

# Estudo de Padrões de Acesso e Abordagens para Otimização de Acesso a Dados Distribuídos

Vinicius de Freitas Reis  
Rodrigo Fernandes de Mello

Instituto de Ciências Matemáticas e de Computação  
Universidade de São Paulo

II Escola Regional de Alto Desempenho de São Paulo –  
ERAD-SP 2011

# Motivação

- *Data Grids*;
- Replicação de arquivos:
  - tolerância a faltas, alto desempenho e balanceamento de carga;
- Ambientes globais, com milhares de computadores e arquivos;
- Problema de acesso a dados distribuídos;
- Discrepância entre tempos de acesso locais e remotos;

# Objetivo

- Investigar o comportamento de acesso a dados de aplicações reais;
  - predizer acessos a arquivos;
  - antecipar a transferência;
  - maximizar a taxa de acertos;
- Propor novas técnicas de replicação de arquivos.

# Metodologia

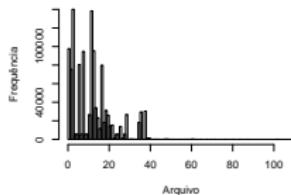
- Técnicas de modelagem de séries temporais foram estudadas;
- Duas técnicas de replicação de arquivos, baseadas na predição de séries, foram propostas;
- Traços de execução de aplicações reais foram convertidos em conjuntos de dados;
- Experimentos realizados:
  - Análise de Determinismo;
  - Análise de Padrões Frequentes;
  - Avaliação das técnicas de replicação.

# Análise e Predição de Séries Temporais

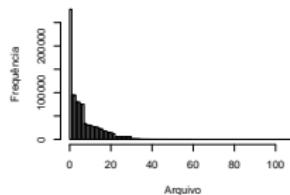
- Modelos estatísticos: AR, MA, ARMA, ARIMA;
- Sistemas Dinâmicos:
  - Teorema de Takens:  $(x_t, x_{t-d}, x_{t-2d}, \dots, x_{t-(m-1)d})$ ;
  - Dimensão de separação: Autoinformação Mútua;
  - Dimensão embutida: Falsos Vizinhos mais próximos;
  - Regressão no espaço fase permite predizer observações futuras;
  - Análise de comportamento: *Recurrence Plot*.

# Conjuntos de Dados

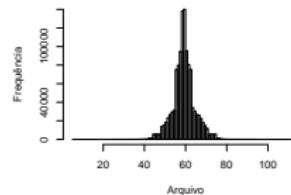
- Traços do repositório: SNIA IOTTA;
  - msn, bs: servidores de dados da Microsoft;
  - lair, deasn, home: servidores NFS;
  - seno, logis: dados sintéticos, com ruído aleatório;
- Variantes:



(a) variante A



(b) variante B



(c) variante C

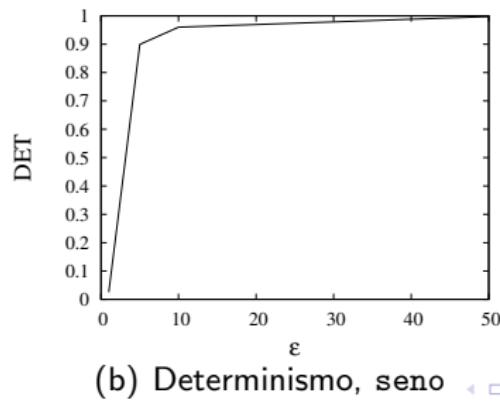
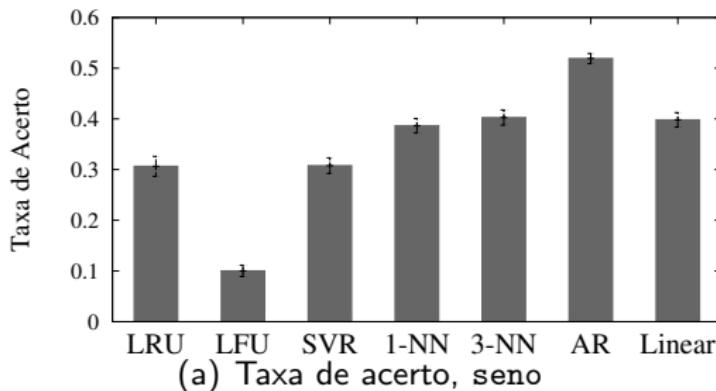
# Técnicas de Replicação

- Algoritmos clássicos:
  - LRU;
  - LFU;
- Abordagens de predição;
- Duas técnicas:
  - AR;
  - Sistemas Dinâmicos.

