

Análise de um Serviço Virtual de Armazenamento em Nuvem Ciente de Padrões de Acesso por Usuários

Samuel de Oliveira Ribeiro[‡], Francisco Airton Silva[‡]
Alex Borges Vieira[◊], Glauber Dias Gonçalves[‡]

¹ [‡]Universidade Federal do Piauí - Campus Picos (UFPI)
samueloliveira0014@gmail.com, {ggoncalves,faps}@ufpi.edu.br
[◊]Universidade Federal de Juiz de Fora (UFJF)
alex.borges@ufjf.edu.br

Resumo. *O armazenamento de dados em nuvem vem se consolidando como um serviço atrativo para o usuário por oferecer facilidades para backup e compartilhamentos. Esse serviço pode ser realizado via um provedor virtual que aluga infraestrutura da nuvem para prover armazenamento a usuários domésticos ou empresas. Nesse artigo investigamos um aspecto chave para um serviço virtual de armazenamento em nuvem, que é a predição da frequência de acessos a dados para armazená-los em mídias de alta latência, ou seja, congelar dados sem acessos, e assim reduzir custos. Analisamos padrões de acesso a dados de usuários do Dropbox, e propomos um arcabouço para prever o momento adequado de congelamento de dados baseado no histórico dos acessos dos usuários. Nossos resultados, ainda preliminares, mostram oportunidades para um serviço virtual de armazenamento em nuvem com benefício para os usuários e uma economia de até 23% nos custos de armazenamento do serviço.*

Abstract. *Cloud storage has become an attractive service for users, given its easy use for data backup and sharing. This service can be managed by a virtual provider that uses cloud infrastructure to provide storage for home or business users. In this paper, we investigate a key aspect of a virtual cloud storage service, which is to predict the frequency of data access, thus storing data without access on high latency media, i.e., “cold storage”, thereby reducing costs. We analyze patterns of user data access in Dropbox and propose a framework for predicting the adequate time to move data to cold storage, based on user access history. Our preliminary results show opportunities for a virtual cloud storage service that either benefits users as well as saves up to 23% on storage costs.*

1. Introdução

O armazenamento de dados em nuvem é uma alternativa ao tradicional armazenamento de dados em dispositivos locais, que atrai cada vez mais adeptos dentre usuários domésticos e corporativos. Armazenar dados em nuvem oferece vantagens aos usuários como o backup com volume rapidamente escalável e replicado em localidades diferentes, além da possibilidade de compartilhamento de dados para a realização de trabalhos colaborativos. Existem diferentes modalidades de armazenamento em nuvem no mercado, desde os serviços de armazenamento em nuvem pessoal como Dropbox, Google Drive e Onedrive, utilizados em cerca de 36% dos domicílios em cidades europeias [Bocchi et al. 2015] e o

armazenamento em grandes provedores de infraestrutura como Amazon e Google Cloud, que oferecem kits de desenvolvimento e várias opções de acesso a dados e preços.

Um serviço de armazenamento em nuvem pode ser virtual, ou seja, o provedor armazena dados de usuários em máquinas virtuais alugadas dos grandes provedores de infraestrutura em nuvem, e adiciona a camada de serviços como o compartilhamento e versionamento de arquivos sobre os recursos de armazenamento.¹ A virtualização de armazenamento em nuvem, seja como um serviço comercial para usuários finais ou gerenciado por uma corporação, tem menor custo com o uso de opções de armazenamento, ciente dos padrões de acesso aos dados. Tipicamente, aplica-se os termos quente e frio para diferenciar as opções de armazenamento de acordo esses padrões. O armazenamento quente tem dados acessados frequentemente, e armazenamento frio tem dados infrequentes, que podem ser acessados via mídias de alta latência e menor custo [Irie et al. 2018].

