

# Algoritmos Evolutivos aplicados ao Classificador Baseado em Segmentos de Retas

Defesa de Mestrado

Aluna: Rosario A. Medina Rodríguez  
Orientador: Ronaldo Fumio Hashimoto

Instituto de Matemática e Estatística  
IME - USP

3 de Julho do 2012



- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

- Nos últimos anos a classificação supervisionada tornou-se uma das tarefas mais importantes em diferentes aplicações (OCR, reconhecimento de voz, diagnóstico por imagens médicas, etc).

- Nos últimos anos a classificação supervisionada tornou se uma das tarefas mais importantes em diferentes aplicações (OCR, reconhecimento de voz, diagnóstico por imagens médicas, etc).
- Dessa forma um grande número de técnicas que lidam com este tipo de problemas têm sido desenvolvidas até o momento.

- Nos últimos anos a classificação supervisionada tornou-se uma das tarefas mais importantes em diferentes aplicações (OCR, reconhecimento de voz, diagnóstico por imagens médicas, etc).
- Dessa forma um grande número de técnicas que lidam com este tipo de problemas têm sido desenvolvidas até o momento.
- Foi introduzido um novo método baseado em segmentos de reta, chamado de método SLS <sup>1</sup> (*Straight Line Segments*).

---

<sup>1</sup> J.H.B. Ribeiro e R.F. Hashimoto. A new machine learning technique based on straight line segments. Em *ICMLA 2006: 5th International Conference on Machine Learning and Applications, Proceedings*

- Nos últimos anos a classificação supervisionada tornou-se uma das tarefas mais importantes em diferentes aplicações (OCR, reconhecimento de voz, diagnóstico por imagens médicas, etc).
- Dessa forma um grande número de técnicas que lidam com este tipo de problemas têm sido desenvolvidas até o momento.
- Foi introduzido um novo método baseado em segmentos de reta, chamado de método SLS <sup>1</sup> (*Straight Line Segments*).
- Um passo importante para obter bons resultados na classificação é encontrar as posições ótimas dos segmentos de reta.

---

<sup>1</sup> J.H.B. Ribeiro e R.F. Hashimoto. A new machine learning technique based on straight line segments. Em *ICMLA 2006: 5th International Conference on Machine Learning and Applications, Proceedings*

- 1 Melhorar a taxa acerto de classificação do método SLS utilizando um outro método de otimização na fase de treinamento.
- 2 Explorar o uso de diferente número de segmentos de reta para representar cada classe.
- 3 Estimar o melhor número de segmentos a serem usados para cada classe.
- 4 Analisar o desempenho de classificação através da aplicação do classificador SLS a problemas reais.

- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais




- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

# Fundamentos Teóricos

## Classificador Baseado em Segmentos de Reta

- Distância entre um conjunto de pontos e dois conjuntos de segmentos de reta. <sup>2</sup>



“AO CONTRÁRIO DE USAR DISTÂNCIAS A PONTOS, USA DISTÂNCIAS A SEGMENTOS DE RETA (INFINITOS PONTOS)”.


---

<sup>2</sup> J.H.B. Ribeiro e R.F. Hashimoto. A new training algorithm for pattern recognition technique based on straight line segments. Em *Proceedings of the 2008 XXI Brazilian Symposium on Computer Graphics and Image Processing*.

# Fundamentos Teóricos

## Classificador Baseado em Segmentos de Reta

- Distância entre um conjunto de pontos e dois conjuntos de segmentos de reta.<sup>2</sup>
- Encontrar duas coleções de segmentos de reta (SLSs) tal que a função de classificação minimize uma determinada função de risco.



“AO CONTRÁRIO DE USAR DISTÂNCIAS A PONTOS, USA DISTÂNCIAS A SEGMENTOS DE RETA (INFINITOS PONTOS)”.


---

<sup>2</sup> J.H.B. Ribeiro e R.F. Hashimoto. A new training algorithm for pattern recognition technique based on straight line segments. Em *Proceedings of the 2008 XXI Brazilian Symposium on Computer Graphics and Image Processing*.

# Classificador Baseado em Segmentos de Reta

## Definições Básicas

- Dado  $x \in \mathbb{R}^d$ ,  $x_e = (x, 0)$  é a extensão do ponto  $x$ , tal que  $x \in \mathbb{R}^{d+1}_{(*)}$




# Classificador Baseado em Segmentos de Reta

## Definições Básicas

- Dado  $x \in \mathbb{R}^d$ ,  $x_e = (x, 0)$  é a extensão do ponto  $x$ , tal que  $x \in \mathbb{R}^{d+1}_{(*)}$
- Sejam  $p, q \in \mathbb{R}^{d+1}$ , o segmento de reta  $L_{p,q}$  é definido como:

$$L_{p,q} = \{x \in \mathbb{R}^{d+1} : x = p + \lambda \cdot (q - p), 0 \leq \lambda \leq 1\}$$