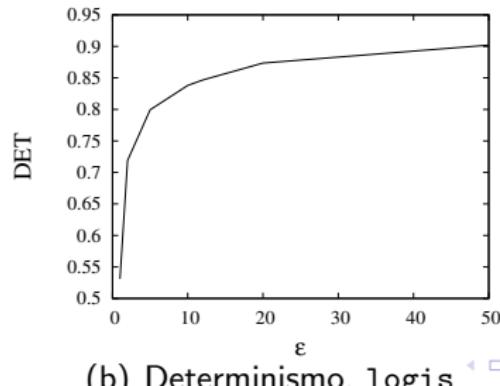
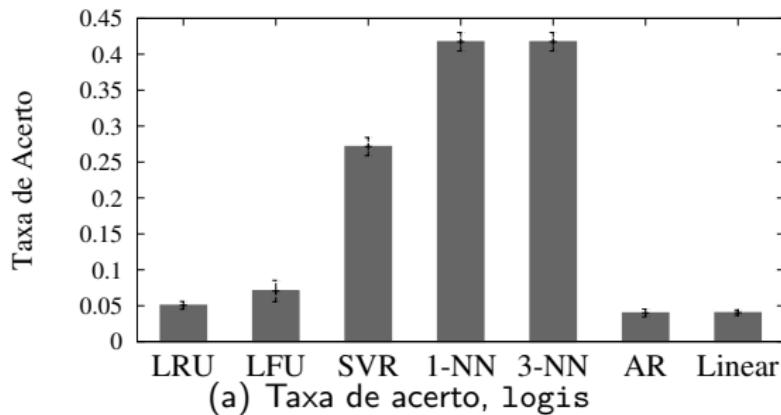
# Experimentos

- Dois experimentos de análise:
  - Análise de determinismo (*Recurrence Plot*);
  - Análise de padrões frequentes (*Suffix Arrays*);
- Experimentos de avaliação de taxa de acerto;

