

# Avaliação de um mecanismo de previsão adaptativa de perdas de pacotes com aplicação à transmissão de Voz sobre IP

Fabrcio Murai, Hugo Hidequi Sato, Edmundo de Souza e Silva, Daniel Ratton Figueiredo

UFRJ - COPPE/PESC - LAND

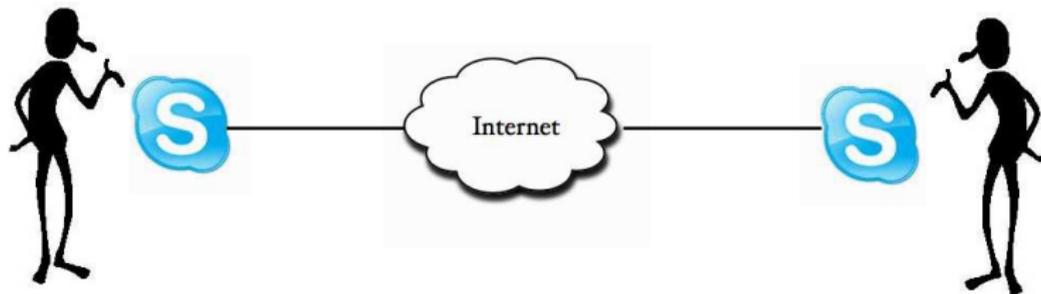
WPerformance, 2008



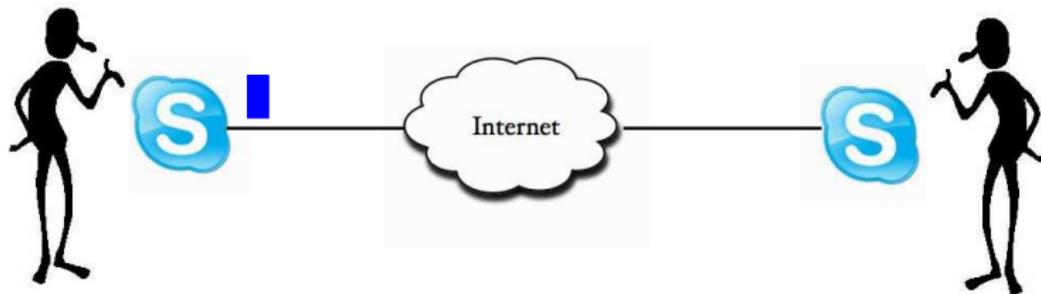
# Índice

- 1 **Introdução**
- 2 **Mecanismo de previsão adaptativa**
- 3 **Avaliação da Previsão**
- 4 **Avaliação da Recuperação**
- 5 **Conclusões**

