

Um modelo para avaliação de desempenho de servidores Web utilizando classificação de conteúdo

Carlos Marcelo Pedroso, Marcia Kotelok e Keiko Fonseca
Pós Graduação em Eng. Elétrica e Informática Industrial
Universidade Tecnológica Federal do Paraná - UTFPR
Av. Sete de Setembro 3165, Curitiba, Paraná, Brasil
Email: c.pedroso@pucpr.br, mkotelok@cpgei.cefetpr.br, keiko@cpgei.cefetpr.br

Abstract—Performance modeling is an important issue to capacity planning and overload control of Web servers. The main concerns of Web server performance modeling are related to the model complexity: the server traffic usually presents high variability, requiring self-similar models to describe it. In this paper, we propose a model for Web server traffic based on semantic classification of the server contents. Through the use of the proposed model, performance evaluation revealed simple, meaning more tractable, than the usual models reported at the researched literature. We present the new modeling approach and show that, the results achieved through it still keeps the necessary precision to a reliable analysis of the server performance. Also, the new approach opens new possibilities to build analytical models based on Markov chains.

I. INTRODUÇÃO

O desenvolvimento de modelos que permitam representar o desempenho de servidores Web é uma importante área de pesquisa. Bons modelos permitem realizar previsões acuradas sobre métricas de desempenho [1] e, a partir destas, por exemplo, o planejamento da capacidade do servidor, por exemplo. Entre as características desejadas para um modelo estão a sua simplicidade, obtida ao se restringir somente aos aspectos que influenciem significativamente no comportamento que se deseja analisar, e a sua tratabilidade, geralmente associada à complexidade de se gerar resultados analisáveis a partir do modelo.

Em se tratando de planejamento de capacidade de servidores Web, os modelos denominados de *modelos de desempenho* devem ser precisos para capturar o comportamento real do servidor: modelos inadequados poderiam resultar em super ou sub dimensionamento da capacidade do servidor.

Nos últimos anos, muito esforço tem sido realizado para desenvolver modelos que descrevem apropriadamente o tráfego de redes de computadores [2], [3] e [4]. O resultado destes trabalhos mostram que o modelo auto-similar descreve apropriadamente o tráfego agregado observado na saída de servidores Web. Um resultado importante é o fato que os modelos utilizados anteriormente, com os modelos Markovianos, não têm apresentado resultados satisfatórios para a modelagem do tráfego atual.

Um modelo de tráfego para servidores Web pode utilizar características de comportamento do usuário ou procurar modelar o sistema observando-se características do fluxo de pacotes. Neste artigo nós propomos um modelo de desempenho

para servidores Web utilizando a classificação semântica do conteúdo transmitido pelo servidor e características comportamento do usuário. Mostra-se aqui que o modelo proposto é tão preciso quanto os atualmente em uso, permitindo a análise de desempenho de servidores através de métodos analíticos de e simulações computacionais mais simples que os reportados na literatura estudada pelos autores. O modelo proposto baseia-se no fato observado de que o tamanho dos objetos de cada classe semântica não segue, via de regra, distribuições de cauda pesada e sim distribuições de decadência exponencial ou sub-exponencial. Com isto, evita-se as características pouco desejáveis para análise exibidas por distribuições de cauda pesada, como a não convergência do desvio padrão. Assim sendo, o uso da classificação semântica permite estabelecer um modelo mais realista para avaliação do desempenho de servidores Web.

A validação do modelo foi realizada a partir da análise estatística de dados de vários servidores que possuem seus arquivos de log disponíveis para uso em pesquisa, usualmente reportados na literatura relacionada a servidores Web [5]. Parametrizando o modelo com os dados destes servidores analisados, avaliou-se os resultados obtidos. A nova abordagem de construção de modelagem aqui proposta contribui em 3 pontos: possibilidade de análise de desempenho do servidor através de cadeias de Markov, geração de carga sintética para simulações computacionais envolvendo servidores Web e pesquisa de novas técnicas relacionadas a melhoria de desempenho de servidores (por exemplo, algoritmos de descarte de dados em cache).