# Classificador Baseado em Segmentos de Reta


## Definições Básicas

- Dado  $x \in \mathbb{R}^d$ ,  $x_e = (x, 0)$  é a extensão do ponto  $x$ , tal que  $x \in \mathbb{R}^{d+1}$  (\*)
- Sejam  $p, q \in \mathbb{R}^{d+1}$ , o segmento de reta  $L_{p,q}$  é definido como:

$$L_{p,q} = \{x \in \mathbb{R}^{d+1} : x = p + \lambda \cdot (q - p), 0 \leq \lambda \leq 1\}$$

- A pseudo-distância entre  $x$  e  $L_{p,q} \in \mathbb{R}^{d+1}$  é definida como:

$$\text{dist}P(x, L) = \frac{\text{dist}(x,p) + \text{dist}(x,q) - \text{dist}(p,q)}{2}$$



# Classificador Baseado em Segmentos de Reta


## Definições Básicas

- Dado  $x \in \mathbb{R}^d$ ,  $x_e = (x, 0)$  é a extensão do ponto  $x$ , tal que  $x \in \mathbb{R}^{d+1}_{(*)}$
- Sejam  $p, q \in \mathbb{R}^{d+1}$ , o segmento de reta  $L_{p,q}$  é definido como:

$$L_{p,q} = \{x \in \mathbb{R}^{d+1} : x = p + \lambda \cdot (q - p), 0 \leq \lambda \leq 1\}$$

- A pseudo-distância entre  $x$  e  $L_{p,q} \in \mathbb{R}^{d+1}$  é definida como:

$$\text{distP}(x, L) = \frac{\text{dist}(x,p) + \text{dist}(x,q) - \text{dist}(p,q)}{2}$$



# Classificador Baseado em Segmentos de Reta


## Definições Básicas

- Dado  $x \in \mathbb{R}^d$ ,  $x_e = (x, 0)$  é a extensão do ponto  $x$ , tal que  $x \in \mathbb{R}^{d+1}_{(*)}$
- Sejam  $p, q \in \mathbb{R}^{d+1}$ , o segmento de reta  $L_{p,q}$  é definido como:

$$L_{p,q} = \{x \in \mathbb{R}^{d+1} : x = p + \lambda \cdot (q - p), 0 \leq \lambda \leq 1\}$$

- A pseudo-distância entre  $x$  e  $L_{p,q} \in \mathbb{R}^{d+1}$  é definida como:

$$\text{dist}P(x, L) = \frac{\text{dist}(x,p) + \text{dist}(x,q) - \text{dist}(p,q)}{2}$$






# Classificador Baseado em Segmentos de Reta

## Definições Básicas

- Uma coleção de segmentos de reta ( $m$ :nSLS por classe)

$$\mathcal{L} = \{L_{p_i, q_i} : p_i, q_i \in \mathbb{R}^{d+1}, i = 1, \dots, m\}$$



# Classificador Baseado em Segmentos de Retas


## Definições Básicas

- Uma coleção de segmentos de reta ( $m$ :nSLS por classe)

$$\mathcal{L} = \{L_{p_i, q_i} : p_i, q_i \in \mathbb{R}^{d+1}, i = 1, \dots, m\}$$

- Dado  $x \in \mathbb{R}^d$ , a distância de  $x$  a  $\mathcal{L}$  é definida como:

$$\text{dist}L(x, \mathcal{L}) = \left( \lim_{\epsilon \rightarrow 0} \sum_{L \in \mathcal{L}} \frac{1}{\text{dist}P(x, L) + \epsilon} \right)^{-1},$$



# Classificador Baseado em Segmentos de Retas

## Definições Básicas

- Uma coleção de segmentos de reta ( $m$ :nSLS por classe)


$$\mathcal{L} = \{L_{p_i, q_i} : p_i, q_i \in \mathbb{R}^{d+1}, i = 1, \dots, m\}$$

- Dado  $x \in \mathbb{R}^d$ , a distância de  $x$  a  $\mathcal{L}$  é definida como:

$$\text{dist}L(x, \mathcal{L}) = \left( \lim_{\epsilon \rightarrow 0} \sum_{L \in \mathcal{L}} \frac{1}{\text{dist}P(x, L) + \epsilon} \right)^{-1},$$

- Dados  $\mathcal{L}_0$  e  $\mathcal{L}_1$ . Um classificador binário é definido pela função:

$$y_{\mathcal{L}_0, \mathcal{L}_1} : \mathbb{R}^d \rightarrow \{0, 1\}$$



$$y_{\mathcal{L}_0, \mathcal{L}_1}(x) = \arg_i \{ \min_{i \in \{0, 1\}} \text{dist}L(x, \mathcal{L}_i) \};$$

# Classificador Baseado em Segmentos de Reta

## Definições Básicas

- Uma coleção de segmentos de reta ( $m$ :nSLS por classe)


$$\mathcal{L} = \{L_{p_i, q_i} : p_i, q_i \in \mathbb{R}^{d+1}, i = 1, \dots, m\}$$

- Dado  $x \in \mathbb{R}^d$ , a distância de  $x$  a  $\mathcal{L}$  é definida como:

$$\text{dist}L(x, \mathcal{L}) = \left( \lim_{\epsilon \rightarrow 0} \sum_{L \in \mathcal{L}} \frac{1}{\text{dist}P(x, L) + \epsilon} \right)^{-1},$$