Os principais provedores de infraestrutura em nuvem oferecem tecnologias de armazenamento quente e frio com diferentes custos e contratos de utilização.² Em geral, quanto mais frios os dados, menor é o custo de armazenamento e maior o custo para acesso quando necessário em termos de tempo ou penalidades de preço. Assim, um aspecto chave para o desenvolvimento de um serviço virtual de armazenamento é a predição da frequência de acessos a dados para o armazenamento quente ou frio. Nesse sentido, o serviço virtual deve alugar o mínimo de armazenamento quente por período de tempo (dia ou mês) para diminuir seus custos. Por outro lado, o provedor deve proporcionar satisfação aos seus usuários. Isso consiste em não congelar equivocadamente arquivos que serão brevemente acessados, dado a maior latência/custo para recuperação de dados do armazenamento frio, e ainda oferecer algum benefício para usuários que apresentam padrões de acesso frio e possibilitam redução de custos do serviço virtual.

Nesse artigo conduzimos uma investigação sobre a predição da frequência de acessos a dados para um serviço virtual que explora armazenamento quente e frio e características do usuário para predizer acessos a dados. Nesse sentido, buscamos responder as seguintes questões de pesquisa: *i) Qual o tempo em que dados podem ser movidos para armazenamento frio (congelados) com menos custo para um serviço virtual de armazenamento em nuvem e menos impacto na satisfação do usuário? ii) Características de acessos dos usuários podem levar a estimativas adequadas para esse tempo de congelamento?* Note que aprender características de usuários é necessário para oferecer benefícios de acordo a redução de custos que tais usuários trazem ao provedor.

Existem estudos na literatura que analisam padrões de acesso a dados com foco no desenvolvimento, desempenho e dimensionamento de infraestrutura [Kaushik and Bhandarkar 2010, Muralidhar et al. 2014, Irie et al. 2018, Hsu et al. 2018] para armazenamento quente e frio (Seção 2). Contudo, esses estudos não analisam padrões de acesso de usuários visando um serviço virtual de armazenamento em nuvem que traz benefícios para o provedor e o usuário conjuntamente. Para responder às questões acima mencionadas, propomos um arcabouço para gerenciamento de dados em um serviço virtual de armazenamento em nuvem, que aprende continuamente características dos usuários através do histórico dos acessos para predizer o momento adequado de congelamento de dados (Seção 3). Por conseguinte, realizamos

¹O Dropbox foi baseado na infraestrutura da Amazon até 2016, quando iniciou a construção de sua infraestrutura de armazenamento própria.

²<https://aws.amazon.com/pt/glacier> e <https://cloud.google.com/storage/archival>

uma avaliação experimental desse arcabouço utilizando traços de acessos de usuários coletados do Dropbox – o serviço pioneiro em armazenamento pessoal na nuvem. Os traços dos Dropbox foram usados para ajustar o modelo de predição do arcabouço e também para avaliá-lo (Seção 4).

As nossas análises mostram oportunidades para um serviço virtual de armazenamento em nuvem. Observamos que pelo menos 20% dos diretórios do Dropbox tiveram atividade apenas no primeiro dia de observação, ao passo que 30% dos diretórios tiveram atividades concentradas no primeiro mês. Além disso, menos de 12% dos usuários se enquadram em um perfil com dados majoritariamente frio, estando aptos a receberem benefícios do serviço por proporcionar redução de custos com armazenamento. Por conseguinte, conduzimos uma simulação do nosso arcabouço para fazer predições de congelamento de diretórios Dropbox, após um determinado período de aprendizagem de características de acessos dos usuários. Nosso arcabouço levou a uma economia de até 21% para um possível provedor virtual de armazenamento em nuvem. Em suma, esse estudo (ainda em estágio preliminar) traz as seguintes contribuições: (i) um arcabouço para gerenciamento automático de um servidor virtual de armazenamento em nuvem; e (ii) uma metodologia de aprendizagem automática e contínua de características de usuários para predição de tempo para congelamento de dados por usuário.