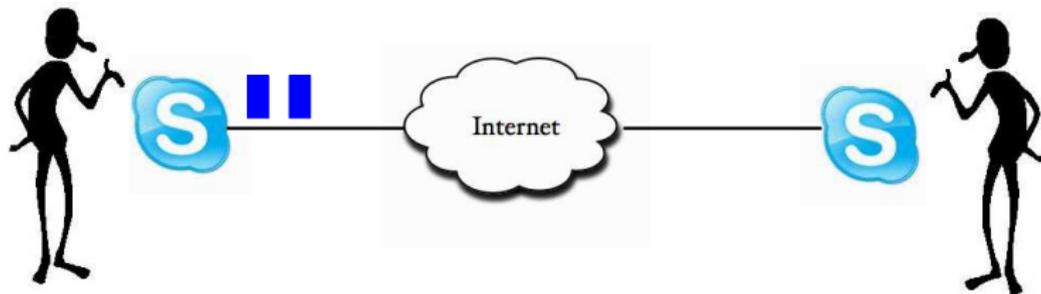
## Aplicações Multimídia em Redes



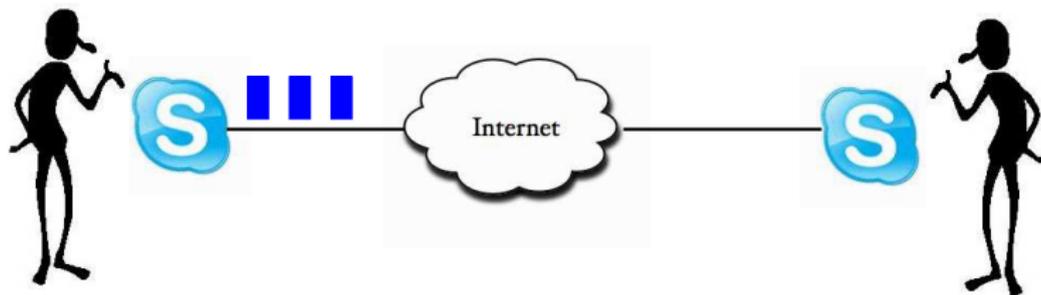
## Aplicações Multimídia em Redes



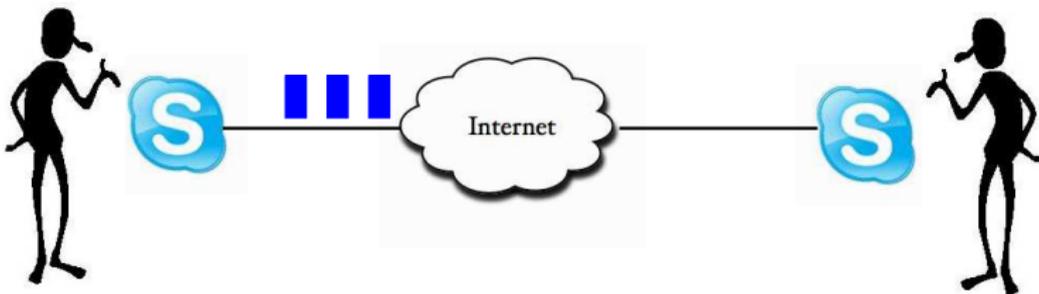
## Aplicações Multimídia em Redes



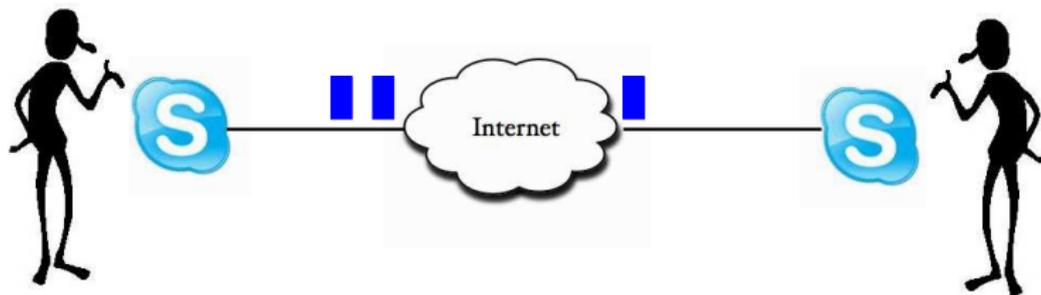
## Aplicações Multimídia em Redes



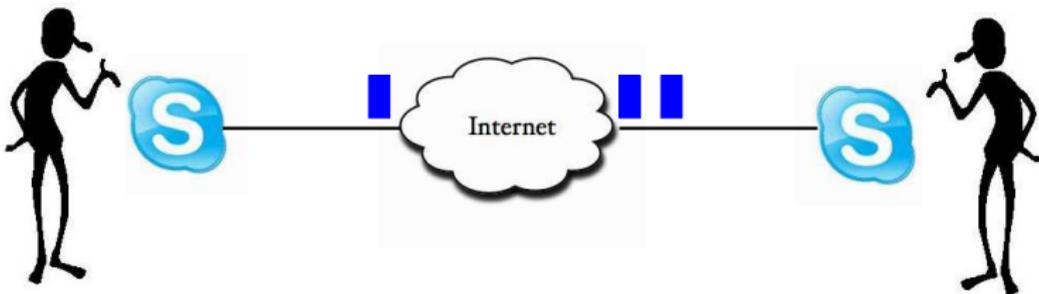
## Aplicações Multimídia em Redes



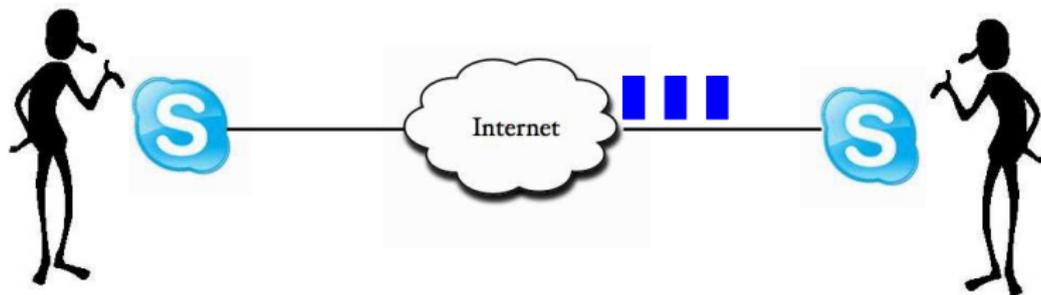
## Aplicações Multimídia em Redes



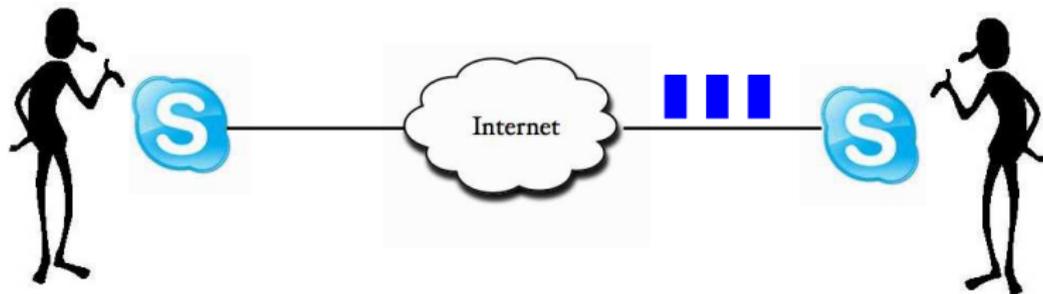
# Aplicações Multimídia em Redes



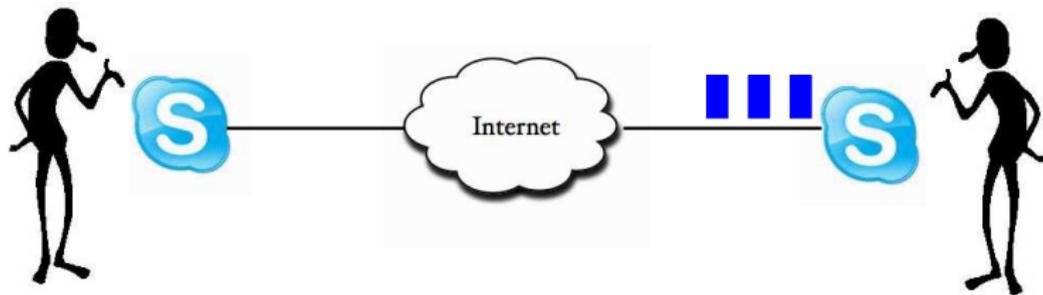
## Aplicações Multimídia em Redes



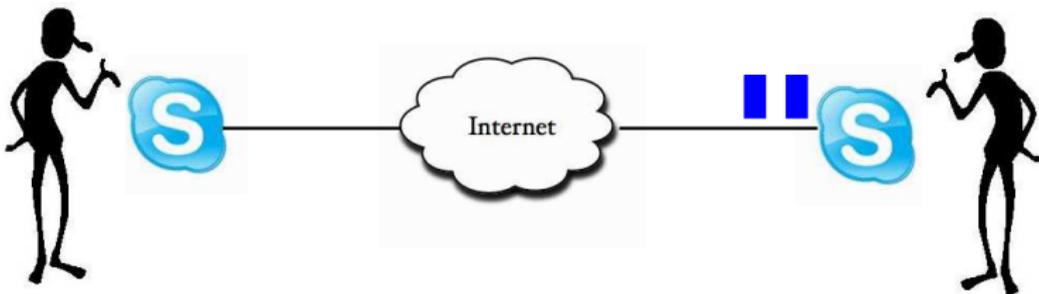
## Aplicações Multimídia em Redes



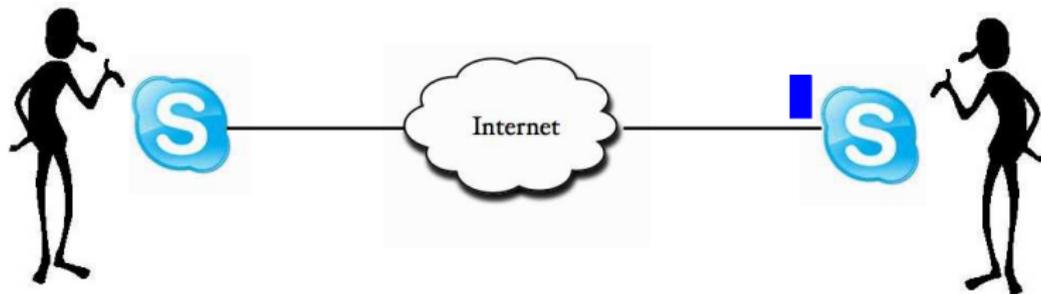
## Aplicações Multimídia em Redes



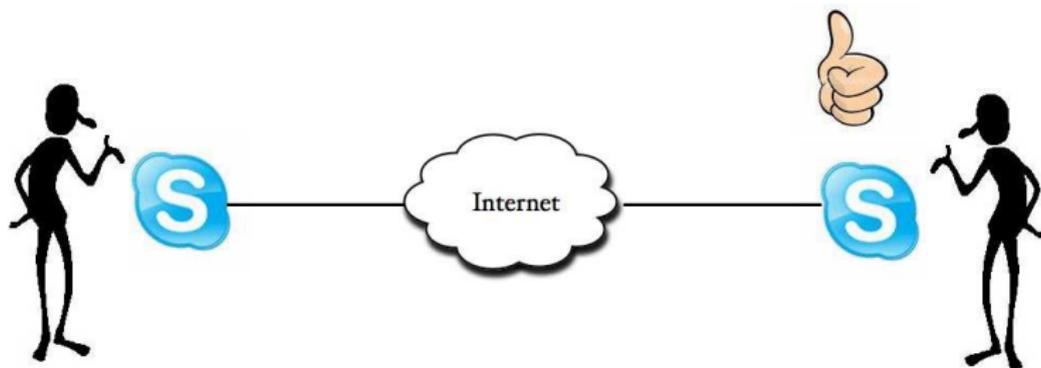
## Aplicações Multimídia em Redes



## Aplicações Multimídia em Redes



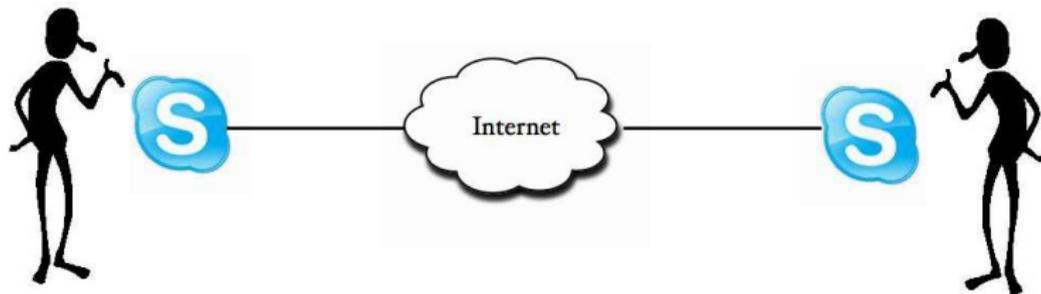
## Aplicações Multimídia em Redes



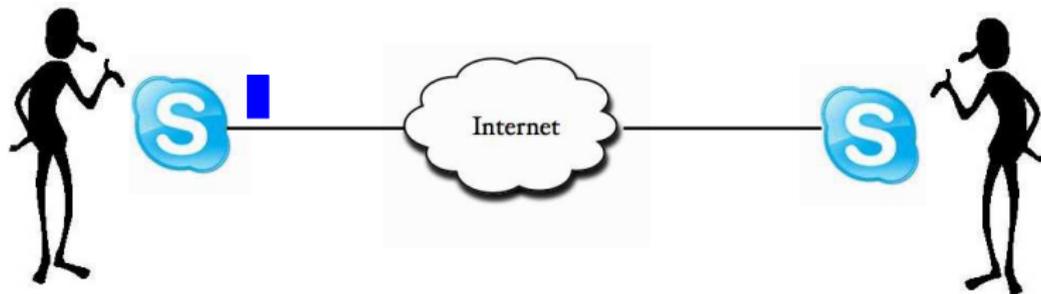
## Perda de pacotes

E se houver perda de pacotes?