- Dados  $\mathcal{L}_0$  e  $\mathcal{L}_1$ . Um classificador binário é definido pela função:

$$y_{\mathcal{L}_0, \mathcal{L}_1} : \mathbb{R}^d \rightarrow \{0, 1\}$$



$$y_{\mathcal{L}_0, \mathcal{L}_1}(x) = \arg_i \{ \min_{i \in \{0, 1\}} \text{dist}L(x, \mathcal{L}_i) \};$$

### ■ Função Discriminante:

$$T_{\mathcal{L}_0, \mathcal{L}_1}(x) = \text{dist}L(x, \mathcal{L}_1)^{-1} - \text{dist}L(x, \mathcal{L}_0)^{-1},$$

Substituindo a Equação  $\text{dist}L(x, \mathcal{L})$  temos

$$T_{\mathcal{L}_0, \mathcal{L}_1}(x) = \left( \lim_{\varepsilon \rightarrow 0} \sum_{L \in \mathcal{L}_1} \frac{1}{\text{dist}P(x, L) + \varepsilon} \right)^{-1} - \left( \lim_{\varepsilon \rightarrow 0} \sum_{L \in \mathcal{L}_0} \frac{1}{\text{dist}P(x, L) + \varepsilon} \right)^{-1};$$

# Classificador Baseado em Segmentos de Reta

## Funções do Classificador SLS

### ■ Função Discriminante:

$$T_{\mathcal{L}_0, \mathcal{L}_1}(x) = \text{dist}L(x, \mathcal{L}_1)^{-1} - \text{dist}L(x, \mathcal{L}_0)^{-1},$$

Substituindo a Equação  $\text{dist}L(x, \mathcal{L})$  temos

$$T_{\mathcal{L}_0, \mathcal{L}_1}(x) = \left( \lim_{\varepsilon \rightarrow 0} \sum_{L \in \mathcal{L}_1} \frac{1}{\text{dist}P(x, L) + \varepsilon} \right)^{-1} - \left( \lim_{\varepsilon \rightarrow 0} \sum_{L \in \mathcal{L}_0} \frac{1}{\text{dist}P(x, L) + \varepsilon} \right)^{-1};$$

### ■ Função de Classificação Binária:

$$y_{\mathcal{L}_0, \mathcal{L}_1}(x) = \frac{1}{1 + e^{-g(T_{\mathcal{L}_0, \mathcal{L}_1}(x))}},$$

- Dado um conjunto de treinamento

$$S = \{(x_i, y_i) : i = 1, 2, \dots, n; x_i \in \mathbb{R}^d; y_i \in [0, 1]\} ,$$

onde  $n$  é o número de exemplos

- Dado um conjunto de treinamento

$$S = \{(x_i, y_i) : i = 1, 2, \dots, n; x_i \in \mathbb{R}^d; y_i \in [0, 1]\} ,$$

onde  $n$  é o número de exemplos

- **Placing:** Encontrar as posições iniciais dos segmentos de reta, aplicando K-means.



- Dado um conjunto de treinamento

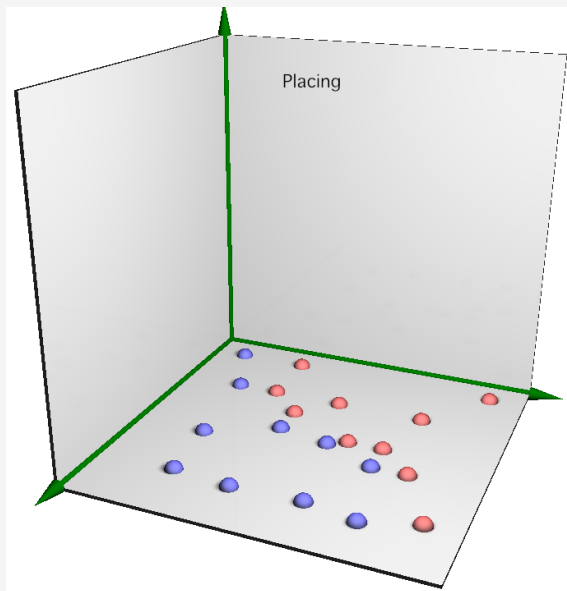
$$S = \{(x_i, y_i) : i = 1, 2, \dots, n; x_i \in \mathbb{R}^d; y_i \in [0, 1]\} ,$$

