



Generalização de Mineração de Sequências Restritas no Espaço e no Tempo

Antonio Castro¹, Heraldo Borges¹,
Ricardo Campisano¹, Esther Pacitti^{2,3}, Fabio Porto⁴,
Rafaelli Coutinho¹, Eduardo Ogasawara¹

Introdução

- **Evolução tecnológica**
 - Popularização dispositivos digitais com sensores e GPS
 - Viabiliza grandes conjuntos de dados espaço-temporais
- **Dados espaço-temporais → Importante para diferentes domínios**
 - Oportunidade de extrair padrões interessantes
- **Eventos com baixa frequência**
- **Buscar intervalo de tempo e posições onde os eventos são frequentes**



Introdução - Exemplo Motivacional

- Engarrafamentos no Rio de Janeiro
 - Padrão: Proximidade do início/fim do expediente gera engarrafamentos
 - Alto suporte



- Em dias de jogo no Maracanã
 - Engarrafamento ao fim do jogo
 - Baixo suporte



- **Objetivo:** sequências de eventos, o conjunto de posições e o intervalo de tempo
 - Importante para o planejamento e gestão da cidade



Trabalhos Relacionados

➤ Diferentes métodos:

- Mineração = apenas tempo
 - Ben Chaabene *et al.* (2021), Xue *et al.* (2016).
- Mineração + agrupamento = tempo + espaço
 - Koseoglu *et al.* (2020), Sunitha and Rama Mohan Reddy (2016)

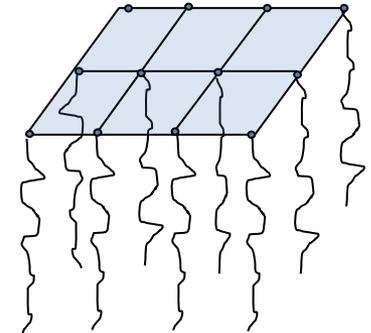
➤ Restrições para espaço e tempo:

- Suporte global = suporte válido para todo o conjunto de dados
 - Zhang *et al.* (2018), Batu *et al.* (2017)
- Suporte local = janelas pré-definidas de tempo, espaço ou ambos
 - Chen *et al.* (2020), Koseoglu *et al.* (2020)

Proposta

Objetivo: Buscar sequências frequentes no tempo que ocorrem em grupos espaciais

- Sem restrições prévias para espaço e tempo
- Limites de densidade estabelecidos pelo usuário:
 - Frequência mínima em um intervalo de tempo = γ
 - Distância máxima dos elementos de um grupo = σ
 - Mínimo de posições dentro de um grupo = β



- Capaz de encontrar diferentes tamanhos de sequências, intervalos de tempo e regiões do espaço

Contribuições

- Generalização de Campisano *et al.* (2018)
 - Campisano *et al.* (2018) considera o espaço de forma linear
- Frequentes no tempo → próximas no espaço (três dimensões)

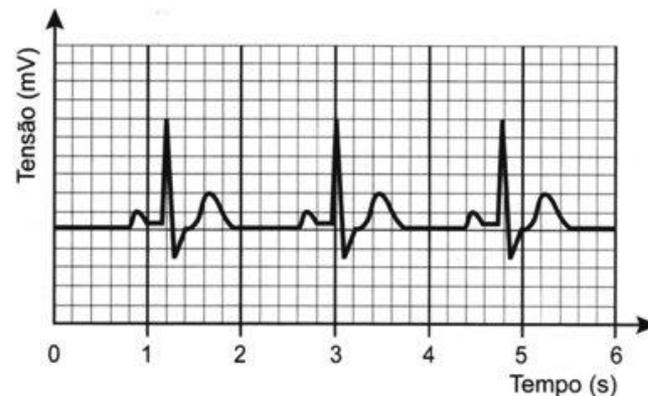
Conceitos Básicos

➤ Sequência com marcação de tempo (TS)