2. Trabalhos Relacionados

Existe uma variedade de estudos na literatura que analisam padrões de acesso a dados em sistemas de armazenamento. Os primeiros estudos dessa área focaram no desenvolvimento de infraestrutura com requisitos mínimos de desempenho para armazenamento quente e frio. Nesse sentido destacam-se [Kaushik and Bhandarkar 2010] e [Muralidhar et al. 2014]. No primeiro estudo, pesquisadores do Yahoo analisaram três meses de traços de usuários na versão comercial do sistema Hadoop e propuseram a variação *GreenHDFS*, que aloca arquivos infrequentes para servidores em modo de baixo consumo de energia, reduzindo gastos energéticos em 26%. No segundo estudo, os autores projetaram uma infraestrutura de armazenamento intermediária (morna) para dados que transitam entre acessos frequentes e infrequentes no Facebook.

Outros estudos tratam do dimensionamento de uma infraestrutura com suporte a armazenamento quente e frio. Em [Irie et al. 2018, Hsu et al. 2018] foi proposto um modelo para classificar arquivos do nível quente a frio de acordo várias características como tipo de arquivos, acessos e atividade dos usuários. Diferente do nosso estudo, esse modelo foi desenvolvido especificamente para ajustar o tamanho do armazenamento quente em sistema de armazenamento multi camada, reduzindo a predição de dados a um problema de políticas de caches.

Há ainda uma linha de estudos voltada para análise de desempenho e caracterização do comportamento de usuários em serviços pessoais de armazenamento na nuvem como Dropbox, Onedrive e Google Drive [Drago et al. 2012, Bocchi et al. 2015, Gracia-Tinedo et al. 2016]. Contudo, em nenhum deles os autores analisam padrões de acesso de usuários como uma oportunidade para desenvolver um serviço virtual de armazenamento em nuvem que traz benefícios para o provedor e o usuário conjuntamente.

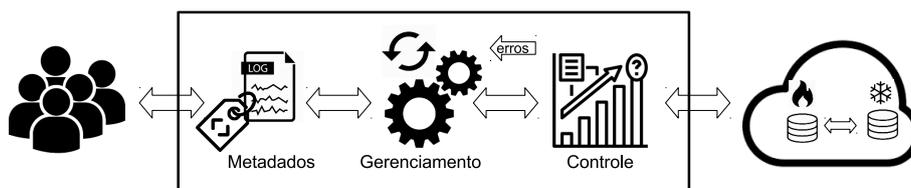


Figura 1. arcabouço para um servidor virtual de armazenamento na nuvem.

3. Serviço Virtual de Armazenamento em Nuvem

3.1. arcabouço

Nesta seção apresentamos o arcabouço para o nosso serviço virtual de armazenamento em nuvem. A Figura 1 mostra uma visão geral desse arcabouço, destacando os usuários e a nuvem, que são as entidades que o serviço interage, e os três componentes principais do serviço: (1) **metadados**, (2) **gerenciamento** e (3) **controle**. Note que setas indicam a dinâmica de funcionamento do serviço, dado o fluxo de dados entre as entidades usuário e nuvem. A seguir, descrevemos cada componente do serviço seguindo esse fluxo de dados.

O componente **metadados** é a interface de comunicação entre os usuários e o serviço. Esse componente recebe todas as requisições dos usuários e realiza autenticação para acesso ao serviço via um canal de comunicação criptografado. Além de armazenamento, o serviço deve oferecer visualização ou atualização de dados via diferentes dispositivos do usuário, assim como o compartilhamento desses dados com outros usuários. Portanto, esse componente deve manter informações dos arquivos gerenciados e dos usuários e dispositivos que podem acessá-los com suas devidas chaves de acessos. Todos os acessos são registrados e utilizados posteriormente para o gerenciamento do serviço.