onde  $n$  é o número de exemplos

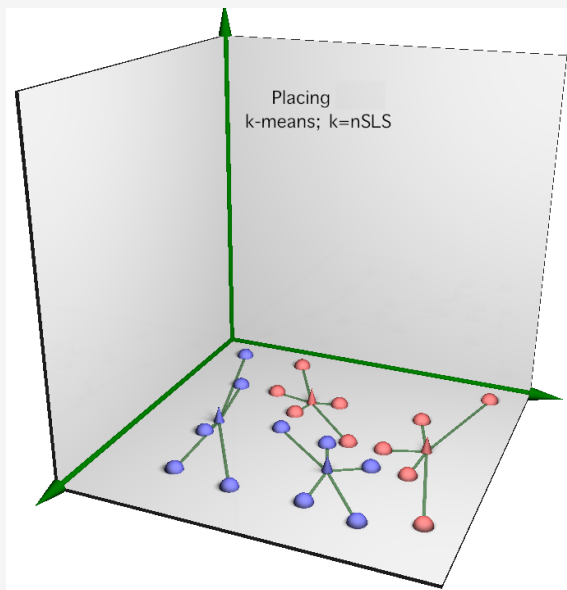
- **Placing:** Encontrar as posições iniciais dos segmentos de reta, aplicando K-means.
- **Tunning:** Minimizar o erro quadrático ( $MSE$ ), usando o método de Gradiente Descendente.

$$MSE(y_{\mathcal{L}_0, \mathcal{L}_1}) = \frac{1}{n} \sum_{i=1}^n [y_{\mathcal{L}_0, \mathcal{L}_1}(x_i) - y_i]^2$$


# Classificador SLS - Treinamento




# Classificador SLS - Treinamento




# Classificador SLS - Treinamento




# Classificador SLS - Treinamento




# Classificador SLS - Treinamento




# Classificador SLS - Treinamento



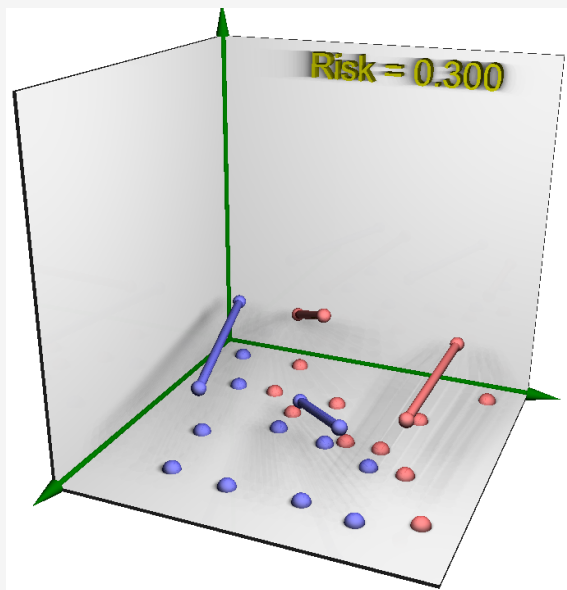
# Classificador SLS - Treinamento







# Classificador SLS - Treinamento



- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - **Algoritmos de Agrupamento**
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais


- Abordagem por particionamento,
- Cada ponto está associado ao agrupamento com a média mais próxima,
- A distância entre cada ponto e cada um dos centróides deve ser calculada para encontrar o agrupamento ao qual pertencem, tornando o algoritmo lento.

## Limitações

- O valor de  $K$  deve ser especificado,
- *K-Means* sofre com problemas de mínimos locais,


## Limitações

- O valor de  $K$  deve ser especificado,
- *K-Means* sofre com problemas de mínimos locais,
- Assume uma distribuição gaussiana esférica, dados alongados podem ter os seus dados misturados,



## Limitações


- O valor de  $K$  deve ser especificado,
- *K-Means* sofre com problemas de mínimos locais,
- Assume uma distribuição gaussiana esférica, dados alongados podem ter os seus dados misturados,
- Efeito pode ser minimizado usando uma quantidade maior de agrupamentos.





- Algoritmo recursivo, executa divisões binárias do espaço até chegar ao melhor valor de agrupamentos, dentro dos limites fornecidos,
- Inicia com  $K$  agrupamentos (limite inferior) e vai adicionando centróides onde for necessário até atingir o limite superior de agrupamentos,

## Ideia Geral




- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

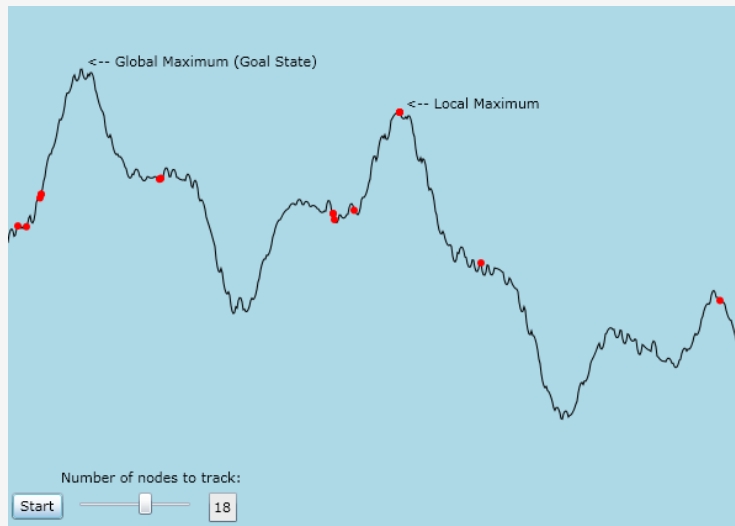
- É uma variação do algoritmo *Local Search*, o qual mantém um estado atual único e procura uma melhor solução se deslocando aos pontos vizinhos,
  - *K-Beams* lida com esse problema, controlando um valor de  $k$  estados e não um único estado atual,
- 1 Inicia com  $k$  estados gerados aleatoriamente;
  - 2 Em cada estado, são gerados sucessores para cada um;
  - 3 Se não for atingido o valor ideal, seleciona os melhores  $k$  estados do conjunto e repete os passos 1 e 2, caso contrário, o algoritmo deve parar.

