた計測結果を、図 2.5.3 に CacheFlow を用いた計測結果を示す。どちらのグラフでも低帯域でのクライアント数の多い箇所はエラーのため有意なデータが計測できず、グラフ上にプロットされていない。

取得時間は帯域に余裕がなくなってくると飽和してくることが読み取れ、高速なキャッシュサーバを用いてもその限界点はかわらないことが判る。これらのグラフから対外線の帯域の影響はあきらかであり、帯域幅を決定することにより、サポートできるクライアントの数、限界となる遅延時間が決定できる。また、2 つのグラフを比較すると、CacheFlow は狭帯域でもエラーの発生が少なく、より多数のユーザ数をサポート出来ることが判る。

しかしながら、ほぼ同じ傾向のグラフを両者が示していることから、狭帯域の場合には高性能なキャッシュサーバであっても取得時間が向上しない。したがって今回の実験結果からは、ユーザに対して快適な環境である高速なサービスを提供するには、キャッシュサーバの増強よりもネットワーク帯域の増強を考えるべきであると結論できる。




図 2.5.3 CacheFlow による取得時間

今後の課題としては、さらに広範囲なキャッシュサーバでのデータの収集と解析を行う必要がある。また、現在のところは、対外線の影響として帯域幅の非対称性のみを考慮しているが、通信の遅延や揺らぎなどもキャッシュサーバの能力に大きな影響を与えていると推測出来る。そのため、これらを考慮したベンチマークシステムの構築が必要となる。