

Save the Data! An Intelligent Approach to Avoid Data Loss

Marcos Iseki, Bruno Nogueira, Brivaldo Jr
{iseki, bruno, brivaldo}@facom.ufms.br

Faculdade de Computação/UFMS

5 de outubro de 2017



Sumário I

Motivação

O contexto de falhas de HD

Como funciona a predição de HDs?

Trabalhos relacionados

Murray *et al.*: Métodos de aprendizado de máquina

Pinheiro *et al.*: Tendências de falhas em HDs

Pitakrat *et al.*: Comparação de algoritmos utilizando WEKA

Base de dados

Descrição

Avaliação da base de dados

Resultados

Avaliação dos resultados

Sumário II

Conclusão

Conclusão e trabalhos futuros

Referências

Por que estudar falhas de HD?

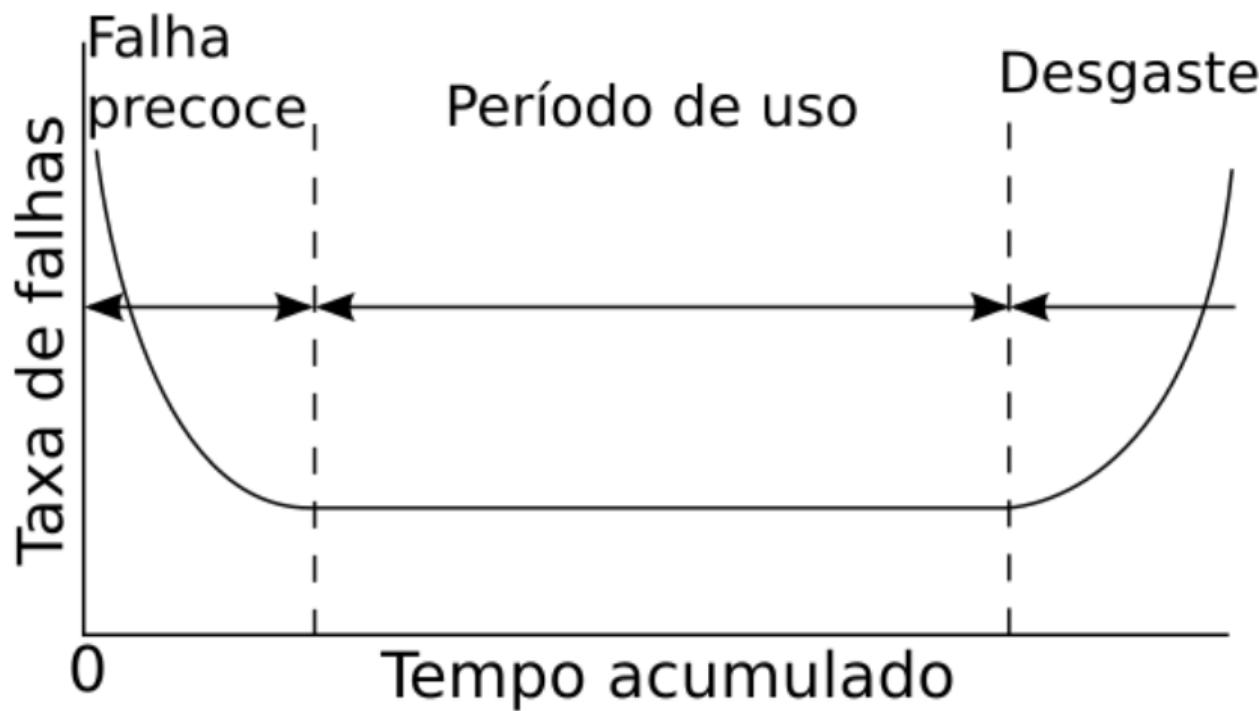
- ▶ Falhas de HD estão relacionadas a perda de dados (permanente ou temporária) [7].
- ▶ Os custos de tempo de trabalho e indisponibilidade de dados são altíssimos [6].
- ▶ Poucos usuários realizam backup diário de seus dados [5].
- ▶ O preço de armazenamento de dados na nuvem ainda é alto, principalmente para pequenas e médias empresas e consumidores.