# Exemplo do *K-Beams*<sup>3</sup>



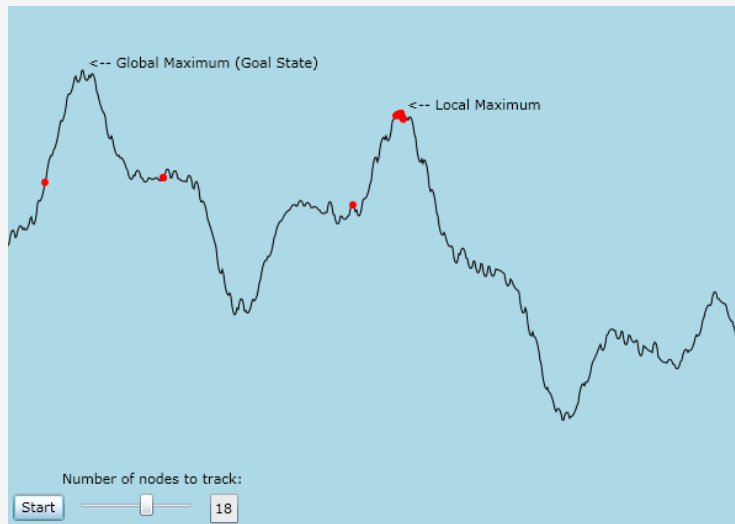
<sup>3</sup> <http://code.google.com/p/stochastic-beam-search-demo/>

# Exemplo do *K-Beams*<sup>3</sup>



<sup>3</sup> <http://code.google.com/p/stochastic-beam-search-demo/>


# Exemplo do *K-Beams*<sup>3</sup>



<sup>3</sup> <http://code.google.com/p/stochastic-beam-search-demo/>

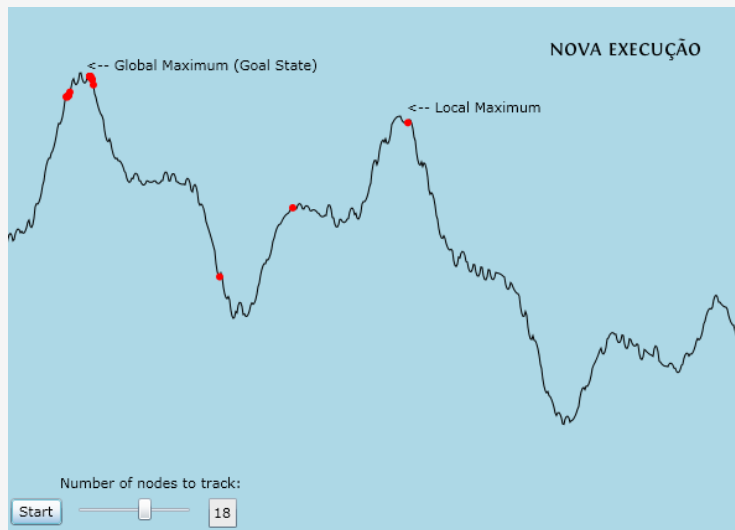


# Exemplo do *K-Beams*<sup>3</sup>




<sup>3</sup> <http://code.google.com/p/stochastic-beam-search-demo/>

# Exemplo do *K-Beams*<sup>3</sup>




<sup>3</sup> <http://code.google.com/p/stochastic-beam-search-demo/>

# Exemplo do *K-Beams*<sup>3</sup>



<sup>3</sup> <http://code.google.com/p/stochastic-beam-search-demo/>

# Exemplo do *K-Beams*<sup>3</sup>



<sup>3</sup> <http://code.google.com/p/stochastic-beam-search-demo/>

- Método evolutivo baseada na Dialética Materialista para resolver problemas de busca e otimização. <sup>4</sup>

---

<sup>4</sup>W.P. Dos Santos, F.M. De Assis, R.E. De Souza, P.B. Mendes, H.S.S Monteiro e H.D. Alves. Dialectical Non-Supervised Image Classification. Em *Proceedings of the Eleventh Conference on Congress on Evolutionary Computation*, CEC'09.

- Método evolutivo baseada na Dialética Materialista para resolver problemas de busca e otimização. <sup>4</sup>
- Um problema de otimização está composto por um conjunto de pólos.

---

<sup>4</sup>W.P. Dos Santos, F.M. De Assis, R.E. De Souza, P.B. Mendes, H.S.S Monteiro e H.D. Alves. Dialectical Non-Supervised Image Classification. Em *Proceedings of the Eleventh Conference on Congress on Evolutionary Computation*, CEC'09.