- Uma sequência ordenada de observações obtidas por meio de medições repetidas ao longo do tempo

$$t = \langle v_1, v_2, \dots, v_n \rangle$$

- Exemplo: eletrocardiograma



Conceitos Básicos

➤ Subsequência

- Uma amostra contínua de uma TS, com tamanho e início definidos

$$sub_{m,p}(t)$$

- Uma **sequência** faz parte de uma TS se existir uma posição a partir da qual seus itens sejam iguais, ou seja, se ela for subsequência da TS

$$s = \langle w_1, w_2, \dots, w_k \rangle, \exists q \mid s = sub_{k,q}(t),$$

onde $|s| = k$

- **Exemplo:** TS $t_1 = \langle B, A, B \rangle$; $sub_{2,1}(t_1) = \langle B, A \rangle$

	t_1
v_1	B
v_2	A
v_3	B

Conceitos Básicos

- **Posição:** Trio com as coordenadas de um ponto no sistema cartesiano

$$p = (x, y, z)$$

- **Sequência com marcação de tempo e espaço (STS)**

- Par com uma posição e uma TS associada a esta posição

$$st = (p, t)$$

- **Conjunto de dados D :** Conjunto de STS

- **Exemplo:** $st_1 = (p_1, t_1)$, $st_2 = (p_2, t_2)$, e $st_3 = (p_3, t_3)$



	t_1	t_2	t_3
v_1	B	A	C
v_2	A	C	A
v_3	B	C	C

Conceitos Básicos

- **Suporte:** número de marcações de tempo no conjunto de dados STS nas quais a sequência ocorre

$$sup(s, D) = |Q|, \forall q \in Q, \exists st_i \in D \mid s = sub_{|s|, q}(st_i.t),$$

onde Q = conjunto de marcações de tempo em que s ocorre em D

- **Frequência:** divisão do suporte de uma sequência em um conjunto de dados STS pelo tamanho da TS no conjunto de dados

$$freq(s, D) = \frac{sup(s, D)}{|st.t|}, st \in D$$

- Uma sequência é **frequente** se sua frequência no conjunto de dados STS for maior ou igual a frequência mínima definida pelo usuário

$$freq(s, D) \geq \gamma$$

- **Período de tempo (período):** definido por uma marcação de tempo inicial e uma final

$$r = (r_s, r_e)$$

Conceitos Básicos

Exemplo:

- $s = \langle A, C \rangle$
- $sup(s, D) = 2$ (ocorre em v_1 e v_2)
- $freq(s, D) = \frac{2}{3}$

	t_1	t_2	t_3
v_1	B	A	C
v_2	A	C	A
v_3	B	C	C

Conceitos Básicos e *Ranged Group* (RG)

- **Grupo de posições espaciais (grupo):** conjunto de posições onde seus elementos devem estar a uma distancia máxima definida pelo usuário (σ) de ao menos um outro elemento do mesmo grupo

$$g \mid \forall p \in g, \exists q \in g \mid dist(p, q) \leq \sigma$$

- ***Ranged Group* (RG):** trio (s, r, g)
 - s é uma sequência
 - r é um período de tempo
 - g é um grupo de posições espaciais

Ranged Group (RG)

- **Ocorrências** de uma sequência em um RG: número de vezes em que a sequência ocorre no intervalo de tempo, e conjunto de STS do grupo, referentes ao RG

$$occur(s, r, g)$$

- **Suporte** de uma sequência em um RG: número de marcações de tempo em que a sequência começa no intervalo de tempo, e no conjunto de STS do grupo, referentes ao RG

$$sup(s, r, g) = |Q|, \forall q \in Q, \exists st \in sts(g) \mid s = sub_{|s|,q}(st.t), \\ r_s \leq q \leq r_e, |s| \leq r_e$$

- **Frequência** de uma sequência em um RG: divisão do suporte do RG pelo tamanho de do intervalo de tempo do RG

$$freq(s, r, g) = \frac{sup(s, r, g)}{|r|}$$

Ranged Group (RG)

Exemplo:

- $\sigma = 1$
- $RG(s, r, g)$:
 - $s = \langle C \rangle$
 - $r = [1, 3]$,
 - $g = \langle p_2, p_3 \rangle$



$$occur(s, r, g) = 4$$

$$sup(s, r, g) = 3$$

$$freq(s, r, g) = \frac{3}{3}$$

	t_1	t_2	t_3
v_1	B	A	C
v_2	A	C	A
v_3	B	C	C

Kernel Ranged-Group (KRG)

Um **Kernel Ranged-Group (KRG)** é um RG com as seguintes restrições:

1. A frequência deve ser maior que a mínima definida pelo usuário

$$freq(s, r, g) \geq \gamma$$

2. O tamanho do grupo deve ser maior que o mínimo definido pelo usuário

$$|g| \geq \beta$$

3. Período de tempo mínimo: reduzir o período de tempo mantém a frequência maior ou igual a mínima, mas o suporte diminui