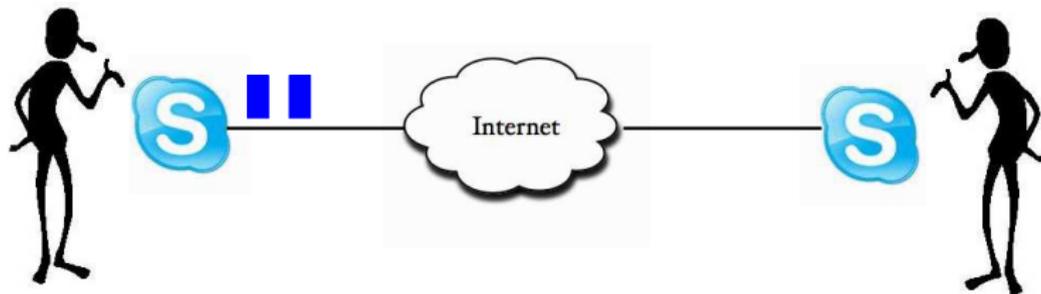
## Perda de pacotes



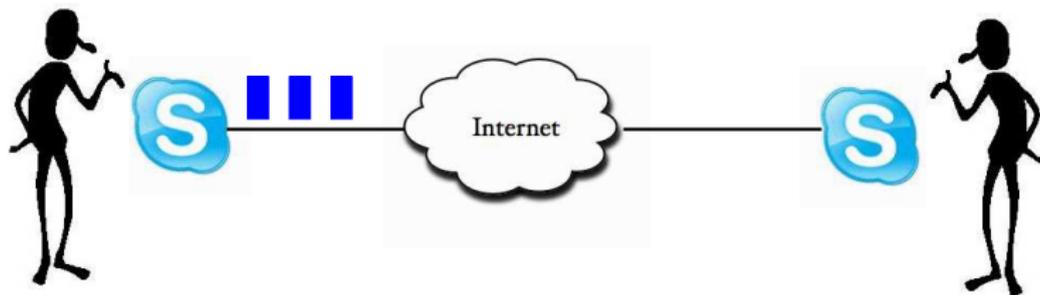
## Perda de pacotes



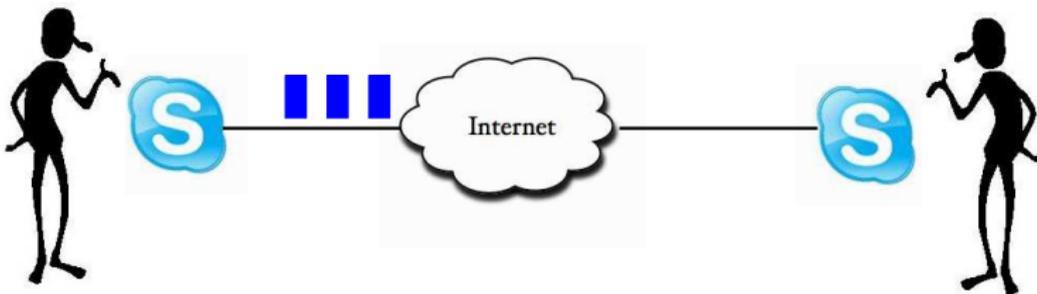
## Perda de pacotes



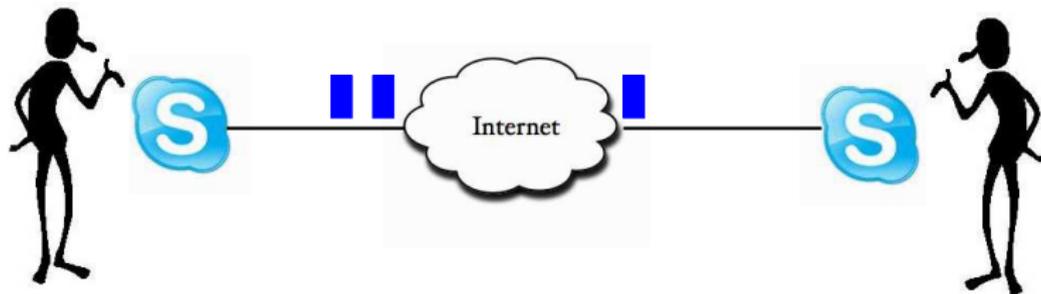
## Perda de pacotes



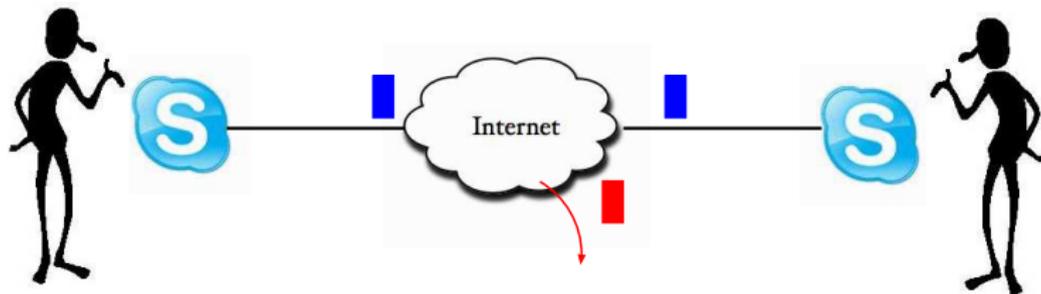
## Perda de pacotes



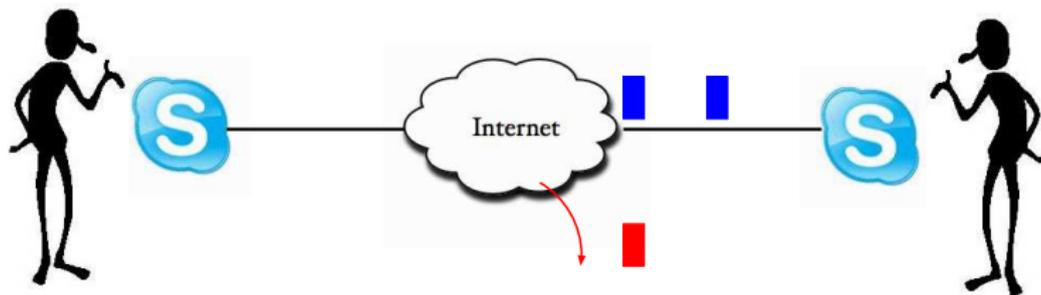
## Perda de pacotes



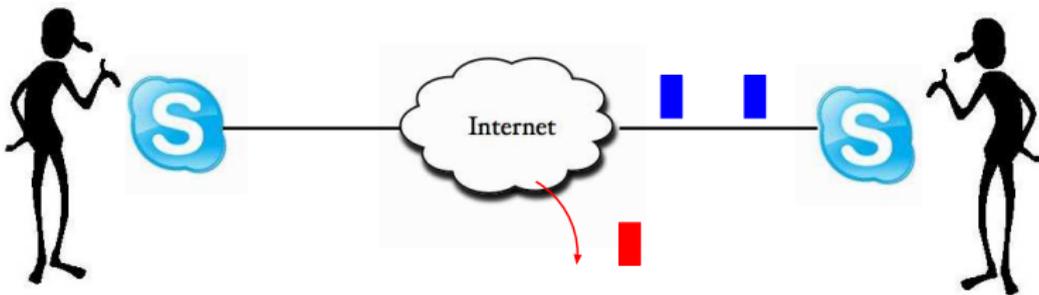
# Perda de pacotes



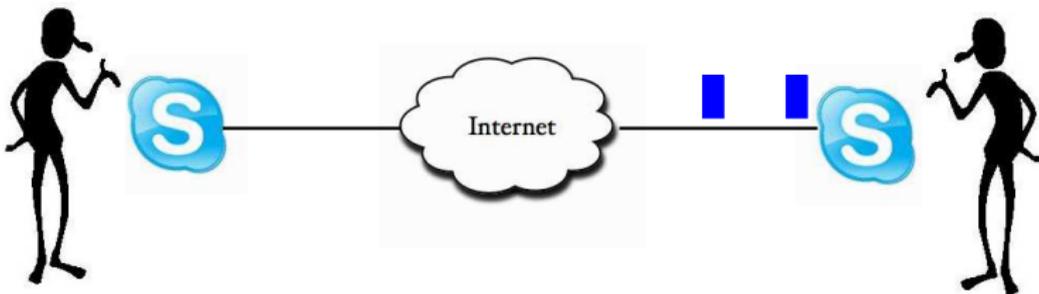
# Perda de pacotes



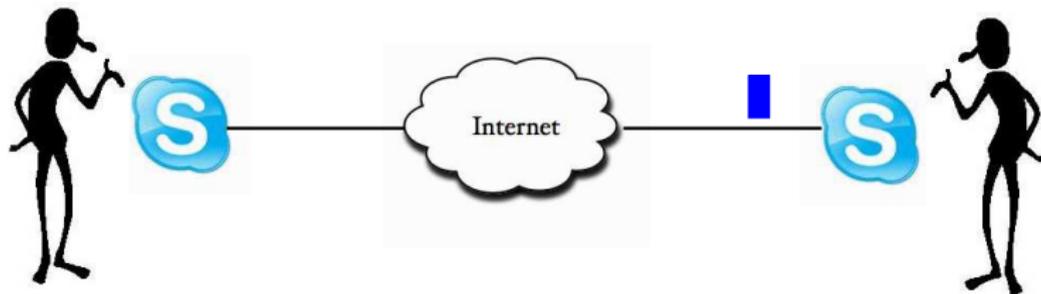
## Perda de pacotes



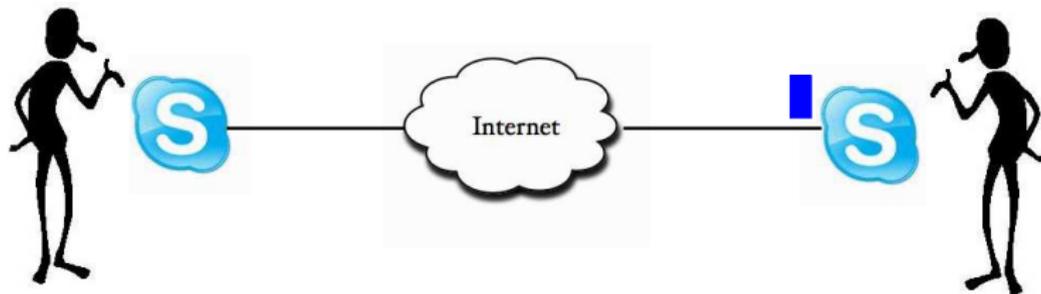
## Perda de pacotes



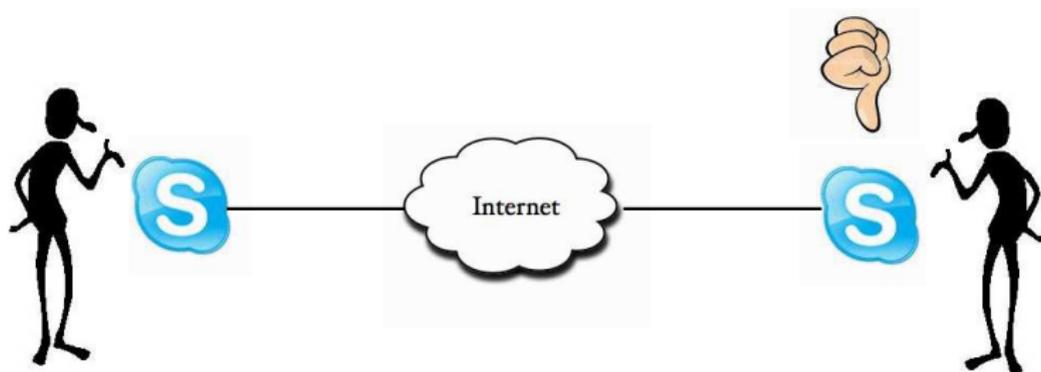
## Perda de pacotes



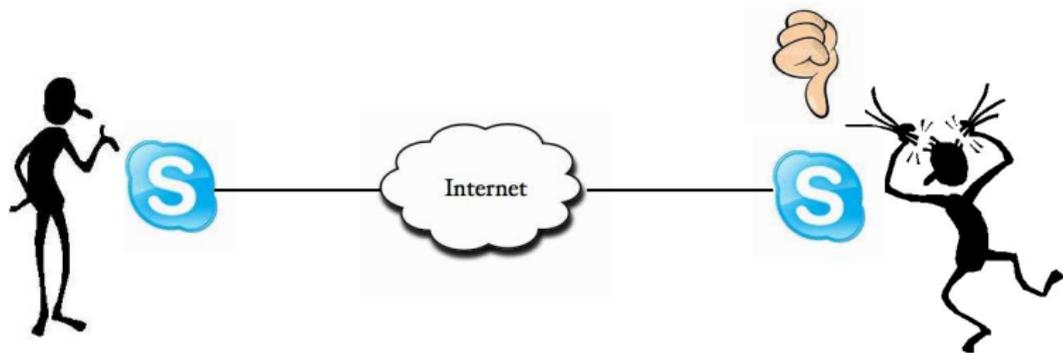
## Perda de pacotes



## Perda de pacotes



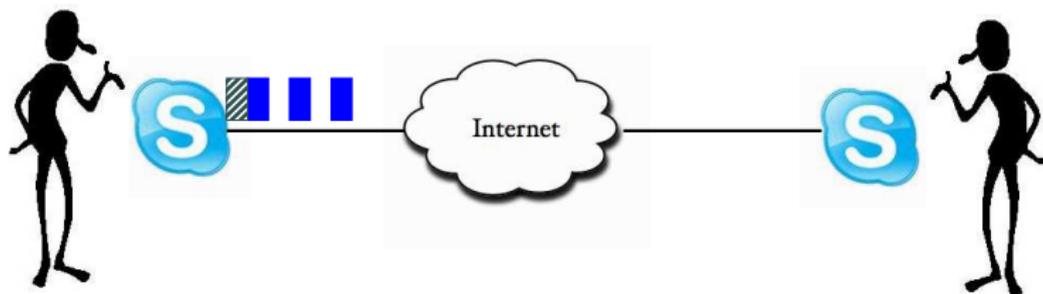
## Perda de pacotes



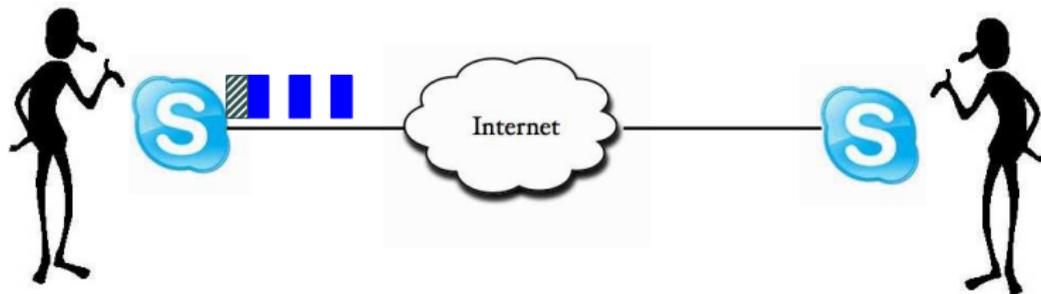
## Uso de redundância

Uso de redundância: atenuar os efeitos das perdas

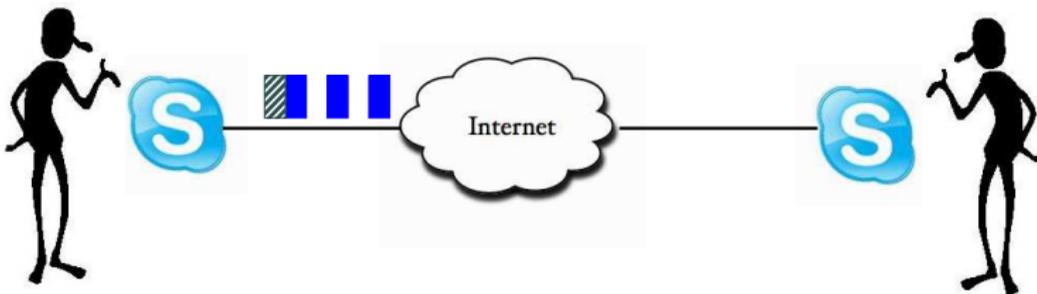
## Uso de redundância



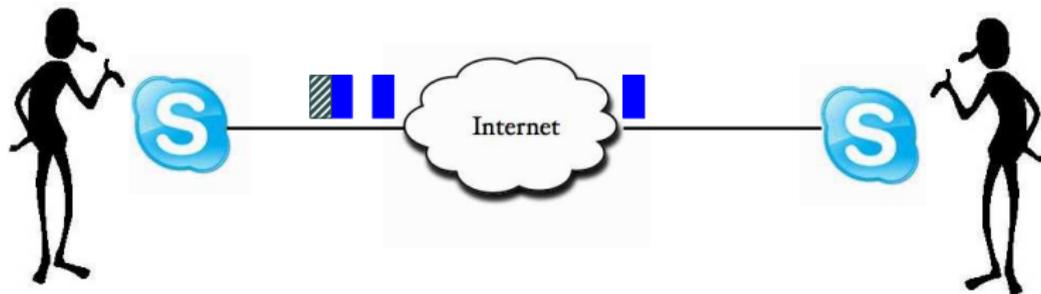
## Uso de redundância



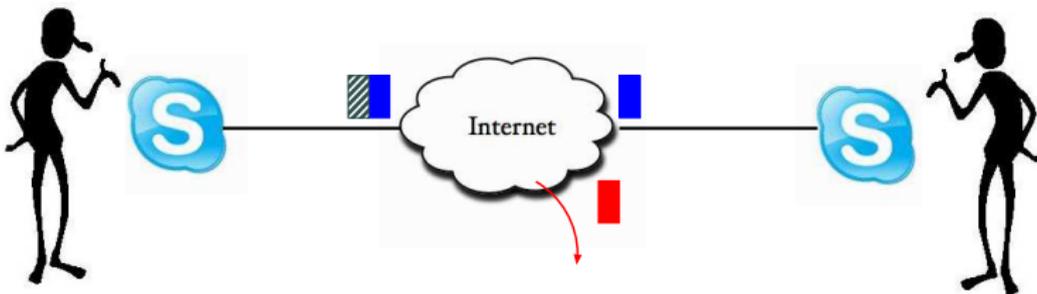
## Uso de redundância



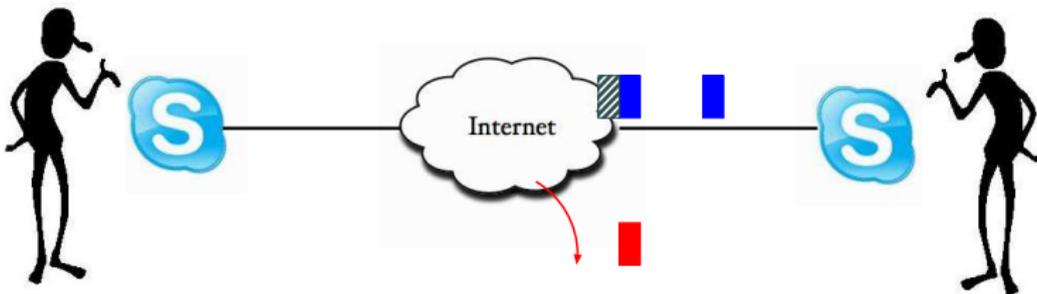
## Uso de redundância



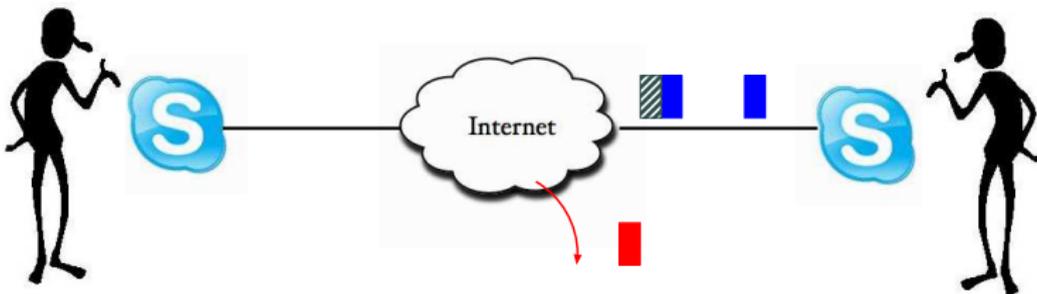
## Uso de redundância



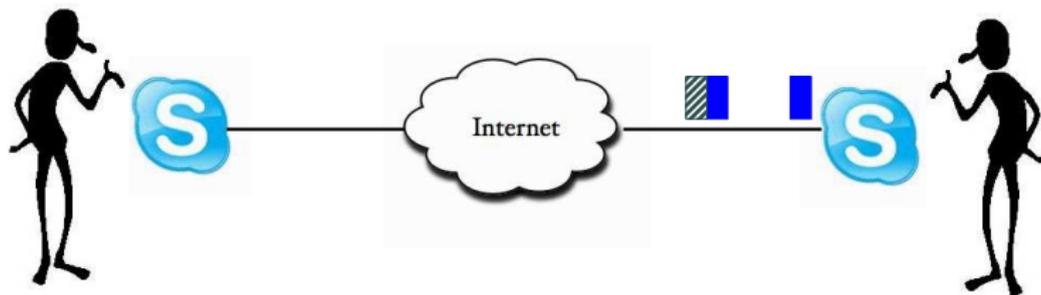