O componente **gerenciamento** é o núcleo do serviço, que utiliza os registros de metadados para aprender características dos usuários e seus padrões de acessos, a fim de otimizar a operação do serviço. Esse componente gerencia todas as atividades do serviço desde políticas de acessos aos dados até detecção de ataques e ameaça a segurança dos usuários. Nesse artigo focamos em uma das funções mais importantes desse componente em termos de custos e viabilidade do serviço, que é a predição de acessos aos dados por usuários. Para isso, o serviço conta com um modelo de predição de acesso a dados que pode ser configurado para diferentes métodos estatísticos, ou algoritmos de inteligência artificial. A função desse modelo é estimar o período de tempo em que determinado conjunto de dados será acessado para determinar o momento de transferência para o armazenamento frio, ou seja, congelar esse conjunto de dados, que pode ser um arquivo ou um diretório de arquivos.

Por fim, o componente **controle** realiza a interface entre o serviço e a nuvem. Logo, esse componente tem a função de armazenar, recuperar dados na nuvem e escalar transferências entre os armazenamentos quente e frio. Para essas atribuições, o controle utiliza as estimativas de congelamento de dados do modelo preditor no componente gerenciamento. Dado essas estimativas, o controle armazena dados recém-gerados no armazenamento quente e escala a data para transferi-los para o armazenamento frio, ou armazena esses dados diretamente no armazenamento frio. O controle também recupera dados no armazenamento frio quando há erros de estimativas. Nesse caso, dados são transferidos para o armazenamento quente, e uma nova estimativa de congelamento é escalonada. É importante observar que a entidade nuvem pode ser composta por um ou mais

provedores de armazenamento terceirizados, que o serviço virtual estabelece acordos de nível de serviço e preços para armazenamentos quente e frio antecipadamente.

3.2. Módulo de Predição

Nesta seção, descrevemos o módulo de predição de acesso a dados que funciona no componente gerenciamento. Propomos esse módulo com dois princípios básicos. Primeiro, o módulo deve suportar diferentes modelos de predição desde estatísticas básicas a algoritmos complexos de inteligência artificial. Para isso, esse módulo tem as etapas de treinamento e teste do modelo de predição, como é tipicamente adotado na literatura [Hsu et al. 2018]. Segundo, o módulo deve suportar predições especializadas por usuários. Adotamos essa abordagem dado o intuito do serviço virtual oferecer benefícios a usuários, cujos padrões de acesso a dados propicia economia ao serviço.

Dado esses princípios, detalhamos agora as etapas de treinamento e teste do nosso módulo de predição. Ambas as etapas ocorrem em janelas de tempo, tipicamente dias ou meses, e são independentes por usuário. Assim, quando um novo usuário i registra no serviço, o modelo utiliza os registros do módulo metadados para aprender as características de acesso a dados desse usuário por um período mínimo de janelas de tempo, definido como L . O serviço utiliza armazenamento quente provisoriamente para os dados de usuários na etapa de aprendizagem.

Ao concluir o período L , o modelo entra na etapa de teste e está habilitado para estimar o período de atividade dos dados gerados pelo usuário i , definido como T_{ij} , com o índice j aplicado alternativamente para a aprendizagem de tipos distintos de dados (texto, imagem, vídeo, etc.). Especificamente, T_{ij} é o período estimado de acessos a arquivos ou diretórios de arquivos novos, gerados pelo usuário i , ou seja, o período em que esses dados devem permanecer em armazenamento quente. Além disso, T_{ij} é atualizado continuamente cada vez que o usuário i realiza um novo acesso a dados. O componente controle utiliza T_{ij} para escalonar a transferência de dados do armazenamento quente para o frio. Esse escalonamento ocorre a cada novo arquivo ou diretório de arquivos gerados pelo usuário i .

4. Avaliação Experimental

Nessa seção apresentamos uma avaliação experimental do arcabouço proposto para o serviço virtual de armazenamento em nuvem. Iniciamos apresentando a metodologia, para então apresentar nossos resultados.

