

Caracterização do Comportamento de E/S Utilizando Aprendizado não Supervisionado *

Pablo J. Pavan¹, Jean Luca Bez¹, Matheus S. Serpa¹,
Francieli Zanon Boito², Philippe O. A. Navaux¹

¹Universidade Federal do Rio Grande do Sul (UFRGS) - Porto Alegre - RS - Brasil

{pjpavan, jean.bez, msserpa, navaux}@inf.ufrgs.br

²Univ. Grenoble Alpes, Inria, CNRS, Grenoble INP, LIG, 38000 Grenoble, France

francieli.zanon-boito@inria.fr

Resumo. Nas aplicações de HPC operações de E/S são gargalos devido a diferença entre velocidade de processamento e de acesso a um dado. Assim, caracterizar as operações pode auxiliar na busca de desempenho. Deste modo, este trabalho propõe uma abordagem com aprendizado não supervisionado para a caracterização de E/S. Utilizando dados do supercomputador Intrepid, fomos capazes de identificar a principal característica de suas aplicações.

1. Introdução

As operações de E/S são um gargalo de desempenho em grande parte das aplicações devido a diferença entre velocidade de processamento e de acesso de um determinado dado. As operações são caracterizadas por padrões de acessos. Os padrões representam o modo que as aplicações acessam seus dados e este modo reflete no desempenho das mesmas. Portanto, é importante identificar e caracterizar os padrões, dado que assim podemos identificar possíveis gargalos. Com essa premissa, propomos uma abordagem de caracterização de E/S que usa aprendizado não supervisionado empregando o algoritmo *K-means* para agrupar *jobs* com comportamento de E/S similar usando informações de *profiling* reportadas pela ferramenta Darshan¹. Como estudo de caso, aplicamos nossa abordagem em quatro meses (Abril, Maio, Junho e Julho) de atividade — um total de 28.938 *jobs* — do supercomputador Intrepid localizado no Laboratório Argonne.

2. Trabalhos relacionados e Metodologia

Inúmeros trabalhos caracterizam E/S como os de [Zoll et al. 2010, Liu et al. 2016], porém, diferentemente destes, neste trabalho propomos uma abordagem de caracterização, não somente uma análise dos dados. Outros trabalhos como [Di et al. 2014, Calzarossa et al. 2016] aplicam abordagens de aprendizado não supervisionado na caracterização de *jobs* similares, porém não abordam a E/S considerando os padrões de acessos.

Nossa abordagem parte desde o arquivo gerado pelo Darshan até a utilização do algoritmo *K-means*. Primeiramente nós extraímos dos arquivos originais fases de E/S, estas representam momentos em que um *job* realizou uma operação de E/S caracterizada por um padrão de acesso. Após a extração criamos um conjunto de dados interpretado

*Trabalho financiado pela Petrobras sobre o projeto 2016/00133-9.

¹<https://www.mcs.anl.gov/research/projects/darshan/>

pelo *K-means* e aplicamos os métodos de *Silhouette* e *Elbow* para encontrar o número ótimo de grupos para cada mês. Aplicamos esta abordagem nos meses de forma separada, para podermos identificar as características que se mantiveram através do tempo e as que eram únicas. Para caracterizar cada grupo, foi escolhida a fase com mais porcentagem de tempo de E/S nos *jobs*, portanto cada grupo possui uma fase com principal característica. Para cada fase principal foi designado uma letra, para melhor compreensão.

3. Resultados Preliminares e Conclusão

Para cada mês tivemos números de grupos diferentes, foram 11, 10, 7 e 5 respectivamente para Abril, Maio, Junho e Julho. A Figura 1 mostra a porcentagem que cada fase representa no tempo de E/S de cada mês. O grupo **A** e o grupo **F** ocorrem em todos os meses, sendo que o grupo **A** apresenta um valor representativo no tempo de E/S de 59%, 26%, 46% e 24% respectivamente em cada mês. A fase principal deste é caracterizada por acessos de escrita consecutiva em arquivos únicos com tamanho de requisição entre 0 à 100 Bytes utilizando a interface POSIX. Este grupo também apresenta o maior número de *jobs* (22, 946 de um total de 28, 938), sendo que estes em média só realizam operações durante 2.41% do seu tempo de execução. Podemos assim concluir que o grupo **A** é caracterizado por um número alto de *jobs* que sozinhos realizam poucas operações de E/S, majoritariamente de escrita, mas juntos são responsáveis por boa parte da carga de E/S nos meses. Outros grupos também apresentam uma porcentagem na carga de trabalho de E/S, porém acontecem em menor frequência, ou somente uma vez. Alguns deles como **H**, **I**, **M** e **O** são caracterizados por *jobs* de uma única aplicação, assim, apresentam diferentes padrões de acessos em uma única fase de E/S.

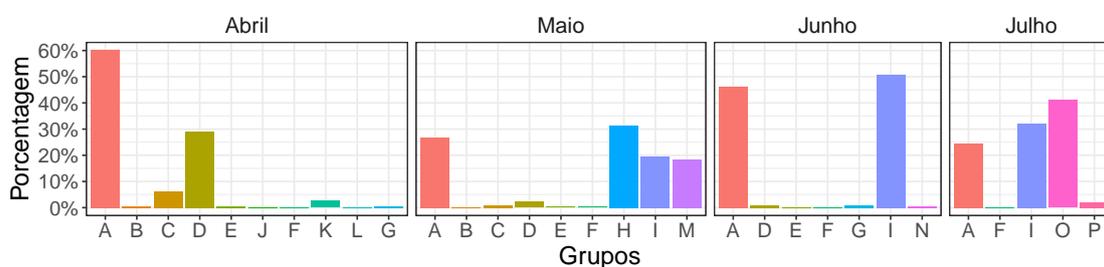


Figura 1. Porcentagem relativa das fases no tempo de E/S de cada mês.

Referências

- Calzarossa, M. C., Massari, L., and Tessera, D. (2016). Workload characterization: A survey revisited. *ACM Computing Surveys (CSUR)*, 48(3):48.
- Di, S., Kondo, D., and Cappello, F. (2014). Characterizing and modeling cloud applications/jobs on a google data center. *The Journal of Supercomputing*, 69(1):139–160.
- Liu, Y., Gunasekaran, R., Ma, X., and Vazhkudai, S. S. (2016). Server-side log data analytics for i/o workload characterization and coordination on large shared storage systems. In *SC'16: International Conference for High Performance Computing*, pages 819–829. IEEE.
- Zoll, Q., Zhu, Y., and Feng, D. (2010). A study of self-similarity in parallel I/O workloads. In *Mass Storage Systems and Technologies (MSST), 2010 IEEE 26th Symposium on*, pages 1–6. IEEE.