- Método evolutivo baseada na Dialética Materialista para resolver problemas de busca e otimização. <sup>4</sup>
- Um problema de otimização está composto por um conjunto de pólos.
- Estes pólos estão envolvidos em processos de *lutas de pólos* e são afetados por *crises revolucionárias*.

---

<sup>4</sup>W.P. Dos Santos, F.M. De Assis, R.E. De Souza, P.B. Mendes, H.S.S Monteiro e H.D. Alves. Dialectical Non-Supervised Image Classification. Em *Proceedings of the Eleventh Conference on Congress on Evolutionary Computation*, CEC'09.

- Método evolutivo baseada na Dialética Materialista para resolver problemas de busca e otimização. <sup>4</sup>
- Um problema de otimização está composto por um conjunto de pólos.
- Estes pólos estão envolvidos em processos de *lutas de pólos* e são afetados por *crises revolucionárias*.
- Estes dois processos, fazem o sistema ter uma tendência à estabilidade.

---

<sup>4</sup>W.P. Dos Santos, F.M. De Assis, R.E. De Souza, P.B. Mendes, H.S.S Monteiro e H.D. Alves. Dialectical Non-Supervised Image Classification. Em *Proceedings of the Eleventh Conference on Congress on Evolutionary Computation*, CEC'09.



- **Pólo:** Solução candidata ao problema:

$$w_i = (w_{i,1}, w_{i,2}, \dots, w_{i,n})^T$$

# Método de Otimização Dialética

## Conceitos Básicos

- **Pólo:** Solução candidata ao problema:

$$w_i = (w_{i,1}, w_{i,2}, \dots, w_{i,n})^T$$

- **Conjunto de Pólos:**  $\omega = \{w_1, w_2, \dots, w_m\}$ ,  $m$  é o número de pólos.

# Método de Otimização Dialética

## Conceitos Básicos

- **Pólo:** Solução candidata ao problema:

$$w_i = (w_{i,1}, w_{i,2}, \dots, w_{i,n})^T$$

- **Conjunto de Pólos:**  $\omega = \{w_1, w_2, \dots, w_m\}$ ,  $m$  é o número de pólos.
- **Força Social:** Associada com a função objetivo do problema, denotada por  $f(w_i)$

# Método de Otimização Dialética

## Conceitos Básicos

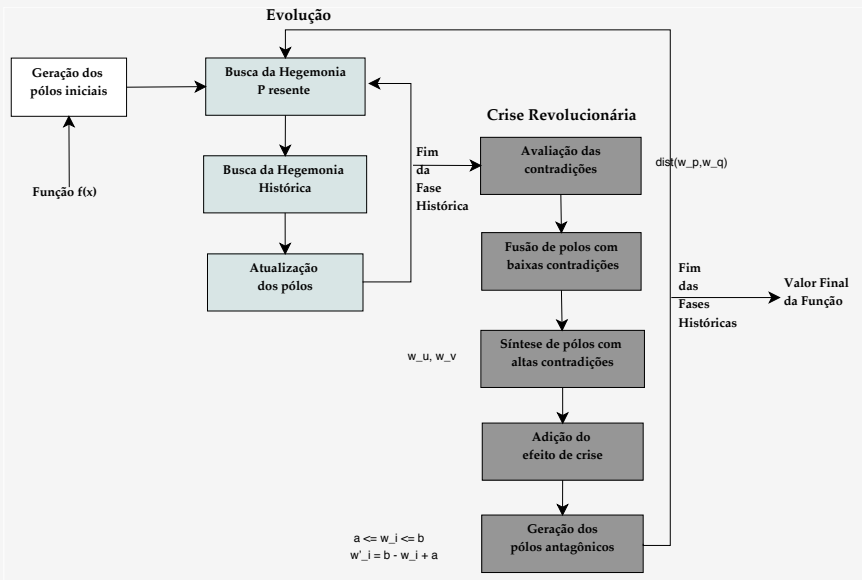
- **Pólo:** Solução candidata ao problema:

$$w_i = (w_{i,1}, w_{i,2}, \dots, w_{i,n})^T$$

- **Conjunto de Pólos:**  $\omega = \{w_1, w_2, \dots, w_m\}$ ,  $m$  é o número de pólos.
- **Força Social:** Associada com a função objetivo do problema, denotada por  $f(w_i)$
- **Contradição:** Dados dois pólos  $w_p$  e  $w_q$  é definida como:

$$\delta_{p,q} = \text{dist}(w_p, w_q)$$

# Método de Otimização Dialética - Algoritmo



- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - **Métodos Híbridos de Treinamento**
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

### **1 Algoritmos Evolutivos:**

- Procuram pela região do mínimo global,
- Proporciona diversidade de soluções.



### 1 Algoritmos Evolutivos:

- Procuram pela região do mínimo global,<sup>5</sup>
- Proporciona diversidade de soluções.