## Uso de redundância



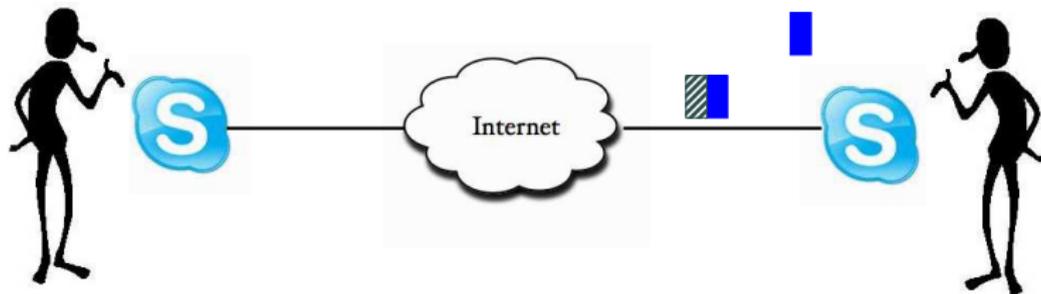
## Uso de redundância



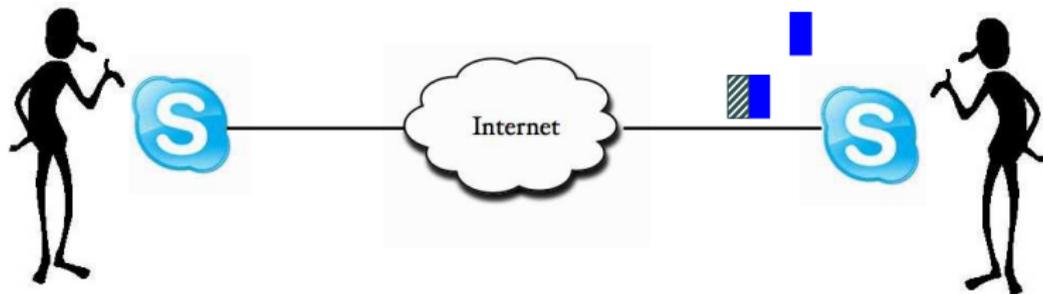
## Uso de redundância



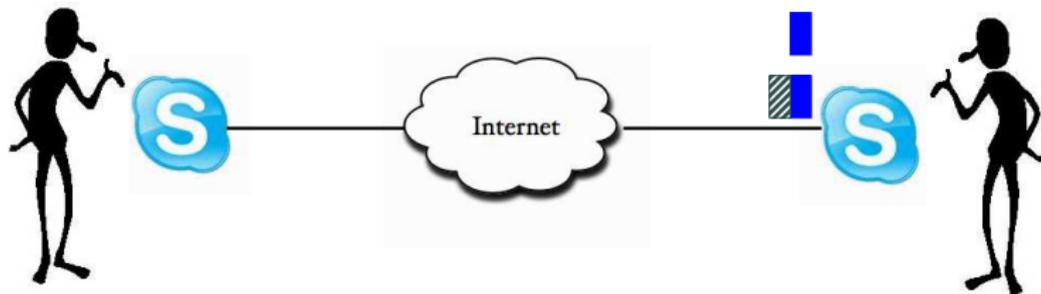
## Uso de redundância



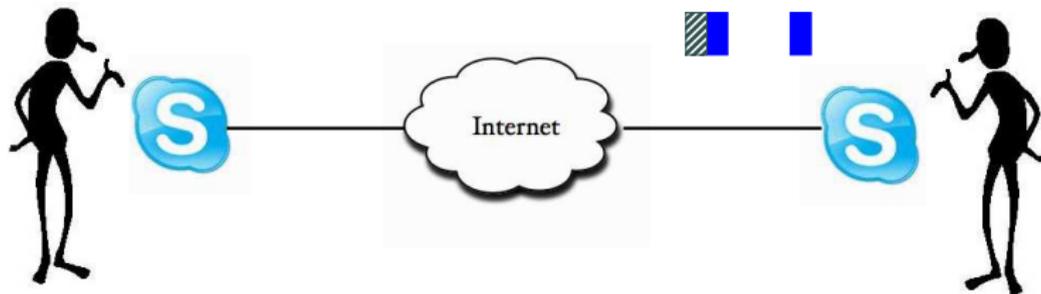
## Uso de redundância



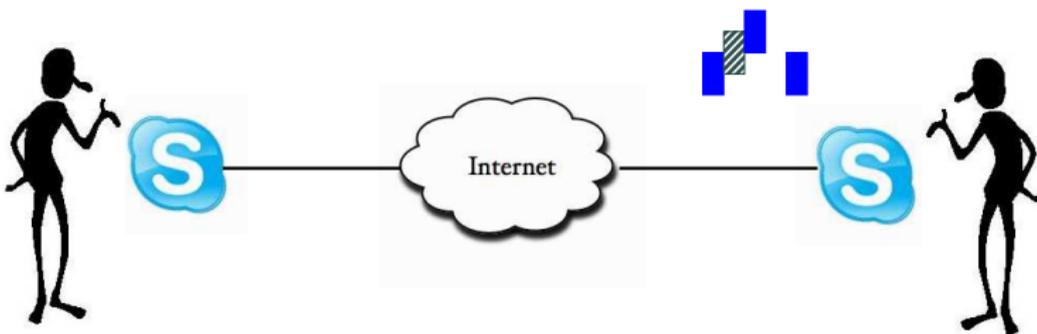
## Uso de redundância



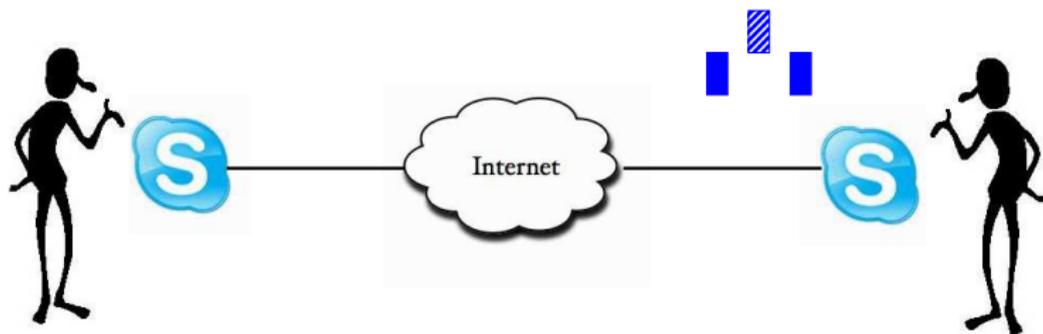
## Uso de redundância



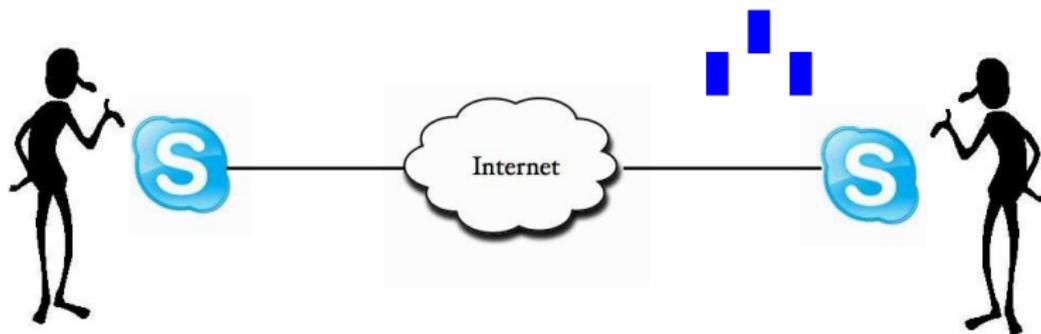
## Uso de redundância



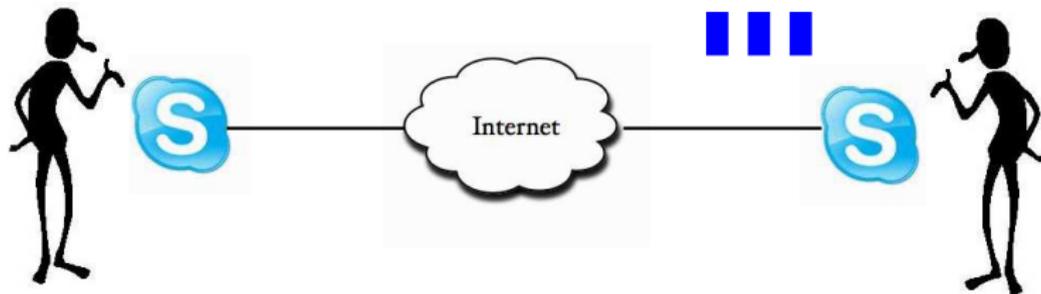
## Uso de redundância



## Uso de redundância



## Uso de redundância



## Quando utilizar redundância?

- Maior redundância → maior recuperação, consome mais recursos
- Redundância nem sempre é necessária

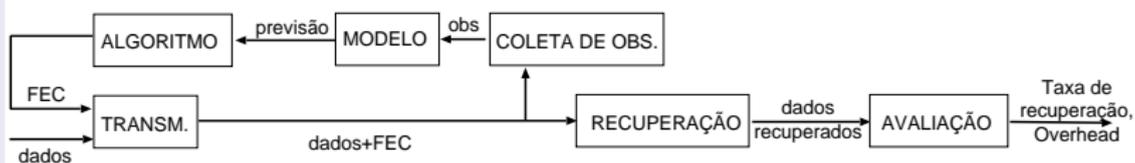
## Quando utilizar redundância?

- Maior redundância → maior recuperação, consome mais recursos
- Redundância nem sempre é necessária



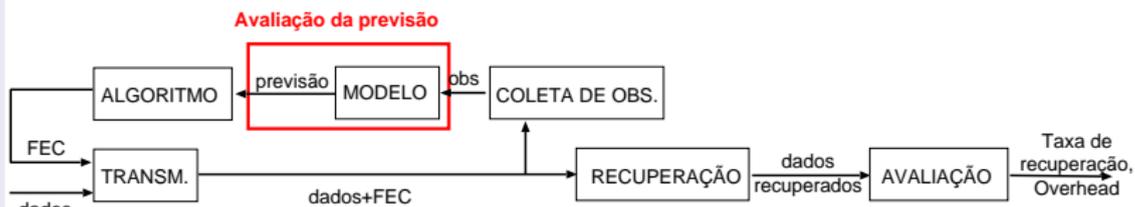
# Diagrama

## Recuperação



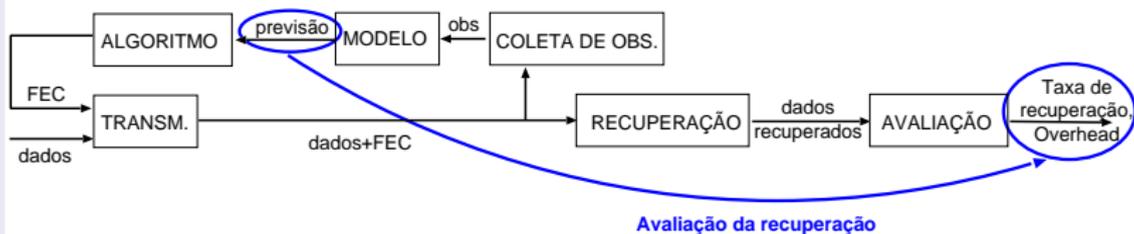
# Diagrama

## Problema 1



# Diagrama

## Problema 2



## Escopo deste trabalho

- 1 Uso de modelos para o processo de perdas:



Modelo de Markov Oculto Hierárquico (HMM)



Modelos Auto-regressivos (AR)

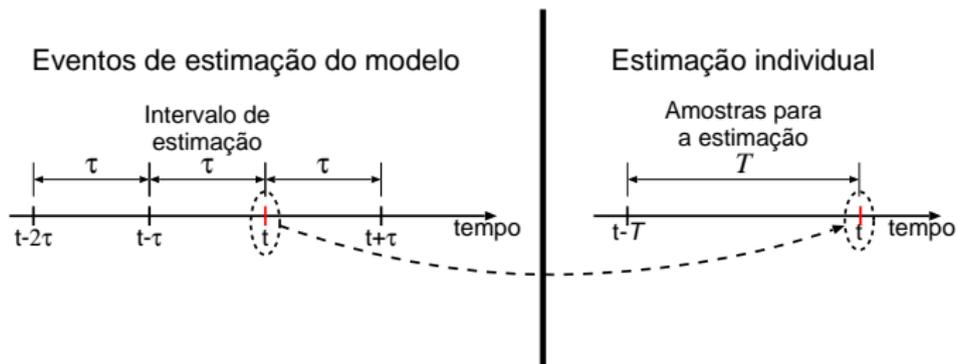
- 2 Avaliação quanto à:
  - Incerteza da previsão
  - Qualidade da recuperação
- 3 Estudo da relação previsão X recuperação