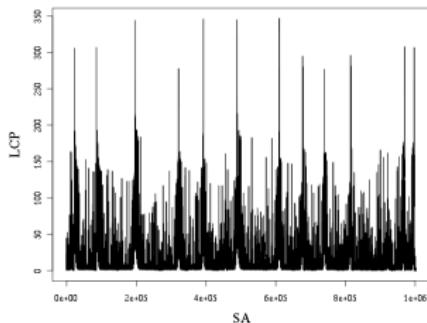
# Experimentos – seno



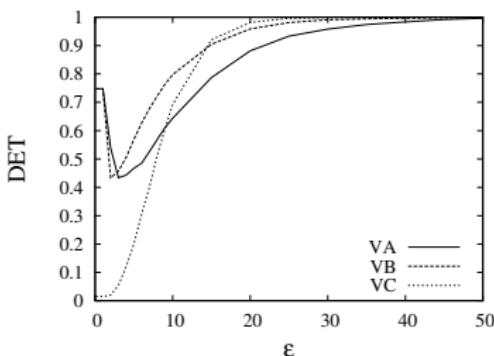
# Experimentos – logis



# Experimentos – msn

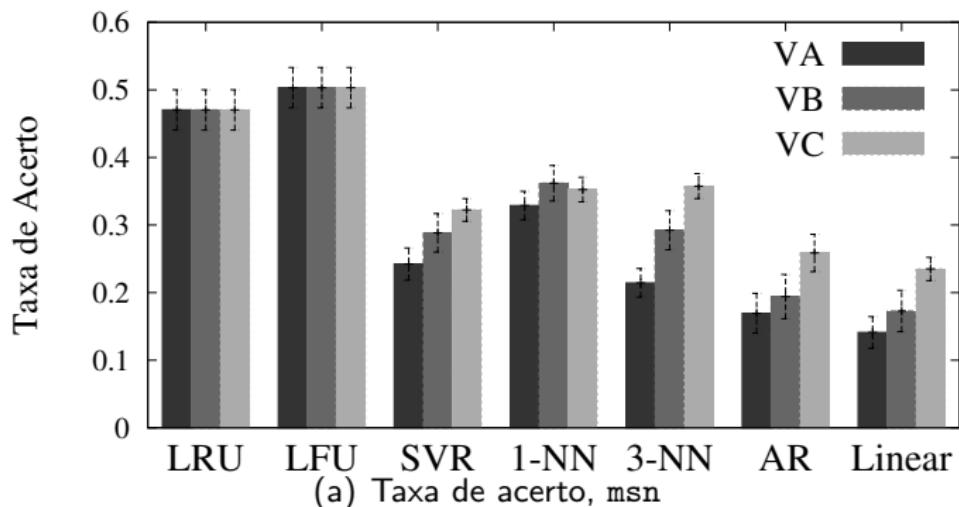


(a) LCP, msn

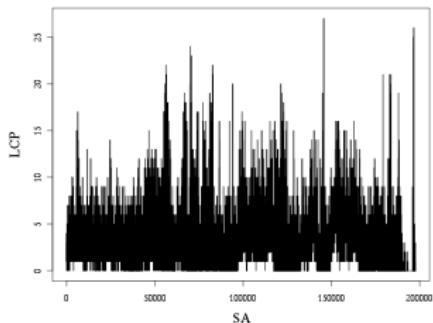


(b) Determinismo, msn

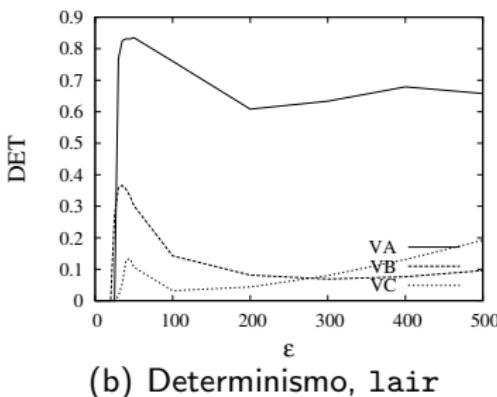
## Experimentos – msn



# Experimentos – lair

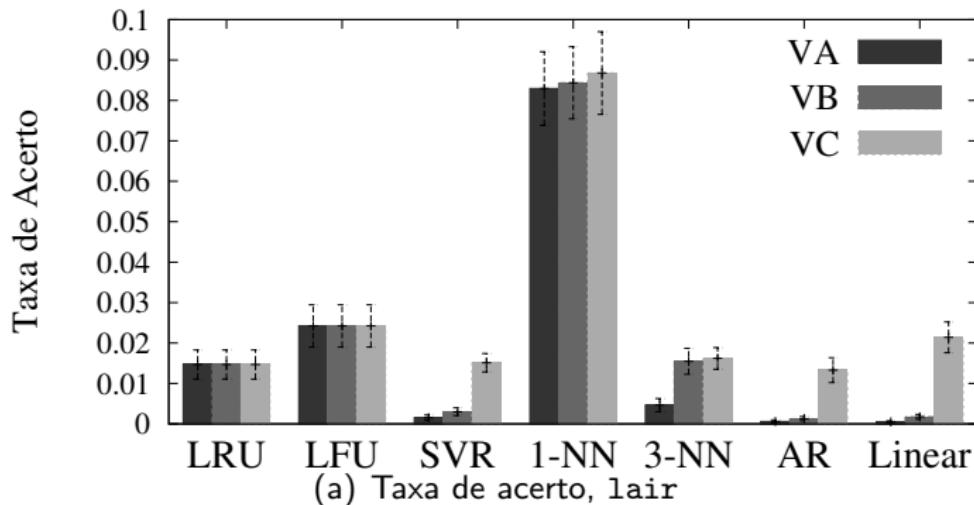


(a) LCP, lair



(b) Determinismo, lair

## Experimentos – lair



# Contribuições

- Proposta de duas técnicas de replicação de arquivos;
- Análises dos conjuntos de dados reais;
- Estudo da influência dos diferentes mapeamentos de arquivos em séries temporais na taxa de acerto das técnicas.

# Trabalhos Futuros

- Variação dos parâmetros  $w$  e  $s$ ;
- Agrupamento de observações;
- Redução de ruídos;
- Diferentes mapeamentos;
- Outros modelos de predição.

# Agradecimentos