Este artigo está estruturado da seguinte forma. A seção II descreve um modelo baseado na classificação semântica dos objetos transmitidos pelo servidor Web. As seções III e IV mostram a coleta de dados e a caracterização do tamanho de cada classe de arquivo. A seção V mostra a caracterização de um servidor Web utilizando-se o modelo proposto. As conclusões e trabalhos futuros são apresentados na seção VI.

II. UM MODELO COMPOSTO PARA SERVIDORES WEB UTILIZANDO CLASSIFICAÇÃO SEMÂNTICA DE CONTEÚDO

O modelo proposto é baseado no modelo SURGE proposto por Crovella e Barford em [6], que é um dos modelos mais citados para geração de tráfego Web. O modelo SURGE é

baseado em um autômato *ON-OFF* que captura o comportamento do usuário e dos arquivos armazenados no servidor. Quando o sistema está no estado *ON*, a sessão está ativa enviando os objetos requisitados na sessão. O intervalo de tempo entre os arquivos enviados durante a sessão é denominado de tempo *active-off*. O tamanho dos arquivos e o número de referências em uma sessão de usuário também são utilizados. As principais variáveis deste modelo são:

- *Tempo OFF*: É o tempo que o usuário permanece pensando. Normalmente modelado por uma distribuição de Pareto;
- *Tamanho dos arquivos*: É o tamanho dos objetos transmitidos. Normalmente modelado por uma distribuição de Pareto;
- *Número de referências*: Número de arquivos transmitidos em uma sessão de usuário. Também modelado normalmente por uma distribuição de Pareto;
- *Tempo active-off*: É o intervalo de tempo entre os arquivos transmitidos em uma sessão de usuário. Modelada pela distribuição de Weibull;
- *Popularidade*: É o número relativo de acessos realizados a um arquivo individual. A popularidade de arquivos em servidores Web segue, via de regra, a lei de Zipf [6];
- *Localidade temporal*: A localidade temporal refere-se que, uma vez tendo sido requisitado um arquivo, a probabilidade de que ele seja novamente requisitado no futuro aumenta.

Neste artigo nós propomos que os arquivos transmitidos pelo servidor sejam classificados em classes de arquivos para que depois as classes sejam estudadas para determinar a distribuição de probabilidade do tamanho dos arquivos de cada classe, como reportado anteriormente em [7].

Trabalhos importantes reportam que o tamanho dos arquivos transmitidos por servidores Web podem ser modelados por distribuições de cauda pesada, por exemplo, a distribuição de Pareto [2]. Existe grande dificuldade no tratamento matemático deste tipo de distribuição devido a sua grande variabilidade.

No modelo proposto, a atividade do usuário será modelada por um autômato finito como no SURGE. O estado *ON* será considerado como o tempo gasto em uma sessão ativa. Durante o tempo de uma sessão ativa serão produzidas requisições para transferência de diversos arquivos. Os arquivos transmitidos serão classificados em classes semânticas previamente identificadas com auxílio dos arquivos de *log* do servidor.

As demais variáveis, como o popularidade, localidade temporal e tempo *active-off*, continuam modeladas da mesma maneira proposta originalmente pelo modelo SURGE.