$\forall r' \in PR \mid r' \subset r \text{ e } r'_s = r_s$, ambas as condições se aplicam:

a) $freq(s, r', g) \geq \gamma$

b) $sup(s, r', g) < sup(s, r, g)$

4. Grupo máximo e mínimo: aumentar o grupo não aumenta o número de ocorrências e diminuir o grupo reduz o número de ocorrências

a) $\forall g' \in PG \mid g \subseteq g', occur(s, r, g') = occur(s, r, g)$

b) $\forall g' \in PG \mid g' \subset g, occur(s, r, g') < occur(s, r, g)$

Kernel Ranged-Group (KRG)

Exemplo:

➤ $\gamma = 60\%$, $\beta = 2$, $\sigma = 1$

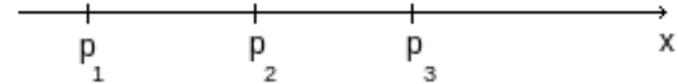
➤ $RG(s, r, g)$:

- $s = C$
- $r = [1, 3]$
- $g = \langle p_2, p_3 \rangle$

$$occur(s, r, g) = 4$$

$$sup(s, r, g) = 3$$

$$freq(s, r, g) = \frac{3}{3} = 1$$



	t_1	t_2	t_3
v_1		C	C
v_2		C	
v_3		C	C
v_4			

Kernel Ranged-Group (KRG)

Exemplo:

➤ $\gamma = 60\%$, $\beta = 2$, $\sigma = 1$

➤ $RG(s, r, g)$:

- $s = C$
- $r = [1, 3]$
- $g = \langle p_2, p_3 \rangle$

$$occur(s, r, g) = 4$$

$$sup(s, r, g) = 3$$

$$freq(s, r, g) = \frac{3}{3} = 1$$



	t_1	t_2	t_3
v_1		C	C
v_2		C	
v_3		C	C
v_4			

Diminuir r para $[1, 2]$
faz $sup(s, r, g) = 2$



	t_1	t_2	t_3
v_1		C	C
v_2		C	
v_3		C	C
v_4			

Kernel Ranged-Group (KRG)

Exemplo:

➤ $\gamma = 60\%$, $\beta = 2$, $\sigma = 1$

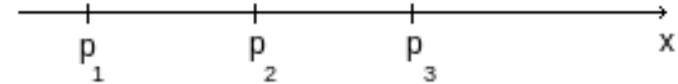
➤ $RG(s, r, g)$:

- $s = C$
- $r = [1, 3]$
- $g = \langle p_2, p_3 \rangle$

$$occur(s, r, g) = 4$$

$$sup(s, r, g) = 3$$

$$freq(s, r, g) = \frac{3}{3} = 1$$



	t_1	t_2	t_3
v_1		C	C
v_2		C	
v_3		C	C
v_4			

Incluir p_1 no grupo
mantém o mesmo
número de ocorrências



	t_1	t_2	t_3
v_1	C	C	C
v_2	C	C	
v_3	C	C	C
v_4			

Kernel Ranged-Group (KRG)

Exemplo:

➤ $\gamma = 60\%$, $\beta = 2$, $\sigma = 1$

➤ $RG(s, r, g)$:

- $s = C$
- $r = [1, 3]$
- $g = \langle p_2, p_3 \rangle$

$$occur(s, r, g) = 4$$

$$sup(s, r, g) = 3$$

$$freq(s, r, g) = \frac{3}{3} = 1$$



	t_1	t_2	t_3
v_1		C	C
v_2		C	
v_3		C	C
v_4			

Remover p_2 do grupo
faz $occur(s, r, g) = 2$



	t_1	t_2	t_3
v_1			C
v_2		C	
v_3		C	C
v_4			

Solid Ranged-Group (SRG)

Objetivo: Padrões restritos no espaço e no tempo, construídos a partir de KRG \Rightarrow Encontrar os Solid Ranged-Groups (SRG)

Um **SRG** é um RG com algumas restrições além das referentes aos KRG:

➤ O período de tempo é mínimo e máximo

Aumentar o período de tempo diminui a frequência para abaixo da mínima e/ou o suporte se mantém