Por que estudar falhas de HD?

- ▶ A capacidade de armazenamento de dados em data centers dobrou a cada ano, desde 2015 [2].
- ▶ A mídia de armazenamento mais comum ainda é o HD.
- ▶ Não é possível confiar nas especificações de fábrica sobre taxa de falhas anuais (AFR) [12] e o padrão de falhas denominado "curva da banheira" [10, 13].
- ▶ O preço médio cobrado pela recuperação de HDs é alto [3].

O contexto de falhas de HD

"Curva da banheira"



Como funciona a predição de HDs?

SMART

- ▶ *Self-Monitoring, Analysis, and Reporting Technology* é um padrão ATA desde 2003.
- ▶ O sistema analisa parâmetros do dispositivo de armazenamento e os compara com limites de funcionamento estabelecidos pelo fabricante.
- ▶ Durante a inicialização do SO, o SMART notifica o usuário sobre possíveis falhas.
- ▶ Assim, a utilização de algoritmos de aprendizado de máquina podem melhorar significativamente a detecção de falhas [8].

Murray *et al.*: Descrição do trabalho [9]

Base de dados

- ▶ 68.411 instâncias de 64 atributos de um modelo de HD.
- ▶ 369 HDs, sendo 191 com falha e 178 sem falha.

Resultados em destaque

- ▶ SVM com taxa de detecção de 50,6% e falso positivo em 0%.
- ▶ *Multiple Instance Naïve Bayes* (mi-NB) com taxa de detecção de 34,5% e falso positivo em 1,0%.

Algumas críticas

Base de dados

- ▶ Pequena quantidade de HDs, todos do mesmo modelo.
- ▶ Logs de SMART extraídos **após** HDs serem declarados com falha.

Resultados

- ▶ Resultados similares ou abaixo do desempenho de uma classificação randômica (50/50).

Pinheiro et al.: Descrição do trabalho [10]

Escopo

- ▶ Mais de 100.000 HDs rodando sistemas da Google.
- ▶ Infraestrutura de avaliação da qualidade dos HDs, incluindo parâmetros SMART.

Resultados em destaque

- ▶ Temperatura e nível de atividade possuem baixa correlação com falhas.
- ▶ Quatro parâmetros SMART têm maior impacto na probabilidade de falhas.
- ▶ AFR não segue o padrão da "curva da banheira".
- ▶ 36% dos HDs com falha apresentaram todos os parâmetros SMART zerados.

Algumas críticas

Base de dados

- ▶ Base de dados bem ampla, incluindo parâmetros externos (razão da falha) e do ambiente (temperatura).

Resultados

- ▶ Apenas três de 2.860 HDs com falha em nosso estudo apresentaram todos os parâmetros SMART zerados.

Pitakrat et al.: Descrição do trabalho [11]

Base de dados

- ▶ A mesma base utilizada por Murray et al.
- ▶ Pré-processamento com reclassificação (7_DAYS e INF), eliminação de parâmetros, e utilização da suíte WEKA.

Resultados em destaque

- ▶ Acurácia acima de 97% com KNN, *random forest*, C4.5, REPTree, RIPPER, PART e K-Star.
- ▶ Tempo de predição abaixo de 0,2s com *Bayesian network* e OneR.
- ▶ Baixa taxa de falso positivo com SMO e SVM.

Algumas críticas

Base de dados

- ▶ Além dos problemas com a base de dados utilizada por Murray, não foi possível verificar como os autores implementaram a reclassificação.