## O Mecanismo de previsão adaptativa



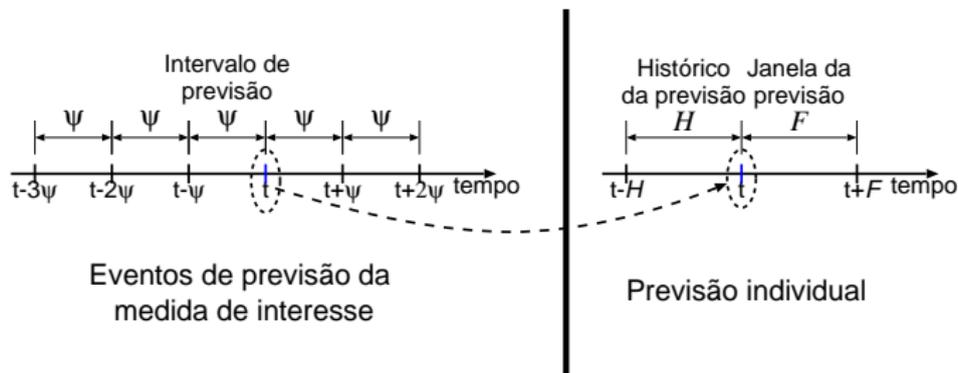
# O Mecanismo de previsão adaptativa

## Estimação dos parâmetros



# O Mecanismo de previsão adaptativa

## Previsão

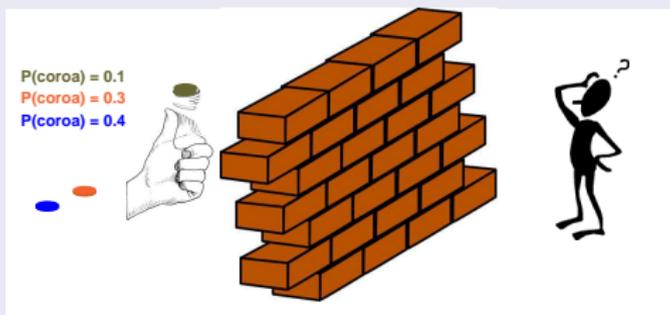


- Estatísticas:

- Taxa de perda média  $R_t^F$
- Tamanho médio da rajada de perda  $B_t^F$

## Modelos Markovianos Ocultos(HMM)

### Exemplo: Lançamento de moedas

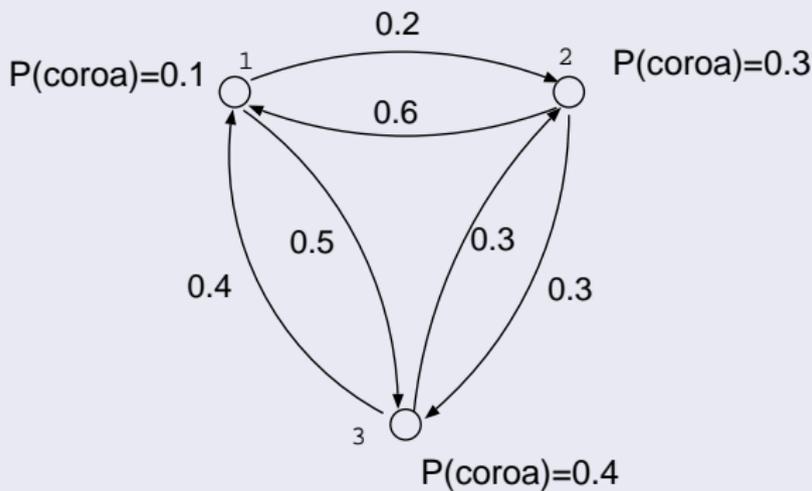


- Símbolos: cara, coroa
- Processo observável: resultados dos lançamentos
- Processo não-observável: troca de moedas

Motivação: como modelar esse processo?

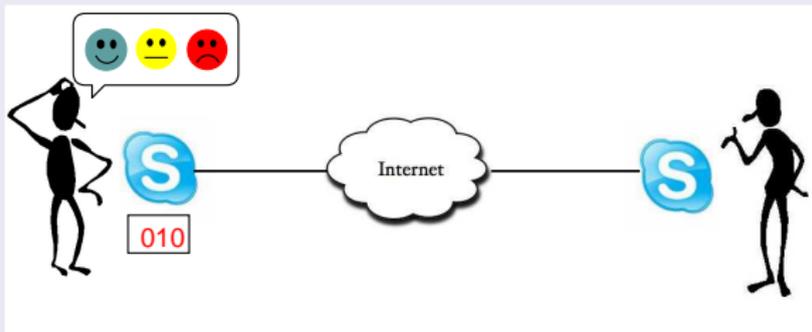
# Modelos Markovianos Ocultos(HMM)

## Modelo



## Modelos Markovianos Ocultos(HMM)

### Exemplo: Processo de perdas



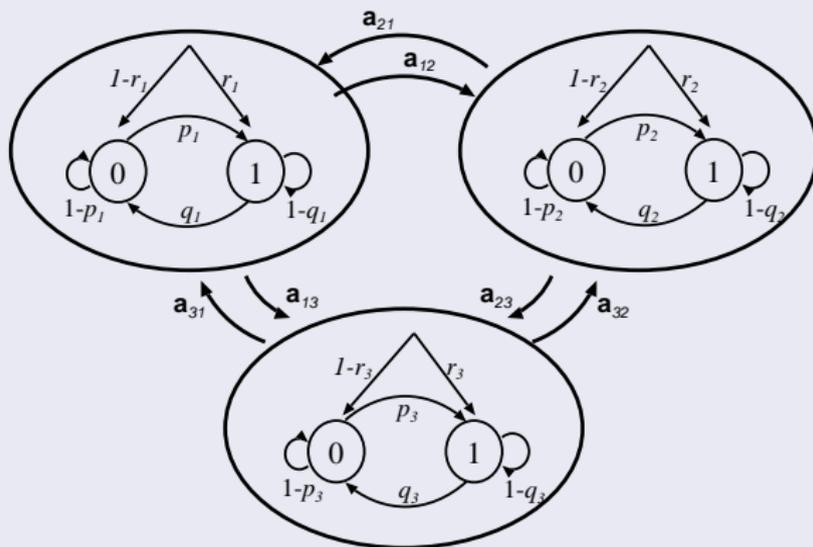
- Símbolos: sucessos(0) e perdas(1)
- Processo observável: resultados das transmissões
- Processo não-observável: estado da rede

Motivação: como modelar esse processo?



# HMM Hierárquico

## Modelo



- Representação do estado: modelo de Gilbert

## Outros preditores



### Modelo auto-regressivo (AR)

A previsão é uma comb. linear das obs. recentes



### Preditor Média

A cada  $\tau$  são calc. as estatísticas



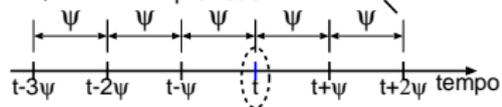
### Replicador

A cada  $\psi$  são calc. as estatísticas

Eventos de estimação do modelo

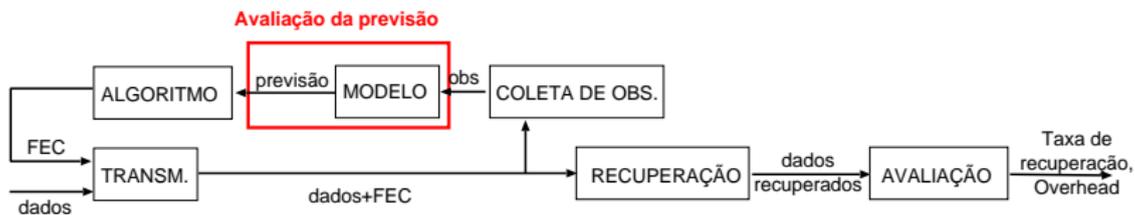


Intervalo de  
previsão



Eventos de previsão da  
medida de interesse

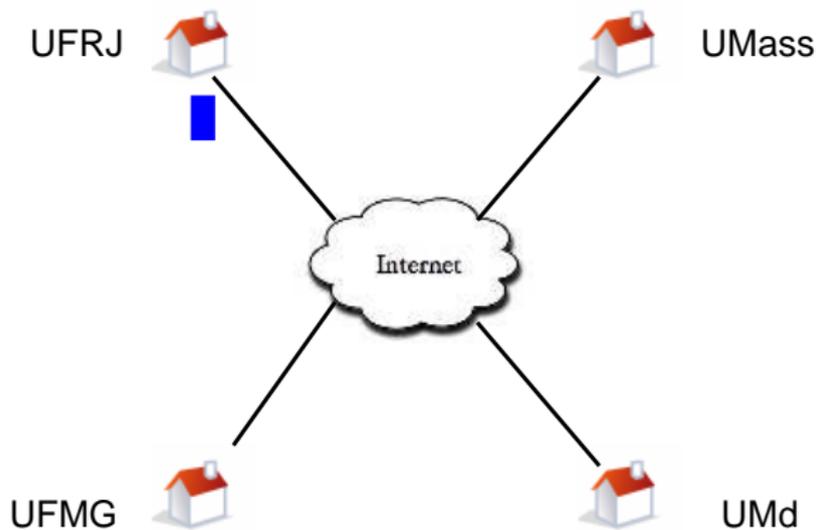
## Problema 1



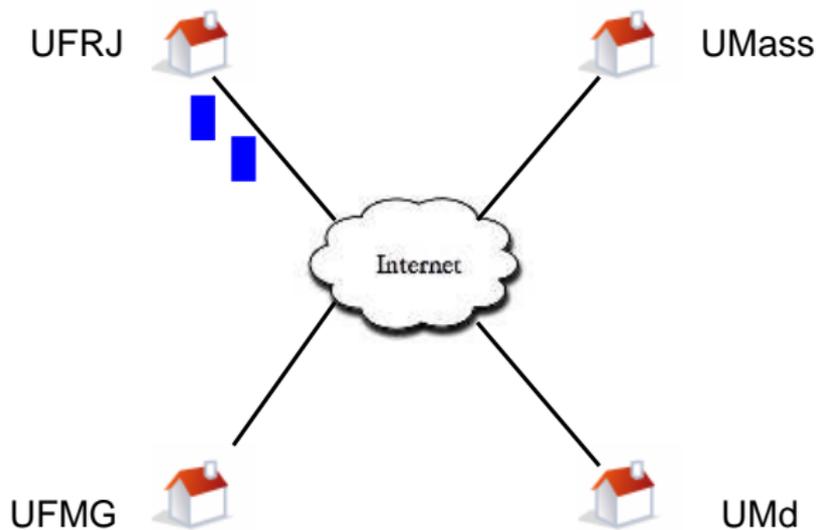
## Uso de traces

Como comparar a previsão se as perdas mudam a cada transmissão?