4.1. Metodologia

Foram utilizados nesta avaliação traços reais de acessos a diretório de compartilhamentos do Dropbox coletados em nossos estudos anteriores [Gonçalves et al. 2016] em pontos presença (PoPs) de provedores de Internet residenciais.³ Esses traços mostram acessos a uma lista de diretórios compartilhados por usuários via Dropbox nesses PoPs, onde cada acesso tem IDs dos diretórios e o(s) respectivo(s) dispositivo(s) de usuários que fez o acesso (todos anônimos). Assim, esses traços nos permite estudar o padrão de acesso a dados no Dropbox, sem oferecer dicas sobre a identidade dos usuários ou o conteúdo armazenado no serviço. A Tabela 1 sumariza as informações desses traços utilizadas para

³Conjuntos de dados disponíveis no website dos autores <https://sites.google.com/a/ufpi.edu.br/traces>.

Tabela 1. Sumário dos traços de acessos a diretórios do Dropbox utilizados para a avaliação experimental

Rede	Dispositivos	Diretórios	Acessos (x1000)	Período
PoP-1	2300	6362	281	10/13-04/14
PoP-2	773	2597	364	07/13-05/14

essa avaliação. Dos dados originais selecionamos apenas dispositivos que acessaram as redes do PoP-1 e PoP-2 por pelo menos 60 dias para obter uma visão mais acurada dos padrões de acessos dos usuários desses dispositivos.

Conduzimos simulações e análises dos traços utilizando um modelo de predição simples e preliminar. Esse modelo consiste em calcular a média aritmética do tempo de acesso de todos os diretórios associados a um dispositivo de usuário (média por usuário). Esse tempo corresponde ao período entre o primeiro e último acesso a um diretório. Estabelecemos janela de tempo em um mês e o tempo mínimo de aprendizagem do método $L = 2$ meses. Após esse período, inicia-se a fase de teste do modelo, onde cada acesso a um diretório leva a uma predição do seu tempo de acesso e posterior escalonamento do congelamento do diretório. Em casos de erros, ou seja, acesso a um diretório já congelado, o modelo de predição é atualizado e um novo congelamento é escalonado.

Para avaliar a economia com redução de custos do modelo propomos a métrica *rcs* [Gonçalves et al. 2016], abreviação do inglês *relative cost savings*, dada por:

$$rcs_t = \frac{cost_hot_t - cost_hot_cold_t}{cost_hot_t}, \quad (1)$$

onde *cost_hot* é o custo do serviço virtual com todos os dados em armazenamento quente, ao passo que *cost_hot_cold* é o custo do serviço com a aplicação de nosso arcabouço que permite armazenamento quente e frio. Todos esses componentes na janela de tempo t .

Por questão de simplicidade, expressamos *cost_hot* e *cost_hot_cold* em função do número de diretórios acessados em t :

$$\begin{aligned} cost_hot_t &= \alpha * d_t \\ cost_hot_cold_t &= \alpha * h_t + \beta * c_{t,1} + \gamma * c_{t,0}, \end{aligned} \quad (2)$$

onde d_t é o total de diretórios, h_t é o número de diretórios com previsão de acessos em t (diretórios quentes), $c_{t,x}$ é o número de diretórios congelados corretamente ($x = 1$) ou equivocadamente ($x = 0$). Por sua vez, os valores α , β e γ representam respectivamente custos para armazenamento quente, armazenamento frio e recuperação de dados em armazenamento frio.

Parametrizamos o modelo para os resultados a seguir com o valores de d_t , h_t e $c_{t,x}$ coletados dos traços a cada janela de tempo. Por outro lado, utilizamos os custos $\alpha = 1, 0$, $\beta = 1, 5$ e $\gamma = 0, 3$, de acordo com custos reais dos armazenamentos padrão dos provedores Google e Amazon.