### 2 Gradiente Descendente:

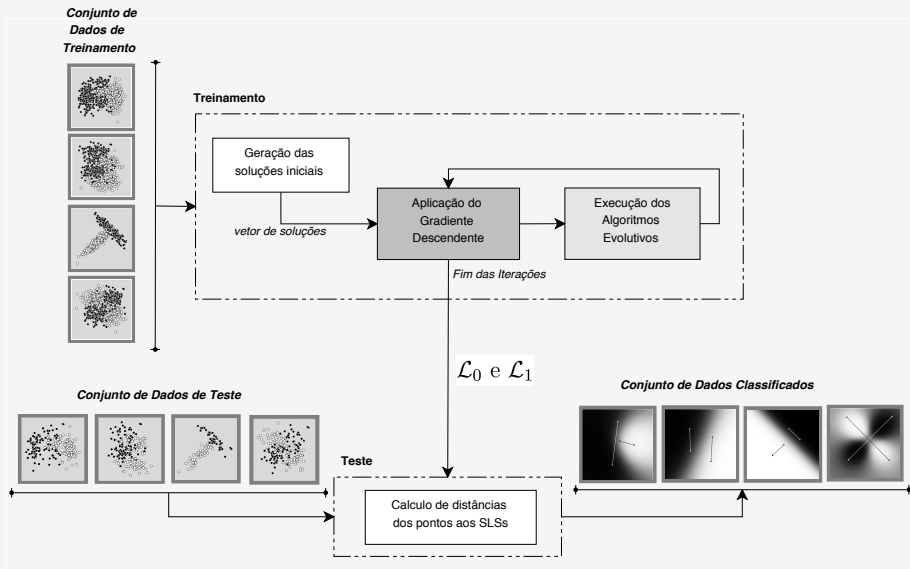
- Rapidez para encontrar um mínimo local,
- Procura pelo valor ótimo.

---

<sup>5</sup> J. Heistermann. A mixed genetic approach to the optimization of neural controllers. Em Proceedings of Computer Systems and Software Engineering.