Resultados

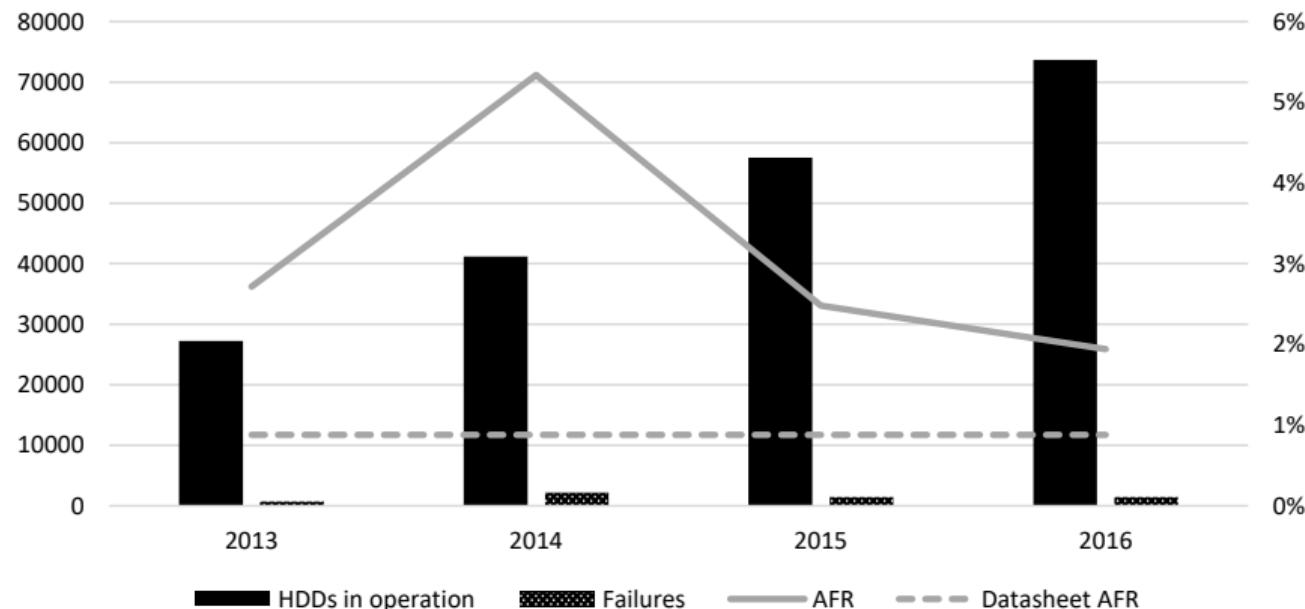
- ▶ A alta taxa de acurácia decorre do desbalanceamento de classes. Nenhuma técnica de balanceamento foi aplicada.

Descrição da base de dados utilizada neste trabalho

- ▶ Base atualizada pela Backblaze desde Abril de 2013, com acesso gratuito.
- ▶ Arquivos diários em formato CSV.
- ▶ Cada arquivo consiste de logs SMART de HDs em operação no dia. Ao fim de 2016, haviam 73.653 HDs.
- ▶ AFR médio de 3% de 2013 a 2016.

AFR médio 2013-2016 [4]

Annual Failure Rate (AFR)



Descrição da base de dados

- ▶ De 2013 a 2014, haviam 40 parâmetros SMART sendo coletados, e 45 a partir de 2015.
- ▶ Houve uma melhora significativa na qualidade dos dados coletados neste último período.
- ▶ Por esse motivo, decidiu-se utilizar os dados de 2015 e 2016 no treinamento e predição dos algoritmos.
- ▶ Cada linha do arquivo refere-se a um HD e as colunas são data, número de série, modelo, capacidade em bytes, falha (booleano), seguido dos parâmetros SMART.