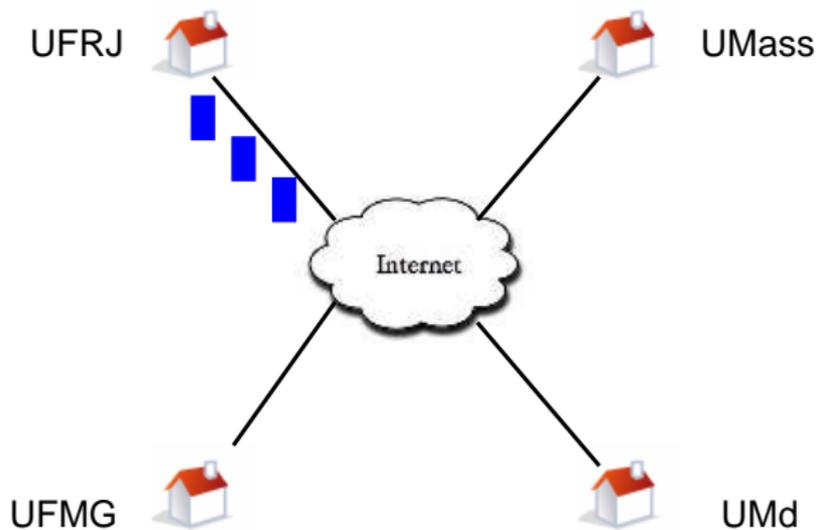
## Uso de traces



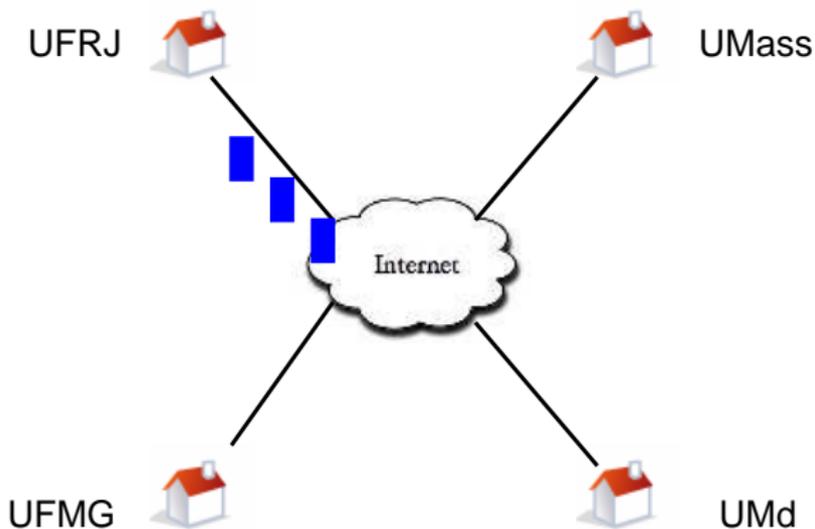
## Uso de traces



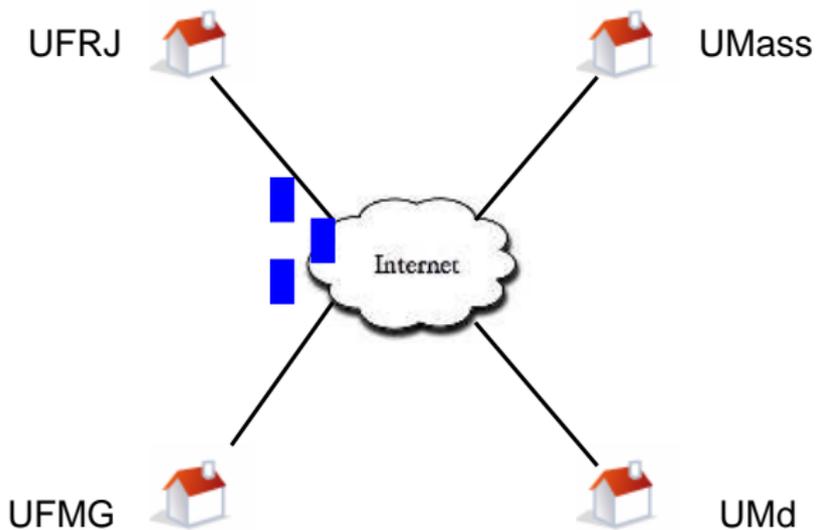
## Uso de traces



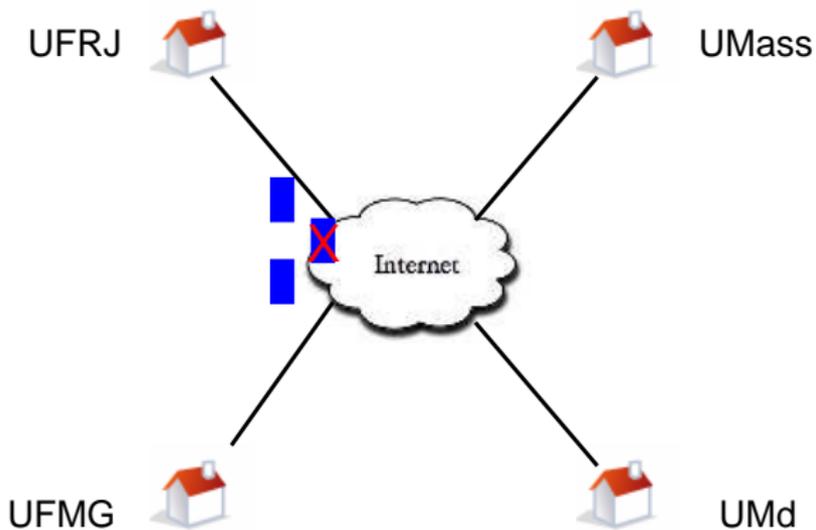
## Uso de traces



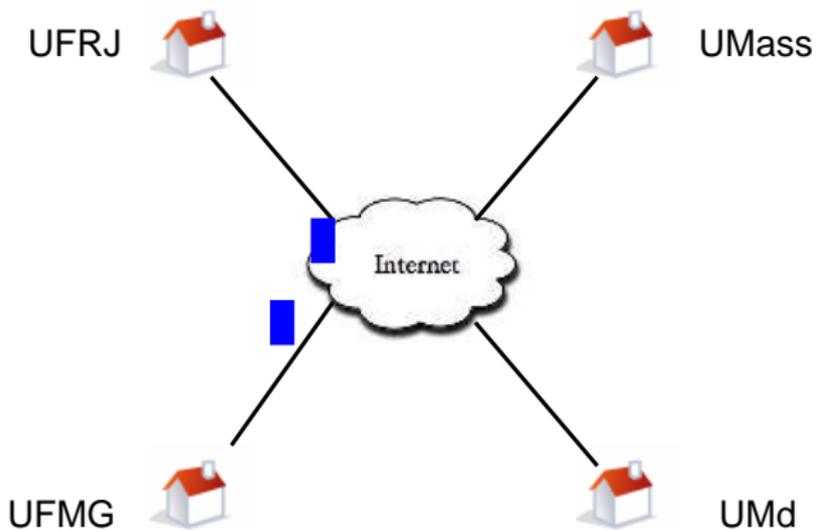
## Uso de traces



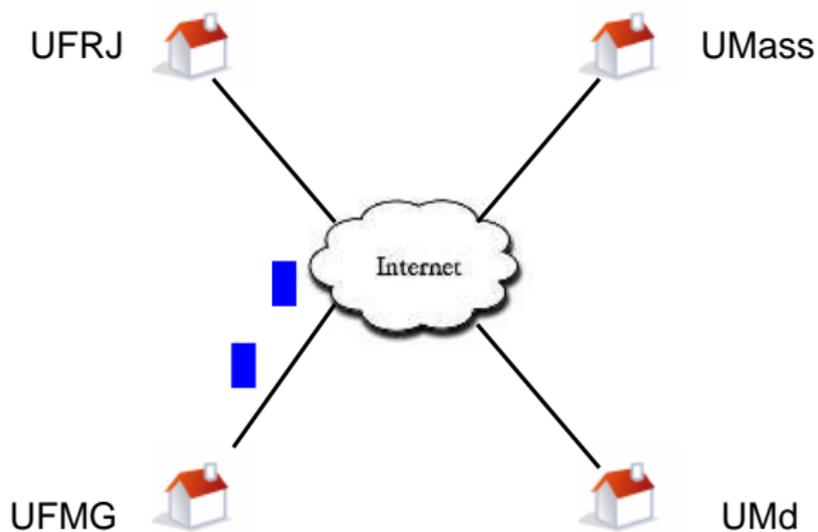
## Uso de traces



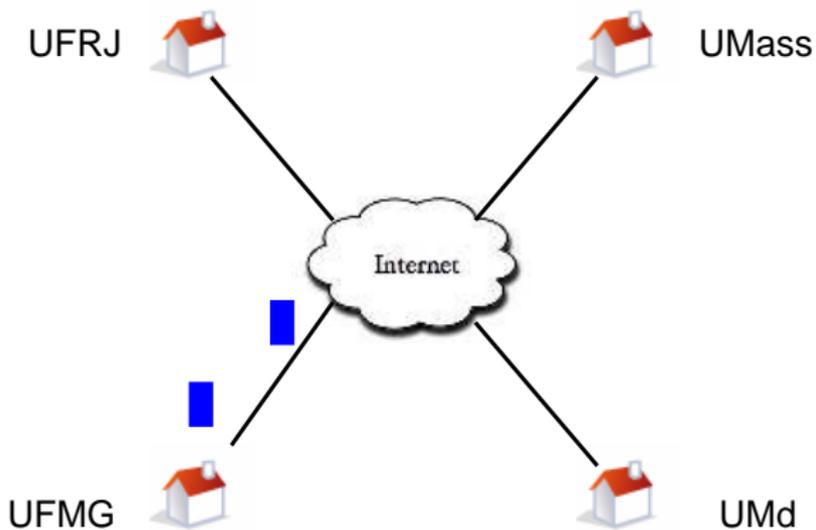
## Uso de traces



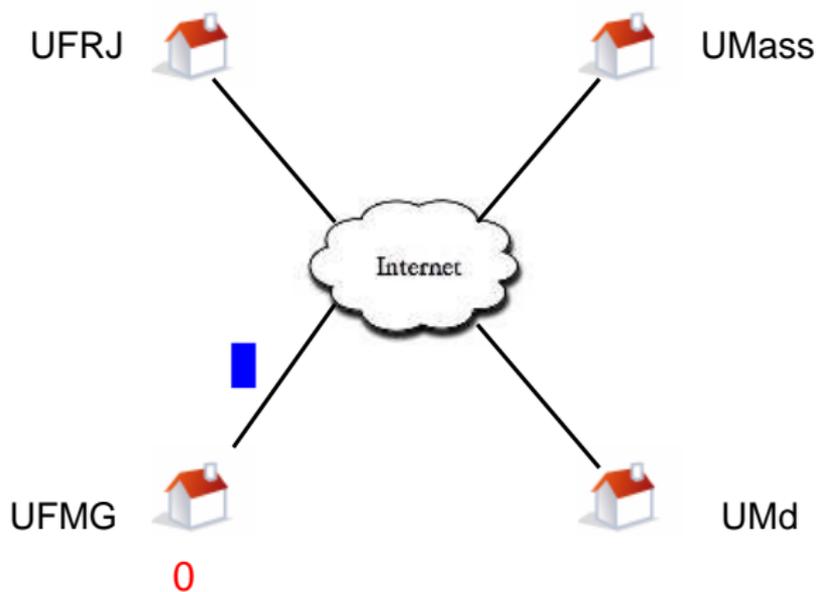
## Uso de traces



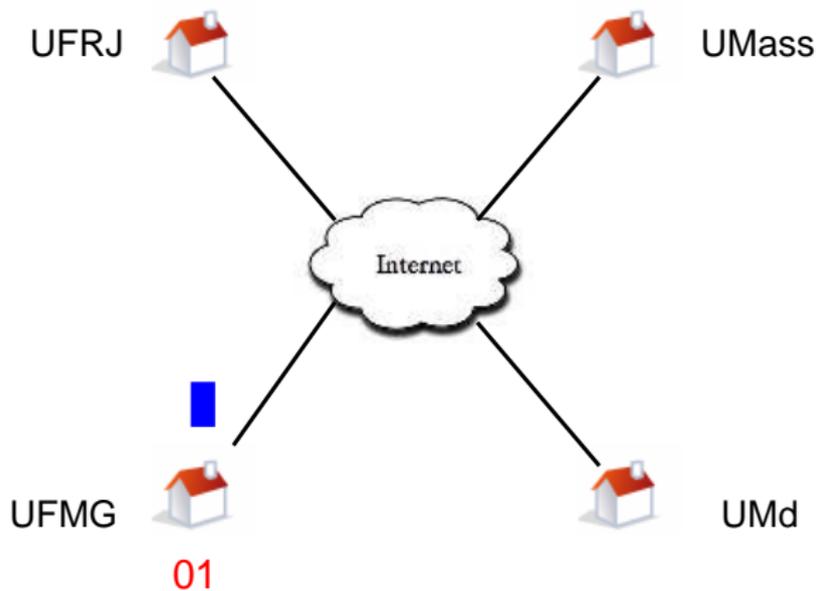
## Uso de traces



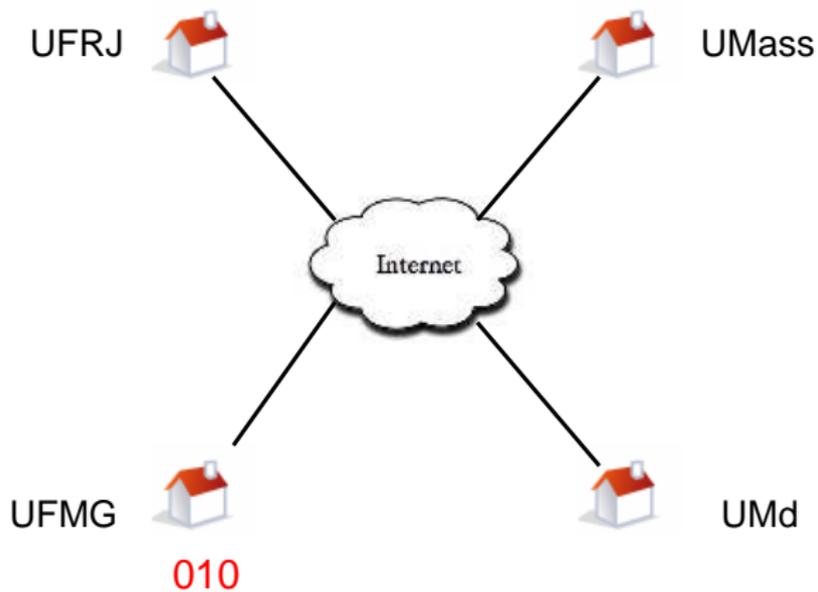
## Uso de traces



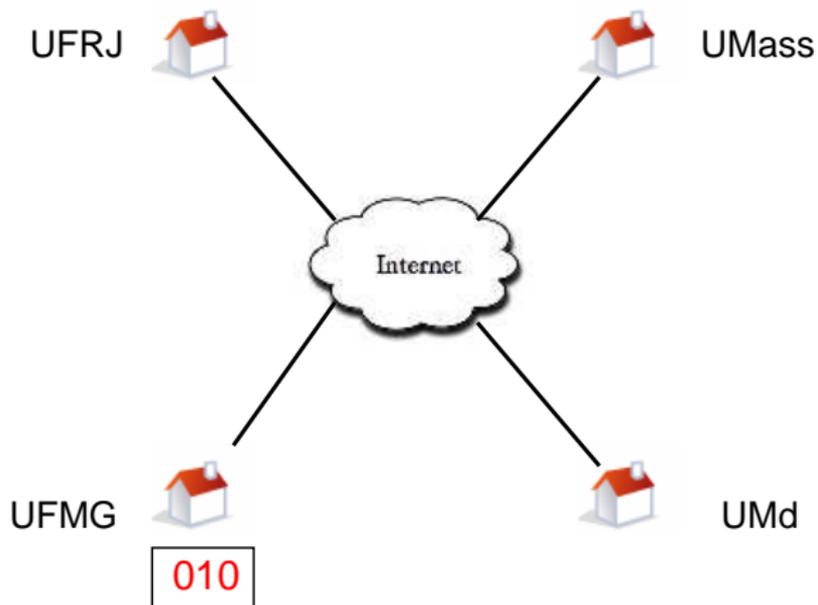
## Uso de traces



## Uso de traces



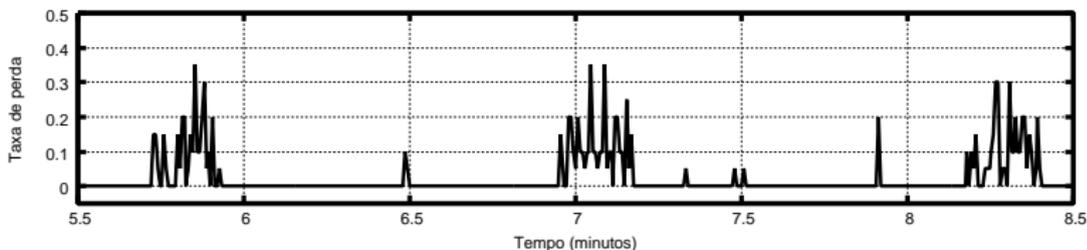
## Uso de traces



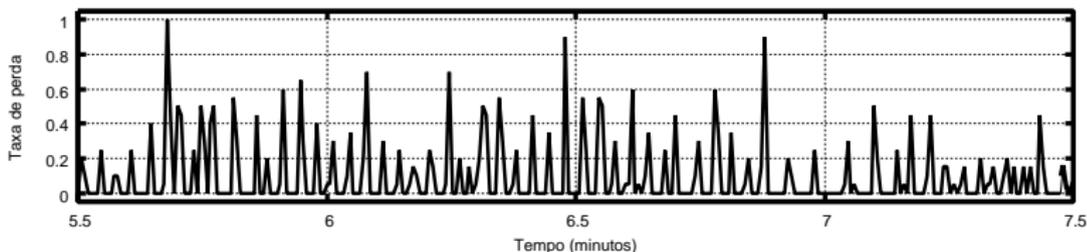
Obtidos através do *Traffic Generator* da ferramenta **Tangram II**

## Traces selecionados

- UMd - UFRJ (rajadas periódicas,  $\bar{R} = 2.2\%$ )

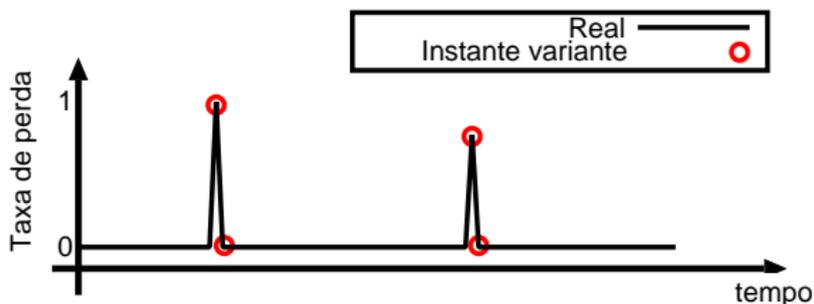


- UMASS - UFRJ (alta variabilidade,  $\bar{R} = 9.5\%$ )



## Avaliação da previsão

Consideramos apenas os instantes em que a taxa de perda é **variante**.



Métricas utilizadas:

- Erro médio quadrático **MSE** =  $E[(\hat{R}_t^F - R_t^F)^2]$
- Correlação cruzada **COR** ( real x previsto )
- Taxa de acerto relativa **I**( $\alpha$ )

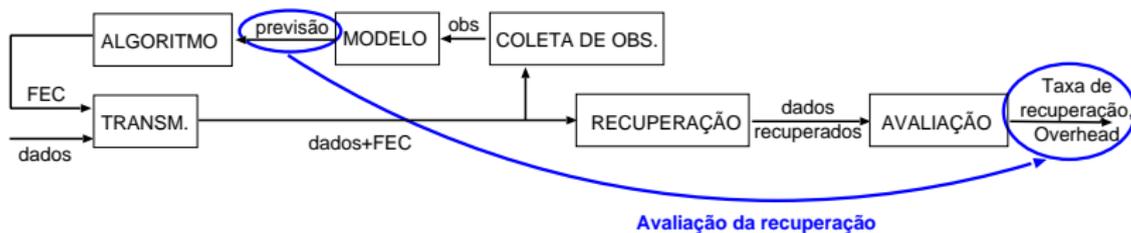
## Resultados Experimentais

### Comparação dos modelos de previsão

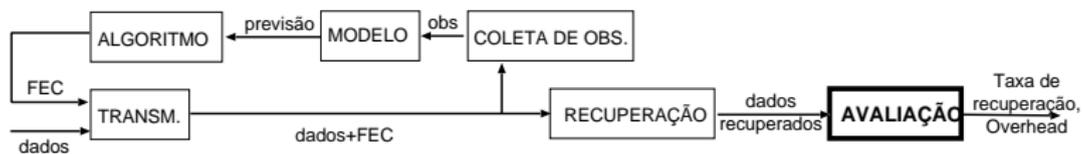
Modelo	UMd - UFRJ			UMass - UFRJ		
	↓ MSE	↑ COR	↑ I(0.4)	↓ MSE	↑ COR	↑ I(0.4)
 HMM	0.01244	0.23599	10%	0.04599	0.43518	<b>25%</b>
 AR	0.01330	0.22376	9%	0.05625	0.41024	<b>16%</b>
 Média	0.02189	0.10525	1%	0.08989	0.00520	0%
 Replicador	0.01823	0.16268	0%	0.11260	-0.16332	0%

- HMM mostrou melhor desempenho

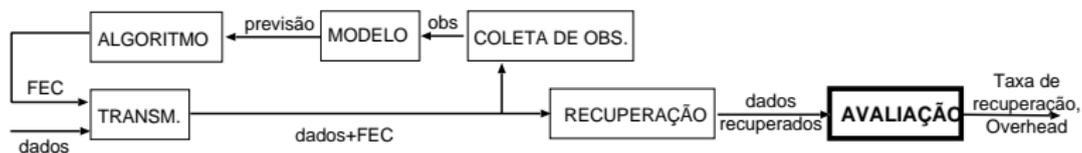
## Problema 2



# Métricas



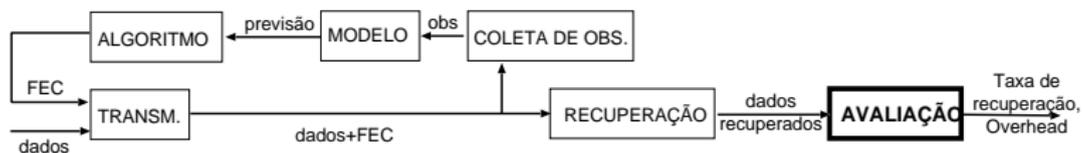
# Métricas



## Taxa de recuperação

$$r = \frac{\text{no. de pacotes recuperados}}{\text{no. de pacotes perdidos}}$$

# Métricas



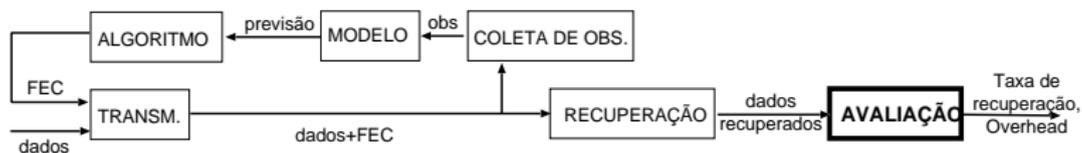