A cada sessão ativa de usuário, após a primeira requisição ser produzida, uma seqüência de arquivos será transmitida. Estas várias requisições serão produzidas para transferir todos os arquivos necessários para apresentar o conteúdo para o usuário. A Figura 1 ilustra um diagrama de estados hipotético utilizando uma classificação com três classes de arquivo: arquivos em formato de hipertexto (HTML), imagens em

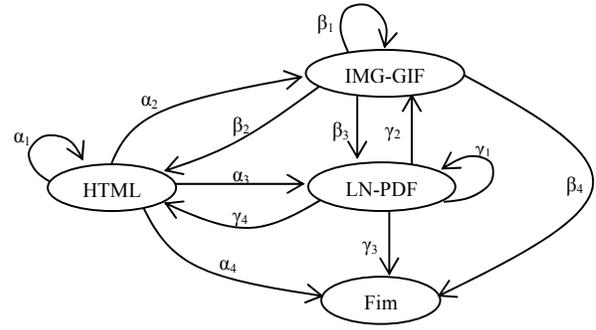


Fig. 1. Diagrama hipotético de classes semânticas para transmissão de objetos durante o estado *ON*

formato GIF (IMG-GIF) e notas de aula em formato PDF (LN-PDF).

A Figura 1 deve ser interpretada da seguinte maneira. Um acesso inicial a um arquivo pertencente à classe *HTML* será seguida por uma transmissão de um novo arquivo pertencente a outra classe de tráfego. No caso específico deste exemplo, α_1 , α_2 e α_3 representam as probabilidades do próximo arquivo transmitido pertencer respectivamente às classes *HTML*, *IMG-GIF* ou *LN-PDF*. α_4 é a probabilidade de não haverem mais requisições de transmissão de arquivos para esta sessão, iniciando-se um período *OFF*. A relação $\sum_{j=1}^i \alpha_j = 1$ deve ser sempre verdadeira. O mesmo ocorre para as probabilidades de transição a partir de cada uma das classes de arquivos do modelo. No exemplo, $\sum_{j=1}^i \beta_j = 1$ e $\sum_{j=1}^i \gamma_j = 1$ para as classes *IMG-GIF* e *LN-PDF*.

De modo genérico, pode-se representar o diagrama de estados da Figura 1 através de uma matriz quadrada *P* com as probabilidades de transição de estados, dada por

$$P = \begin{bmatrix} P_{00} & P_{01} & \cdots & P_{0i} \\ P_{10} & P_{11} & \cdots & P_{1i} \\ \vdots & \vdots & \ddots & \vdots \\ P_{(i-1)0} & P_{(i-1)1} & \cdots & P_{(i-1)(i-1)} \\ 0 & 0 & \cdots & 0 \end{bmatrix}$$

onde *i* representa o número de classes de arquivos, incluindo-se o estado representando o fim da sessão. Na montagem da matriz, o estado *i* é o estado que representa o fim da sessão. Para um estado *k*, $\sum_{j=1}^i P_{kj} = 1$ com $k \neq i$.

Este diagrama de transição de estados representa a sucessão de classes de arquivos transmitidos, e não o tamanho dos arquivos transmitidos em cada estado. O tamanho dos arquivos transmitidos em cada estado deve ser determinado através da análise dos arquivos do servidor. A determinação da distribuição de probabilidade de cada classe de arquivos tipicamente encontrada na Internet é mostrada na seção III.

A análise do arquivo de *log* irá revelar a quantidade de classes de arquivos do servidor. A montagem da classe pode facilitar a tarefa de modelagem do tamanho dos objetos, uma vez que a classificação pode ser realizada de acordo com diversos critérios. Neste trabalho, a classificação se fez apenas através da extensão do arquivo. A matriz de transições de

probabilidade entre as classes de arquivos para uma dada sessão também pode ser extraída dos arquivos de log, de modo a completar o modelo.

III. LEVANTAMENTO DAS CLASSES DE ARQUIVOS E DA MATRIZ DE TRANSIÇÃO DE ESTADOS

Os resultados aqui apresentados foram obtidos através da análise de coletas feitas pelo *IRCache*, que é um projeto do *NLANR* - National Laboratory for Applied Network Research[1]. Os servidores cache do *NLANR* registram os acessos de toda a Internet e estão geograficamente distribuídos pelo Estados Unidos da América para balanceamento de carga e de forma a atender todos os continentes. Desta forma, as milhares de requisições diárias destes servidores refletem o comportamento típico de acessos a servidores Web em geral, pois não se restringem a um grupo restrito de clientes ou a aplicações específicas. Os arquivos analisados no trabalho são apresentados na Tabela I.