Avaliação preliminar

Estatísticas 2015-2016

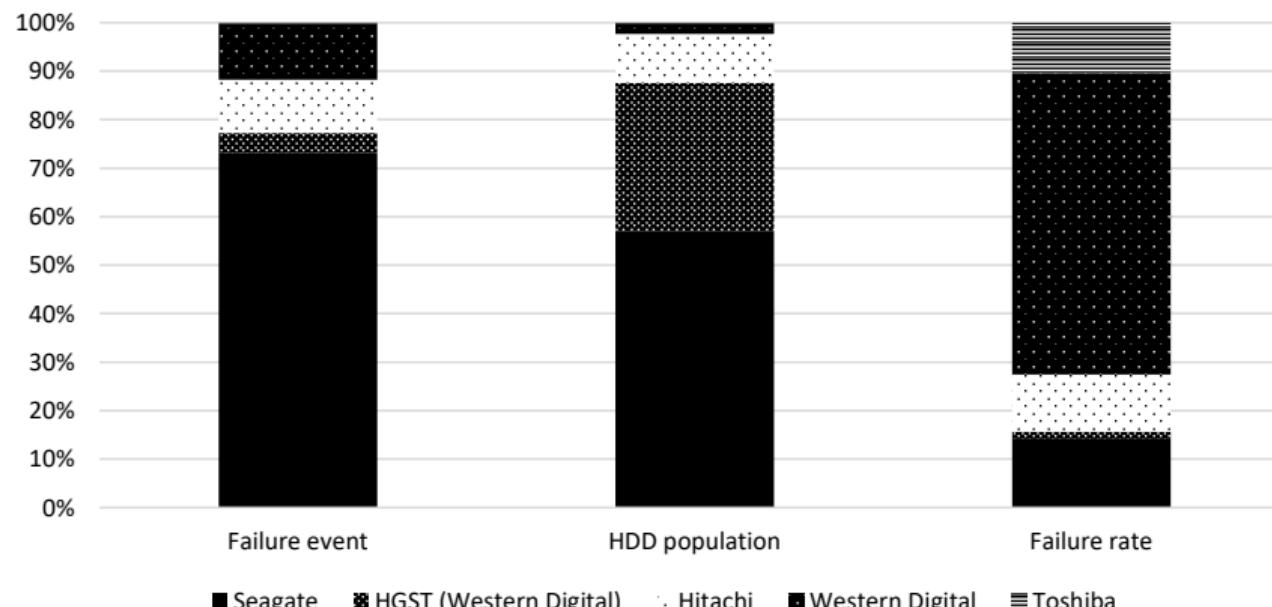
- ▶ Taxa de falha: 0,5% (HGST), 20,23% (Western Digital).
- ▶ População de HDs (fim de 2016): 24.545 (HGST), 45.531 (Seagate).
- ▶ Apenas três das 2.860 ocorrências de falha (0,001%) apresentaram todos os dados SMART zerados.

Conceito de falha de acordo com a Backblaze

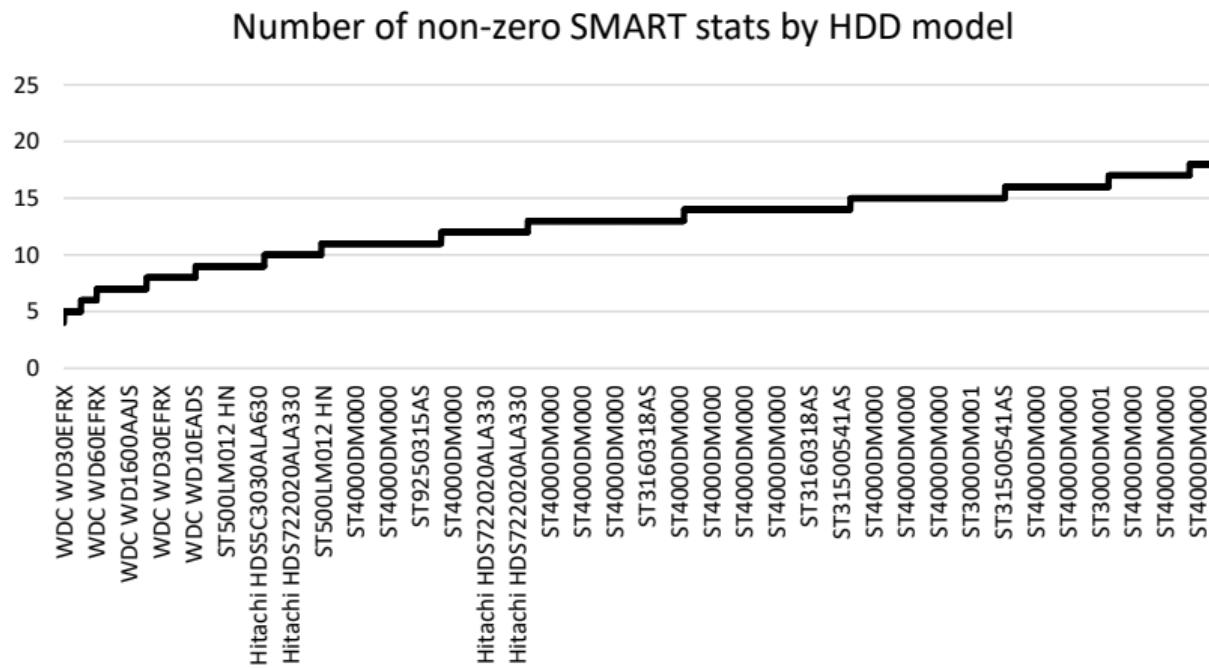
- ▶ O HD não rotaciona ou conecta ao SO.
- ▶ O HD não sincroniza ou permanece sincronizado ao sistema RAID.
- ▶ Algum parâmetro SMART acompanhado atinge um limite estabelecido pela empresa.