## Taxa de recuperação

$$r = \frac{\text{no. de pacotes recuperados}}{\text{no. de pacotes perdidos}}$$

## Overhead

$$O = \frac{\text{no. de pacotes adicionados ao fluxo}}{\text{no. de pacotes do fluxo original}}$$

## Métricas



### Taxa de recuperação

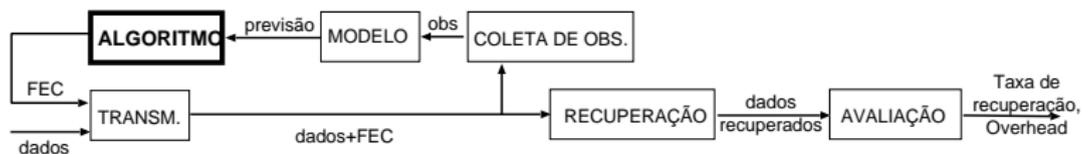
$$r = \frac{\text{no. de pacotes recuperados}}{\text{no. de pacotes perdidos}}$$

### Overhead

$$o = \frac{\text{no. de pacotes adicionados ao fluxo}}{\text{no. de pacotes do fluxo original}}$$

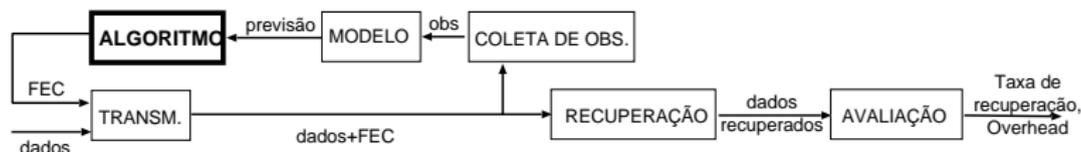
- Comparação de resultados

## Seleção de FEC



Dada a previsão como eu escolho a FEC?

## Seleção de FEC



Dada a previsão como eu escolho a FEC?

### Heurística C [Filho e de Souza e Silva, 2006]

- Objetivo: Taxa de perda após a recuperação abaixo de  $\theta$
- Entrada: modelo de Gilbert
- Calcula analiticamente  $E[\text{taxa de perda após recup.}]$

## Algoritmo de seleção de FEC

- Baseia-se na esperança da taxa de perda média e do tamanho médio da rajada
- Determina um modelo de Gilbert

**procedure selectFEC( $R_{t+1}^*$ ,  $B_{t+1}^*$ )**

**início**

$$q := \frac{1}{B_{t+1}^*};$$

$$p := \frac{q \times R_{t+1}^*}{1 - R_{t+1}^*};$$

Use o esquema de FEC dado pela heurística  $\mathbb{C}$  para o modelo de Gilbert( $p, q$ );

**fim**

## Mostrando a eficácia do algoritmo

Vamos supor a existência do seguinte preditor:

- **Preditor Ótimo:** conhece a taxa de perda e o tamanho médio da rajada (traces).

## Parametrização dos Modelos e do Algoritmo Adaptativo

### Parâmetros Fixos

S = 25 símbolos

Intervalo de treinamento: 4 minutos

Histórico de treinamento: 4 minutos

$\theta = 0.03$

### Parâmetros variáveis do HMM

Número de estados ocultos: 5, 10, 20

Intervalo de previsão: 50, 100 símbolos

Histórico de previsão: 50, 100, 1000 símbolos

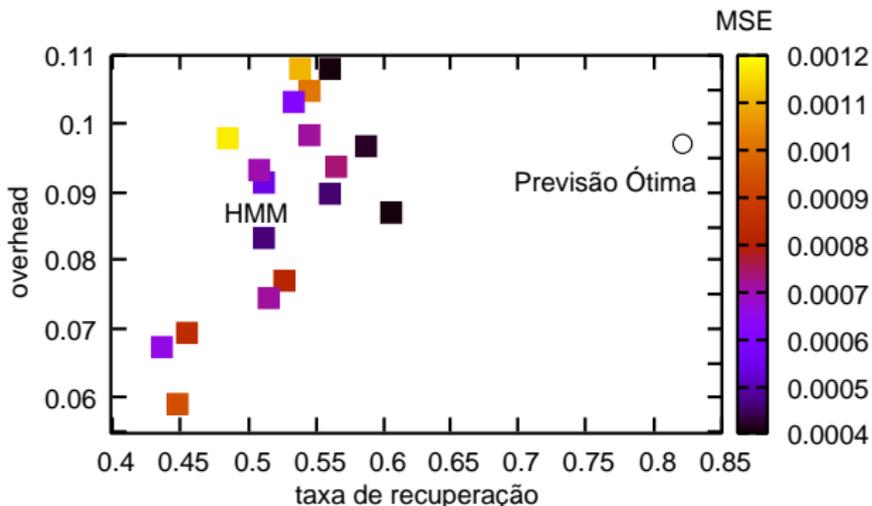
### Parâmetros variáveis do AR

Intervalo de previsão: 50, 100 símbolos

Grau de regressão: 2, 20, 40

## Resultados do HMM (UMd - UFRJ)

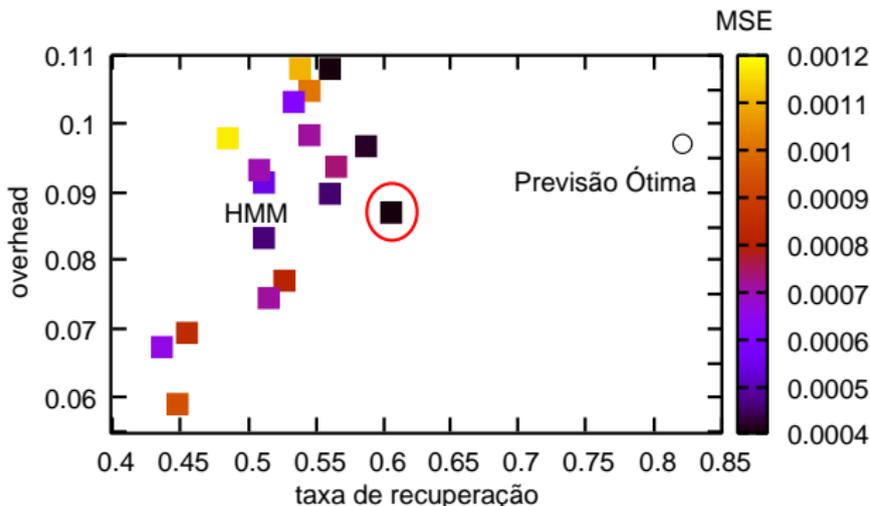
### Comparação para diferentes parametrizações