Diminuir o período de tempo reduz o suporte

i. $\forall r' \in PR \mid r \subseteq r'$, temos a) ou b) ou ambos:

a) $freq(s, r', g) < \gamma$

b) $sup(s, r', g) = sup(s, r, g)$

ii. $\forall r' \in PR \mid r' \subset r$, $sup(s, r', g) < sup(s, r, g)$



Solid Ranged-Group (SRG)

Exemplo:

➤ $\gamma = 60\%$, $\beta = 2$, $\sigma = 1$

	t_1	t_2	t_3	t_4	t_5	t_6	t_7
v_1		C	C			B	B
v_2		C	C			B	B
v_3						B	B
v_4						B	B
v_5			C	C		B	B

Solid Ranged-Group (SRG)

Exemplo:

➤ $\gamma = 60\%$, $\beta = 2$, $\sigma = 1$

	t_1	t_2	t_3	t_4	t_5	t_6	t_7
v_1		C	C			B	B
v_2		C	C			B	B
v_3			São mesclados			B	
v_4			São mesclados			B	
v_5			C	C		B	B

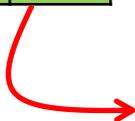

SRG

Solid Ranged-Group (SRG)

Exemplo:

➤ $\gamma = 60\%$, $\beta = 2$, $\sigma = 1$

	t_1	t_2	t_3	t_4	t_5	t_6	t_7
v_1		C	C			B	B
v_2		C				B	B
v_3						B	
v_4						B	
v_5		C	C			B	B


SRG

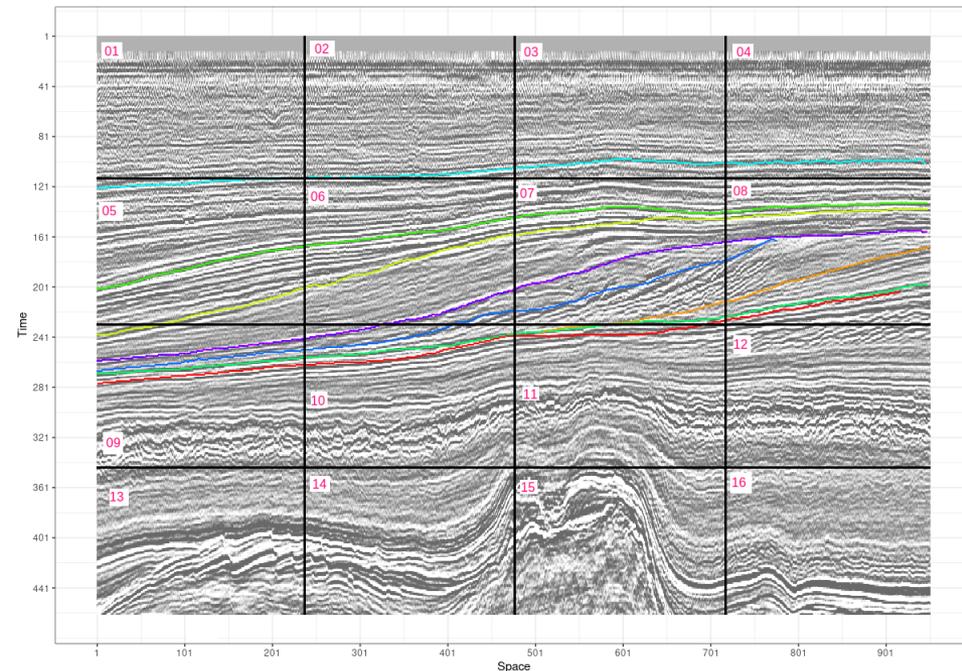
Avaliação Experimental

- Algoritmo capaz de produzir os SRGs
- Análise de sensibilidade do algoritmo

Os experimentos foram implementados em R e executados em um computador com processador com 16 núcleos, 128GB de RAM e Ubuntu 20.04 LTS