Descrição da base de dados [4]

Dataset description 2015-2016



Número de atributos SMART não zerados [4]



Avaliação preliminar

Características importantes

- ▶ A base de dados não informa o motivo da falha, assim um HD "saudável" do ponto de vista SMART pode ser considerado falho.
- ▶ A Backblaze acompanha cinco parâmetros SMART. Se um desses parâmetros atinge o limite estabelecido, o HD é considerado falho.
- ▶ Os dados SMART são expostos como contadores de ocorrência (com exceção de temperatura) e também dados normalizados, seguindo o padrão ATA. Contudo, nem todos os fabricantes seguem esta convenção.

Dados preliminares

Hardware e software utilizados

- ▶ Máquina equipada com Intel Core i7 3,4GHz, 32GB RAM.
- ▶ SO Ubuntu 16.04 LTS, Linux Kernel 4.8.0.
- ▶ Algoritmos em Python 2.7, Python scikit-learn 0.18.1, smartctl 6.6, pySMART 0.3 e dependências.

Pré-processamento

- ▶ Extração de todas as ocorrências de falhas e exclusão das três ocorrências com todos os parâmetros SMART zerados.
- ▶ Balanceamento de classes com *undersampling* [1], selecionando-se pseudo-randomicamente os arquivos.

Algoritmos de aprendizado de máquina

Treino e teste dos algoritmos

- ▶ Algoritmos testados:
 1. *Decision Tree* (DT);
 2. SVM *linear kernel*;
 3. SVM RBF *kernel*;
 4. KNN;
 5. *Multi Layer Perceptron* (MLP);
 6. *Naïve Bayes* (NB);
 7. *Multinomial Naïve Bayes* (MNB);
 8. *Bernoulli Naïve Bayes* (BNB); e
 9. *Logistic Regression* (LR).

Algoritmos de aprendizado de máquina

Ajuste de parâmetros

- ▶ Ajuste de parâmetros dos quatro primeiros algoritmos utilizando *Randomized Search on Hyper Parameters*.

Divisão dos dados e cálculo das médias de desempenho

- ▶ Dados divididos em 10 grupos com *Stratified K-Folds CV*.
- ▶ Cálculo das médias de 100 execuções.

Persistência

- ▶ Preparação de um modelo (*Decision Tree*) com persistência.

Resultados [4]

Algorithm	Accuracy	Precision	Recall	F1	AUC	Time (sec)
DT	0.80±0.06	0.88±0.03	0.70±0.13	0.78±0.09	0.80±0.06	0.02±0.01
MLP	0.71±0.04	0.72±0.06	0.70±0.10	0.70±0.05	0.71±0.04	6.74±4.84
KNN	0.76±0.07	0.82±0.04	0.66±0.14	0.73±0.10	0.76±0.07	0.05±0.01
NB	0.55±0.03	0.77±0.13	0.14±0.07	0.22±0.11	0.55±0.03	0.01±0.01
MNB	0.61±0.04	0.58±0.03	0.79±0.09	0.67±0.04	0.61±0.04	0.01±0.01
BNB	0.59±0.05	0.57±0.04	0.72±0.09	0.64±0.05	0.59±0.05	0.01±0.00
LR	0.75±0.04	0.81±0.03	0.66±0.07	0.73±0.05	0.75±0.04	0.37±0.10
SVM RBF	0.79±0.06	0.87±0.03	0.69±0.12	0.76±0.09	0.79±0.06	1.84±0.18
SVM Linear	0.78±0.07	0.80±0.05	0.75±0.14	0.76±0.10	0.78±0.07	0.85±0.11