TABELA I
SUMÁRIO DOS DADOS COLETADOS DO IRCACHE

Amostra	Cache	Data da coleta	Número de linhas
1	New York	28/11/2004	366.234
2	New York	29/11/2004	20.530
3	Palo Alto	29/11/2004	140.636

Utilizando uma heurística semelhante àquela desenvolvida originalmente por Mah [8] e por Barford e Crovella [6], foram identificadas as diversas sessões de clientes nos servidores Web em estudo. Para identificar as sessões foi produzido um software que identifica o primeiro acesso de um determinado cliente e busca pelas transições de requisições de classes de arquivos, apresentando como resultado a matriz de probabilidade de transição de classe de arquivos. O programa considerou um tempo limite de 120 segundos para concluir sobre a inatividade da sessão. Utilizamos o conceito de sessão para definir o período de tempo onde um cliente transfere uma página e em seguida outros arquivos referenciados por esta página, que podem ser chamados de objetos embutidos.

TABELA II
PERCENTUAL OBSERVADO EM RELAÇÃO AO VOLUME TOTAL TRAFEGADO

Classe de arquivo	Amostra 1	Amostra 2	Amostra	Média
GIF	5,84	7,86	5,98	6,56
HTML	22,11	15,71	20,94	19,59
JPEG	20,88	25,86	10,25	19,00
MPEG	4,22	3,7	3,11	3,68
OCTET-STREAM	13,85	28,07	20,15	20,69
Outros	33,1	18,8	39,57	30,49

IV. CARACTERIZAÇÃO DO TAMANHO DOS OBJETOS TRANSMITIDOS EM CADA CLASSE DE ARQUIVO

Foi realizada a caracterização do tamanho do arquivo transmitido em nas principais classes identificadas na Tabela II.

Para realizar o teste de aderência, a distribuição de probabilidade acumulada da amostra foi comparada com distribuições

clássicas de probabilidade. A distribuição lognormal (linha contínua) obtém uma boa aderência a praticamente todas as classes de arquivos. A Figura 2 mostra uma comparação entre a distribuição acumulada teórica (lognormal) e a distribuição amostral para as principais classes. O eixo horizontal x representa o tamanho do arquivo transmitido e o eixo vertical $P(X \leq x)$ indica a probabilidade acumulada.

Em todas as classes estudadas o tamanho dos arquivos mostrou decadência exponencial em suas funções de distribuição de probabilidade. Isto contrasta com a distribuição de cauda pesada reportada na literatura observada quando os arquivos são tratados em conjunto.

Mesmo para as classes menos importantes e não listadas na Tabela II o tamanho dos arquivos transmitidos pôde ser caracterizado por uma distribuição lognormal ou por uma distribuição exponencial.

V. CARACTERIZAÇÃO DE UM SERVIDOR WEB

Foi realizada a parametrização do modelo utilizando dados de um servidor Web já estudado na literatura [5], que foi o servidor Web da Copa do Mundo de 1998. Foram estudados 3 dias totalizando aproximadamente 40 milhões de requisições.

Como este servidor não é HTTP 1.1, não existem informações sobre início e fim de sessão de usuário. Para identificar as sessões foi adotado o mesmo procedimento descrito na seção III.

A Tabela III mostra a matriz de probabilidade de transição de classes obtidos a partir dos arquivos de log dos dias 27, 52 e 73 do servidor Web da copa do mundo de 1998.

Verifica-se a existência de poucas classes de arquivos que contribuíram significativamente com o tráfego de saída do servidor, o que permite a construção de um modelo bastante simplificado. Os tipos mais importantes foram HTML, JPEG, GIF e ZIP neste caso.