Conjunto de Dados

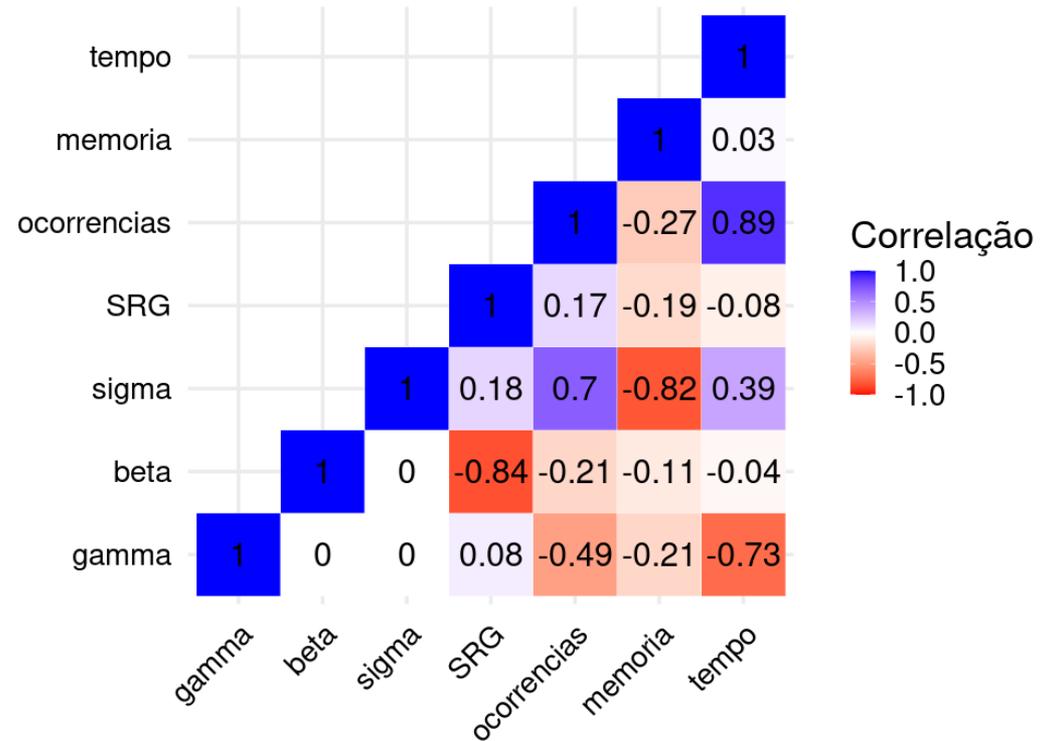
- Conjunto de Dados
 - $D \rightarrow$ inline T401 do F3 Block
- 951 sequências com marcação de tempo e espaço com 462 observações discretizado
- Alfabeto de tamanho 25
- Dividido em 16 quadrantes organizados de maneira retangular (4 x 4)



Análise de Sensibilidade

➤ Correlação entre os parâmetros de entrada (γ , β e σ) e as informações de saída:

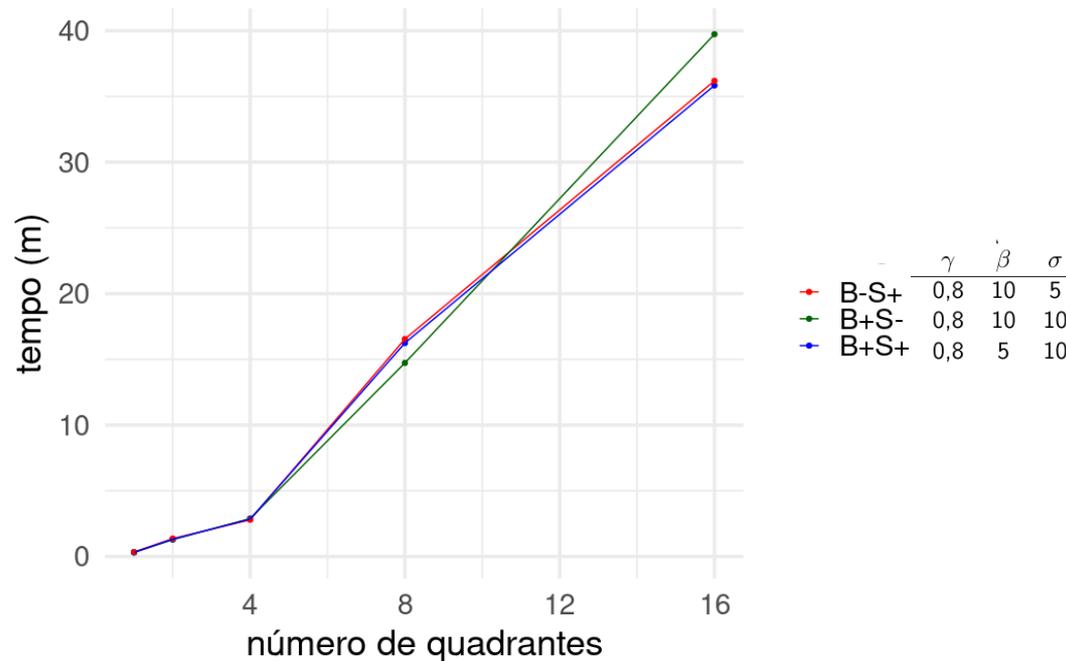
- número de SRG
- número de ocorrências
- uso de memória
- tempo de execução