4.2. Resultados

Iniciamos discutindo padrões de acessos dos usuários. Nesse sentido, analisamos o tempo de *atividade* dos diretórios de usuários do Dropbox. Intuitivamente, usuários realizam

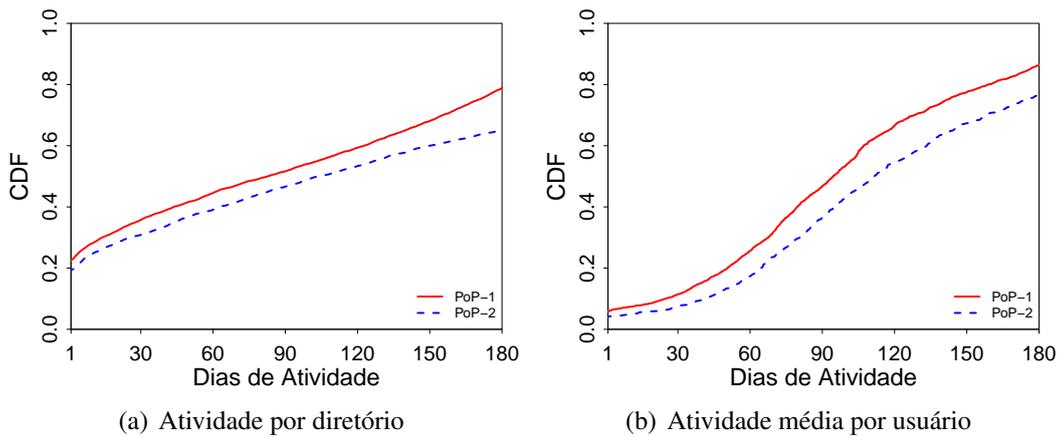


Figura 2. Distribuições acumuladas da atividade de diretórios (dias de acessos).

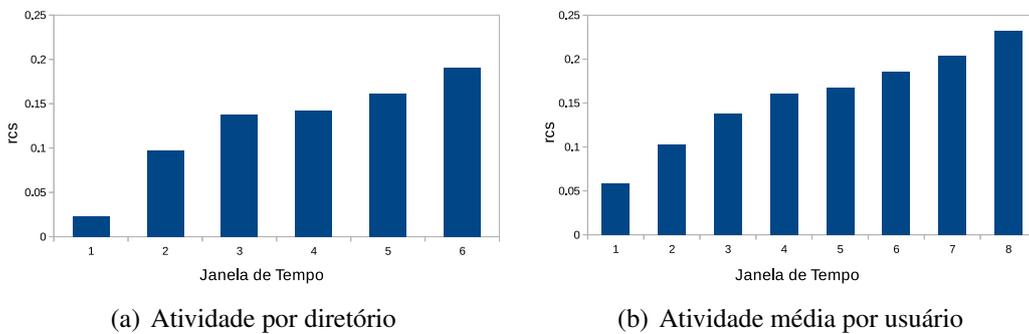


Figura 3. Economia do modelo proposto medida em rcs (relative cost savings).

vários acessos em um diretório, criando, removendo ou modificando arquivos, mas com o passar do tempo, essa atividade diminui, até que o diretório torna-se inativo, não recebendo mais acessos. A Figura 2(a) apresenta a distribuição acumulada (CDF, do inglês cumulative distribution function) do tempo de atividade dos diretórios em dias nos PoP-1 e PoP-2. Observa-se que pelo menos 20% dos diretórios tiveram atividade apenas no primeiro dia de observação, ao passo que 30% dos diretórios tiveram atividade concentrada no primeiro mês, mostrando assim um potencial de economia para o serviço com o congelamento de dados. Por sua vez, a Figura 2(b) apresenta CDFs para as médias do tempo de atividade dos diretórios por usuários. Pode-se observar que menos de 12% dos usuários tem média abaixo de 30 dias, apresentando assim um padrão de acesso com potencial para redução de custos. Esses usuários, portanto, poderiam receber benefícios de um possível serviço virtual de armazenamento. Tais benefícios podem variar de descontos no pagamento do serviço a bônus de armazenamento gratuito, que exploraremos em trabalhos futuros.