Conclusão

Contribuições

- ▶ Dados SMART são apropriados para a predição de falhas de HD. A qualidade dos dados SMART aumentou significativamente se comparado com trabalhos passados.
- ▶ Foi possível aplicar os algoritmos de aprendizado de máquina apesar do padrão ATA não ser igualmente seguido pelos fabricantes.
- ▶ Com uma base de dados mais complexa e atualizada, foram obtidos resultados similares para *decision tree* e SVM, com 80% de acurácia, 88% de precisão e 12% de taxa de falso positivo. *Decision Tree* foi 92 vezes mais rápido que o SVM.

Trabalhos futuros

Algumas propostas

- ▶ Melhorias no ajuste de parâmetros dos algoritmos.
- ▶ Seleção de melhores atributos SMART.
- ▶ Clusterização de dados.
- ▶ Busca de bases de dados SMART sobre SSDs.

Referências I

-  Nitesh V. Chawla.
Data Mining for Imbalanced Datasets: An Overview.
Springer US, Boston, MA, 2005.
-  Cisco Inc.
Cisco Global Cloud Index: Forecast and Methodology 2015–2020, White Paper, 2016.
Online; accessed 2017-02-15.
-  Dell inc.
Data Loss: Understanding the Causes and Costs, white paper, 2016.
Online; accessed 2017-02-10.

Referências II

 Marcos Iseki, Brivaldo Junior, and Bruno Nogueira.

Save the data! an intelligent approach to avoid data loss.
2017. Text submitted to publication.

 Andy Klein.

Data Backup: Are You a Hero or a Zero?, 2016.
Online; accessed 2017-01-30.

 Kroll Ontrack Inc.

Lost Data? Reasons and Costs of Data Loss, 2010.
Online; accessed 2017-03-25.

Referências III

-  **Kroll Ontrack Inc.**
Hard Disk Drive (HDD) Crashes Remain the Leading Cause of Data Loss,
Survey Says, 2014.
Online; accessed 2017-03-25.
-  **Thomas M. Mitchell.**
Machine Learning.
McGraw-Hill Higher Education, 1997.
-  **Joseph F. Murray, Gordon F. Hughes, and Kenneth Kreutz-Delgado.**
Machine learning methods for predicting failures in hard drives: A
multiple-instance application.
J. Mach. Learn. Res., 6:783–816, December 2005.

Referências IV

-  Eduardo Pinheiro, Wolf-Dietrich Weber, and Luiz André Barroso.
Failure trends in a large disk drive population.
In *5th USENIX Conference on File and Storage Technologies (FAST 2007)*,
pages 17–29, 2007.
-  Teerat Pitakrat, André van Hoorn, and Lars Grunske.
A Comparison of Machine Learning Algorithms for Proactive Hard Disk Drive
Failure Detection.
In *Proceedings of the 4th International ACM Sigsoft Symposium on
Architecting Critical Systems, ISARCS '13*, pages 1–10, New York, NY, USA,
2013. ACM.

Referências V

-  **Bianca Schroeder and Garth A. Gibson.**
Disk Failures in the Real World: What Does an MTTF of 1,000,000 Hours Mean to You?
In *Proceedings of the 5th USENIX Conference on File and Storage Technologies*, FAST '07, Berkeley, CA, USA, 2007. USENIX Association.
-  **J. Yang and Feng-Bin Sun.**
A comprehensive review of hard-disk drive reliability.
In *Annual Reliability and Maintainability Symposium. 1999 Proceedings (Cat. No.99CH36283)*, pages 403–409, 1999.

Questões e comentários

Save the Data! An Intelligent Approach to Avoid Data Loss

Marcos Iseki, Bruno Nogueira, Brivaldo Jr
{iseki, bruno, brivaldo}@facom.ufms.br

Faculdade de Computação/UFMS

5 de outubro de 2017