- Relação direta entre previsão e recuperação
- Robustez do HMM

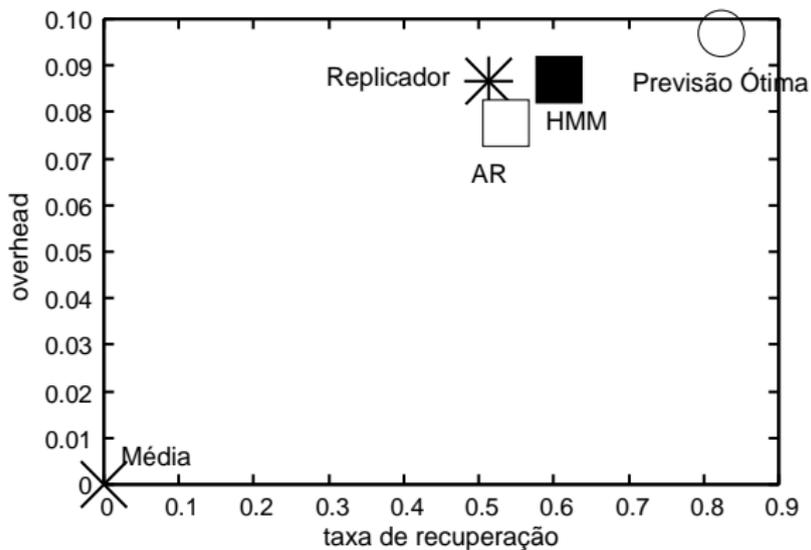
## Resultados do HMM (UMd - UFRJ)

### Comparação para diferentes parametrizações



- Relação direta entre previsão e recuperação
- Robustez do HMM

## Comparação dos modelos (UMd - UFRJ)



- Proximidade do HMM e da Previsão Ótima

## Contribuições

- 1 Definição de métricas para avaliação da previsão
- 2 Proposto Algoritmo de seleção de FEC
- 3 Avaliação dos modelos HMM e AR
- 4 Análise de sensibilidade do HMM
- 5 Previsão X Recuperação

# Conclusões

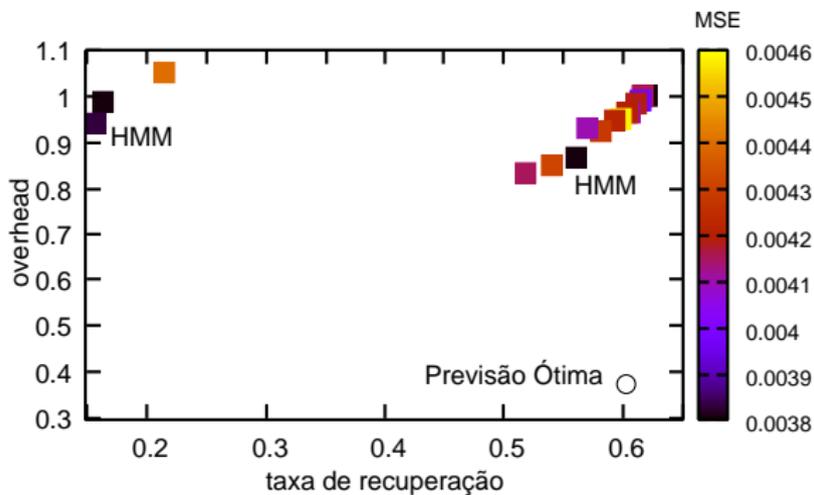
- 1 HMM mostrou melhor desempenho
- 2 Robustez do HMM com relação aos parâmetros
- 3 Em geral, boa previsão → boa recuperação
- 4 HMM + algoritmo proposto = bons resultados

# Obrigado!

## Fabício Murai

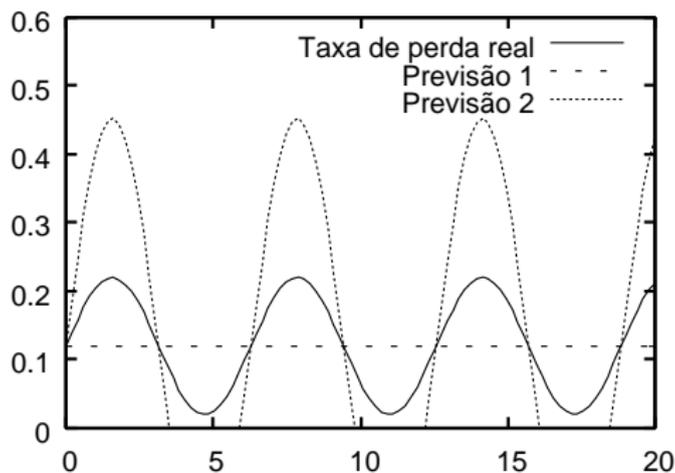
- Este Material: [www.land.ufrj.br/~fabricio](http://www.land.ufrj.br/~fabricio)
- Texto do artigo: [www.land.ufrj.br](http://www.land.ufrj.br)
- Email:  
[fabricio@land.ufrj.br](mailto:fabricio@land.ufrj.br)

## Previsão para parametrizações do HMM (UMass - UFRJ)



- 2 clusters
- HMM X Preditor Ótimo

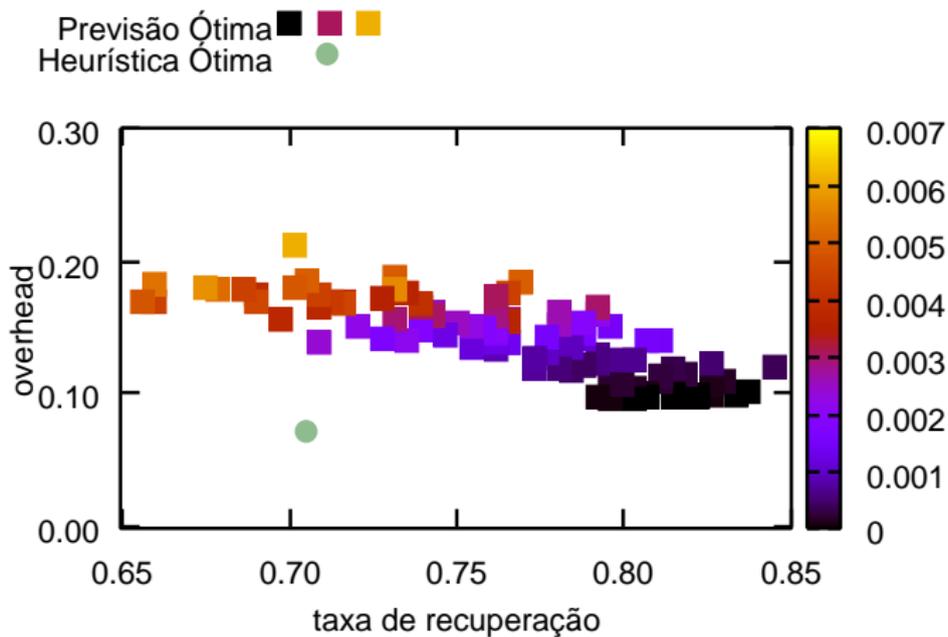
## Explicação dos resultados para o trace (UMass - UFRJ)



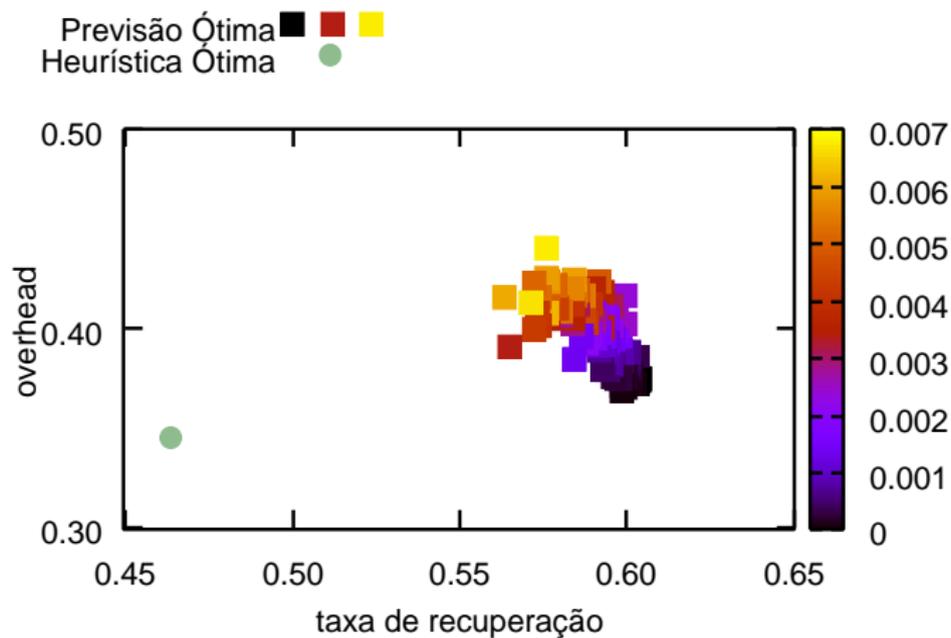
- Previsão 1: menor erro, sempre emprega redundância
- Previsão 2: maior erro, só emprega redundância quando necessário

A previsão do HMM para este trace se assemelha à previsão 1.

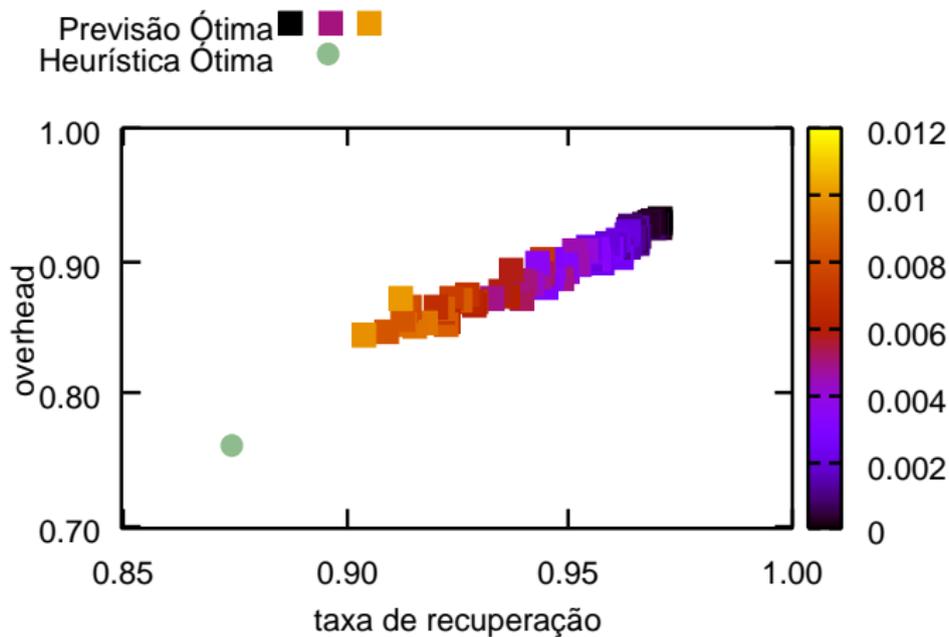
# Previsão X Recuperação (UMd - UFRJ)



# Previsão X Recuperação (UMass - UFRJ)



# Previsão X Recuperação (UFMG - UFRJ)



## Previsão X Recuperação (MMPP)