Analisamos agora como os padrões de acessos dos usuários analisados acima podem proporcionar economia ao serviço virtual com o arcabouço proposto. O nosso desafio aqui é prever a janela de tempo em que um diretório recente do usuário pode ser congelado com base em seu histórico de acesso a diretórios antigos. Para isso conduzimos uma simulação baseado nos traços de acessos dos usuários do Dropbox a partir do modelo e métricas mostrados na Seção 4.1. A Figura 3 apresenta os resultados do rcs (ver Eq. 2)

por janela de tempo para o PoP-1 e PoP-2. Observa-se que o r_{cs} obtido com congelamento de dados, aumenta ao longo do tempo, devido ao acúmulo de dados congelados. O modelo proposto segue essa tendência e alcança r_{cs} de 19% na sexta janela de tempo da simulação no PoP-1 e 23% na oitava janela de tempo no PoP-2. Consideramos a economia alcançada pelo modelo razoavelmente boa, dado que se trata de um modelo extremamente simples (média aritmética do histórico de acessos do usuário aos seus diretórios) para uma abordagem inicial a esse problema. Portanto, há oportunidades de melhoria desses resultados com modelos mais sofisticados, como algoritmos de aprendizagem de máquina, a serem avaliados na extensão desse trabalho.

5. Conclusões e Trabalhos Futuros

Nesse artigo, propomos um arcabouço para gerenciamento de dados em um serviço virtual de armazenamento em nuvem. Esse arcabouço é parametrizado com um modelo de predição que aprende continuamente características dos usuários através do histórico dos acessos para prever o momento adequado de congelamento de dados. Avaliamos esse arcabouço utilizando traços reais de acessos de usuários coletados do Dropbox. Nossos resultados preliminares são otimistas e mostram oportunidades para desenvolvimento de um serviço virtual de armazenamento em nuvem com benefício para os usuários com padrões de acessos majoritariamente frios (cerca de 12% em nossas análises) e uma economia de até 23% dos custos do serviço com armazenamento.

Em trabalhos futuros pretendemos incluir em nosso arcabouço mecanismos de incentivo para os usuários que propiciam redução de custos ao serviço como descontos no pagamento do serviço ou bônus na forma de armazenamento gratuito. Além disso pretendemos explorar modelos mais sofisticados, como algoritmos de aprendizagem de máquina, para predição de acessos a dados por usuários.

Referências

- Bocchi, E., Drago, I., and Mellia, M. (2015). Personal Cloud Storage: Usage, Performance and Impact of Terminals. In *Proc. of the IEEE CloudNet*.
- Drago, I., Mellia, M., Munafò, M. M., Sperotto, A., Sadre, R., and Pras, A. (2012). Inside Dropbox: Understanding Personal Cloud Storage Services. In *Proc. of the ACM IMC*.
- Gonçalves, G., Drago, I., Da Silva, A. P. C., Vieira, A. B., and Almeida, J. M. (2016). The impact of content sharing on cloud storage bandwidth consumption. *IEEE Internet Computing*, 20(4):26–35.
- Gracia-Tinedo, R., García-López, P., Gómez, A., and Illana, A. (2016). Understanding data sharing in private personal clouds. In *Proc. of the IEEE CLOUD*.
- Hsu, Y., Irie, R., Murata, S., and Matsuoka, M. (2018). A novel automated cloud storage tiering system through hot-cold data classification. In *Proc. of the IEEE CLOUD*.
- Irie, R., Murata, S., Hsu, Y., and Matsuoka, M. (2018). A novel automated tiered storage architecture for achieving both cost saving and qoe. In *Proc. of the IEEE SC2*.
- Kaushik, R. T. and Bhandarkar, M. (2010). Greenhdfs: towards an energy-conserving, storage-efficient, hybrid hadoop compute cluster. In *Proc. of the USENIX*.
- Muralidhar, S., Lloyd, W., Roy, S., Hill, C., Lin, E., Liu, W., Pan, S., Shankar, S., Sivakumar, V., Tang, L., et al. (2014). f4: Facebook’s warm blob storage system. In *Proc. of the OSDI*.