$$\gamma = \{0,6; 0,8; 1,0\}, \beta = [5,10] \text{ e } \sigma = [5,10]$$

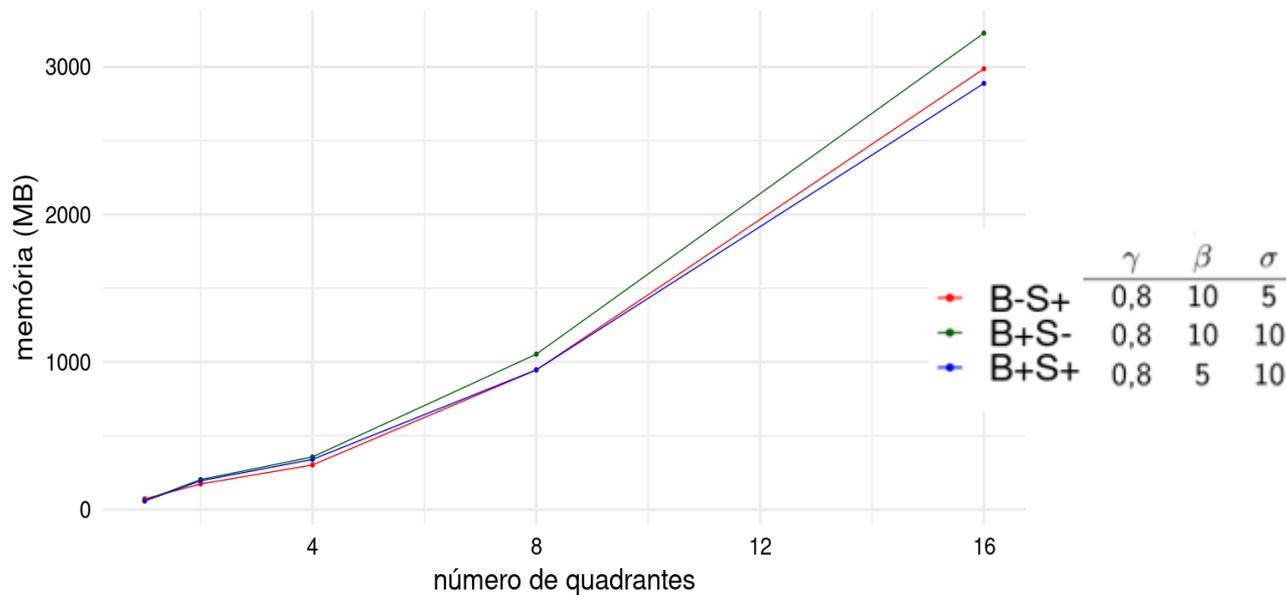
Análise de Sensibilidade

- Tempo de execução usando diferentes configurações e tamanhos de conjunto de dados



Análise de Sensibilidade

- Uso máximo de memória para diferentes configurações e tamanhos de conjunto de dados



Conclusões

- Fundamentos importantes e as noções de grupo, RG, KRG e SRG foram introduzidos
- Primeiro algoritmo capaz de encontrar sequências restritas no espaço e no tempo que funciona com uma dimensão de tempo e três dimensões de espaço
- Experimentos com conjunto de dados sísmicos do mundo real
- Análise de sensibilidade do algoritmo ⇒
 - o que mais afeta seu funcionamento é o tamanho do conjunto de dados de entrada
- Trabalhos em andamento:
 - Comparação com uma abordagem intuitiva
 - Avaliação do algoritmo com dados de outros domínios



Generalização de Mineração de Sequências Restritas no Espaço e no Tempo

Obrigado!

Eduardo Ogasawara
eogasawara@ieee.org