VI. CONCLUSÕES E TRABALHOS FUTUROS

O modelo auto-similar tem sido utilizado para caracterizar o tráfego produzido por servidores Web. Este modelo apresenta dificuldades para realização de estudos analíticos devido a sua tratabilidade [9]. Uma explicação para o fenômeno da auto-similaridade do tráfego é a distribuição de probabilidade dos arquivos transmitidos pelo servidor, onde os estes arquivos são caracterizados por uma distribuição de cauda pesada [2].

O modelo proposto neste artigo captura as características do tráfego realizando a separação dos arquivos transmitidos em diversas classes utilizando apenas a extensão do arquivo. No entanto, é possível classes baseadas em critérios mais refinados. Cada sessão irá transmitir uma seqüência de classes em uma seqüência modelada através uma máquina de estados.

Baseado no levantamento estatístico de servidores reais, concluiu-se que em cada classe, o tamanho dos arquivos de cada classe podem ser modelados de acordo com a distribuição lognormal ou exponencial. Isto representa um ganho em relação ao modelo SURGE que representa apenas o tamanho do conjunto total de arquivos tipicamente modelados através de distribuições de cauda pesada. Em um trabalho recente [10]

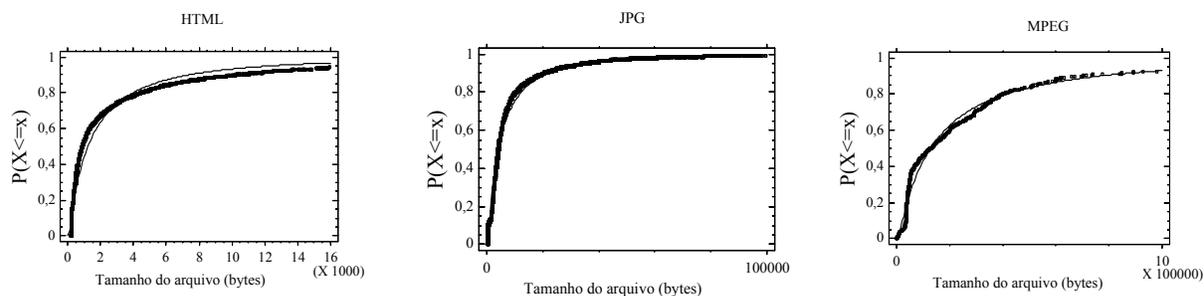


Fig. 2. Distribuição de probabilidade teórica (lognormal) e distribuição amostral para cada um dos conjuntos de dados

TABELA III
MATRIZ DE PROBABILIDADE TRANSIÇÃO DE ESTADOS PARA O SERVIDOR DA COPA DO MUNDO DE 1998

	HTML	JPEG	GIF	ZIP1	ZIP2	MOV	HQX	CLASS	PL	OUTROS	FIM
HTML	0.3105	0.0881	0.5244	0.0003	0.0002	0.0000	0.0000	0.0045	0.0002	0.0219	0.0495
JPEG	0.1279	0.3145	0.5075	0.0014	0.0002	0.0003	0.0000	0.0053	0.0002	0.0089	0.0333
GIF	0.0657	0.0346	0.8634	0.0001	0.0002	0.0000	0.0000	0.0110	0.0002	0.0064	0.0180
ZIP1	10.1539	0.0258	0.1658	0.2601	0.0159	0.0000	0.0001	0.0008	0.0025	0.0117	0.3630
ZIP2	20.0908	0.0122	0.1142	0.0091	0.1323	0.0000	0.0025	0.0008	0.0039	0.0039	0.6298
MOV	0.1234	0.1428	0.1076	0.0014	0.0014	0.3094	0.0000	0.0000	0.0000	0.0093	0.3043
HQX	0.0815	0.0163	0.1068	0.0036	0.0724	0.0000	0.1757	0.0000	0.0054	0.0126	0.5253
CLASS	0.0661	0.0202	0.8622	0.0000	0.0000	0.0000	0.0000	0.0217	0.0000	0.0042	0.0251
PL	0.0794	0.0451	0.3973	0.0008	0.0023	0.0000	0.0000	0.0002	0.2850	0.0067	0.1828
OUTROS	0.1830	0.0509	0.6424	0.0005	0.0003	0.0000	0.0000	0.0082	0.0002	0.0380	0.0761

apresenta as dificuldades na realização de testes de aderência entre dados reais e este tipo de distribuição. Além disso, as distribuições de cauda pesada apresentam-se difíceis em termos de análise matemática.

Como contribuições desta nova abordagem de modelagem citamos: a ampliação de possibilidades em termos de novos modelos analíticos, por exemplo, através de cadeias de Markov, uma geração de tráfego sintético mais precisa do que o SURGE através do refinamento em classes de arquivos e a novas possibilidades de pesquisa de técnicas de melhoria de desempenho de sistemas Web, por exemplo, o desenvolvimento de algoritmos de gerência de áreas de cache.

A caracterização do tráfego de um servidor Web através do novo modelo requer as seguintes informações:

- 1) Classes de arquivos transmitidos pelo servidor;
- 2) Média e desvio padrão do tamanho de cada classe de arquivo.
- 3) Probabilidades de transição de estados para transmissão de classes de arquivos em uma sessão;
- 4) Intervalo entre chegada de sessões.

Os dados necessários podem ser extraídos dos arquivos de log do servidor. Foram desenvolvidos programas para a extração e classificação dos dados dos arquivos de log de servidores Web.

O trabalho prossegue no desenvolvimento de um modelo analítico utilizando Cadeias de Markov e a avaliação da aplicação do modelo proposto através do software de simulação NS-2.

REFERÊNCIAS

- [1] Jianhua Cao, Mikael Andersson, Christian Nyberg, and Maria Kihl. Web server performance modeling using an M/G/1/K*PS queue. In *International Conference on Telecommunication (ICT 2003)*, February 2003.
- [2] M. Crovella and A. Bestavros. Self-similarity in World Wide Web traffic: Evidence and possible causes. *IEEE/ACM Transactions on Networking*, 5(6):835–846, 1995.
- [3] W.E. Leland, M.S. Qaqqu, W. Willinger, and D.V. Wilson. On the self-similar nature of Ethernet traffic (extended version). *IEEE/ACM Transactions on Networking*, 2(1):1–15, February 1994.
- [4] W. Willinger and K. Park. *Self-similar network traffic and performance evaluation*. John Wiley & Sons, New York, 1st edition, 2000.
- [5] Martin Arlitt and Tai Jin. A workload characterization study of the 1998 World Cup Web site. *IEEE Network*, 14:30–37, 2000.
- [6] Paul Barford and Mark Crovella. Generating representative web workloads for network and server performance evaluation. In *Joint International Conference on Measurement and Modeling of Computer Systems - Performance Evaluation Review (SIGMETRICS '98/PERFORMANCE '98)*, 1998.
- [7] Carlos M. Pedroso and Keiko Fonseca. Um modelo para avaliação de desempenho de servidores web utilizando classificação de conteúdo [short paper]. In *4th International Information and Telecommunication Technologies Symposium (I2TS2005)*, 2005.
- [8] Bruce A. Mah. An empirical model of http network traffic. In *INFOCOM '97: Proceedings of the INFOCOM '97. Sixteenth Annual Joint Conference of the IEEE Computer and Communications Societies. Driving the Information Revolution*, page 592, Washington, DC, USA, 1997. IEEE Computer Society.
- [9] William Stallings. *High-Speed Networks and Internets: Performance and Quality of Service*. Prentice Hall, New York, 2nd edition, 2002.
- [10] Wei-Bo Gong, Yong Liu, Vishal Misra, and Donald F. Towsley. Self-similarity and long range dependence on the internet: a second look at the evidence, origins and implications. *Computer Networks*, 48(3):377–399, 2005.