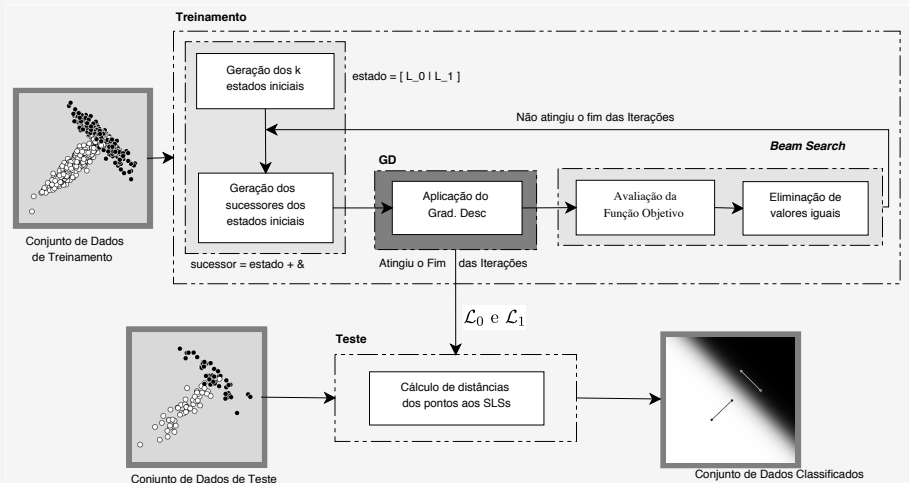
# Algoritmos Híbridos de Treinamento

## Algoritmo Geral



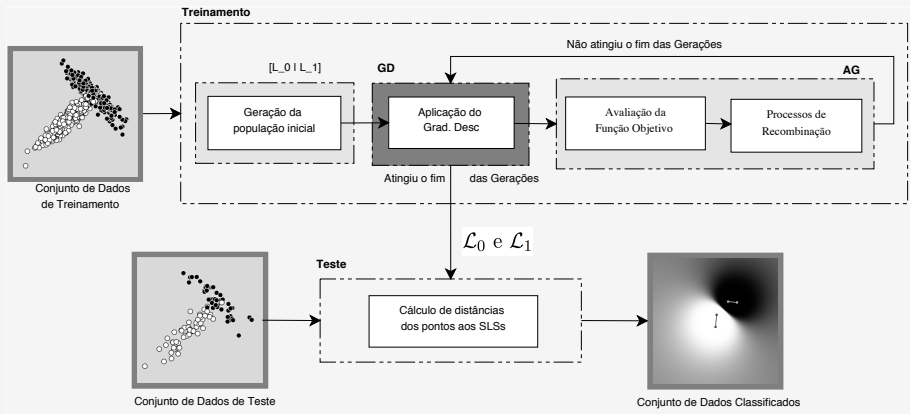
# Algoritmos Híbridos de Treinamento

## Gradiente Descendente e *K-Beams*



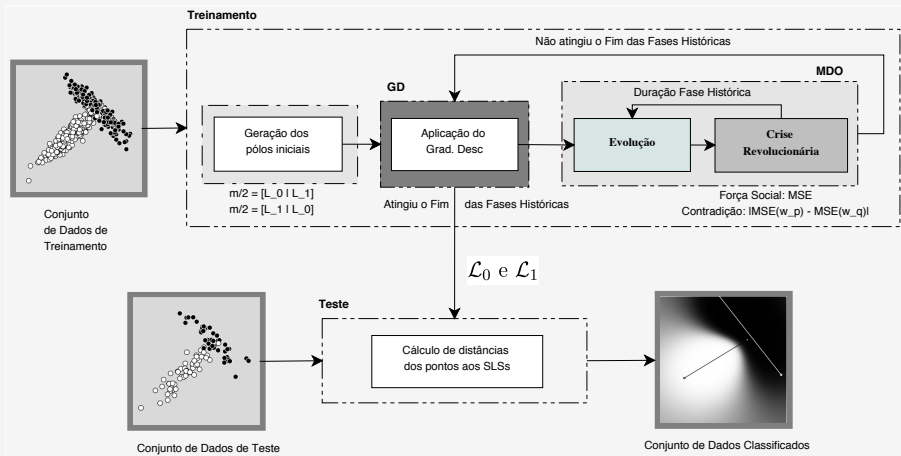
# Algoritmos Híbridos de Treinamento

## Gradiente Descendente e Algoritmos Genéticos



# Algoritmos Híbridos de Treinamento

## Gradiente Descendente e Método Dialético de Otimização



- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

# Proposta

## Estimar o Número de Segmentos de Reta

- 1 *Busca Exaustiva*: Explorar qual é o desempenho do classificador SLS quando o número de segmentos de reta, que representarão cada classe, é diferente,


<b>nsls</b>	1	2	3	4
1	<b>1-1</b>	1-2	1-3	1-4
2	2-1	<b>2-2</b>	2-3	2-4
3	3-1	3-2	<b>3-3</b>	3-4
4	4-1	4-2	4-3	<b>4-4</b>

- 2 *Usar X-Means*: Evitar a definição a priori do número de segmentos de reta a serem usados na configuração do algoritmo de treinamento.



# Busca Exaustiva


## Agrupamentos Iniciais




Distribuição F

# Busca Exaustiva


## Posições dos Segmentos de Reta Finais




76.86%




78.92%




75.00%




79.77%




85.21%



**87.17%**




86.99%




85.96%


Bayes: **87.66%**




82.98%



85.10%




85.42%



85.73%



85.23%



79.63%



86.55%




84.36%


# Aplicação do X-Means

## Posições dos Segmentos de Retas


Tx. ACERTO BAYES	USANDO X-MEANS				K-MEANS
	<u>2 - 2 SLS</u>	<u>3 - 2 SLS</u>	<u>4 - 2 SLS</u>	<u>4 - 3 SLS</u>	<u>2 - 2 SLS</u>
	100 EXEMPLOS	800 EXEMPLOS	1600 EXEMPLOS	3200 EXEMPLOS	1600 EXEMPLOS
<b>87.66%</b>	85.89%	84.87%	83.22%	<b>87.03%</b>	<b>(87.17%)</b>




Distribuição-F (1600 EXEMPLOS)




Classe 0




Classe 1



100 EXEMPLOS



1600 EXEMPLOS



800 EXEMPLOS




3200 EXEMPLOS

- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais


- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - **Dados Artificiais**
  - Dados Reais
- 5 Considerações Finais

# Resultados


## Distribuições Artificiais




F



S



SIMPLES




X


- 1 É possível aplicar o classificador de Bayes.

# Resultados


## Distribuições Artificiais




F



S



SIMPLES



X

- 1 É possível aplicar o classificador de Bayes.
- 2 A função de densidade de probabilidade é conhecida, portanto é possível aplicar integração numérica para calcular a taxa de acerto de classificação.

- # de Exemplos: 100, 200, 400 , 800, 1600 e 3200;
- Total de Amostras: 18 amostras, 3 para cada quantidade de exemplos;
- Algoritmos de Treinamento:
  - 1 (GD) - Gradiente Descendente,
  - 2 (AG+GD) - Algoritmos Genéticos e Gradiente Descendente,
  - 3 (AG) - Algoritmos Genéticos,
  - 4 (MDO+GD) - Método de Otimização Dialética e Gradiente Descendente,
  - 5 (KBM+GD) - *K-Beams* e Gradiente Descendente.



### ■ Parâmetros aplicados

AG+GD	Parâmetros		
	PARAM. 1	PARAM. 2	PARAM. 3
POPULAÇÃO	2	10	50
GERAÇÕES	2	5	3
MDO+GD	Parâmetros		
	PARAM. 1	PARAM. 2	PARAM. 3
PÓLOS	30	15	50
FASES	20	10	15
ITERAÇÕES	15	15	15

AG	Parâmetros		
	PARAM. 1	PARAM. 2	PARAM. 3
POPULAÇÃO	200	500	1000
GERAÇÕES	100	1000	500
KBM+GD	Parâmetros		
	PARAM. 1	PARAM. 2	PARAM. 3
ESTADOS	2	5	10
SUCESORES	10	20	15
ITERAÇÕES	3	10	5

### ■ Forma de estimar o número de segmentos de reta:

- 1 Busca Exaustiva: { 1..4; 2..4; 3..4; 4..4 }
- 2 *X-Means*.

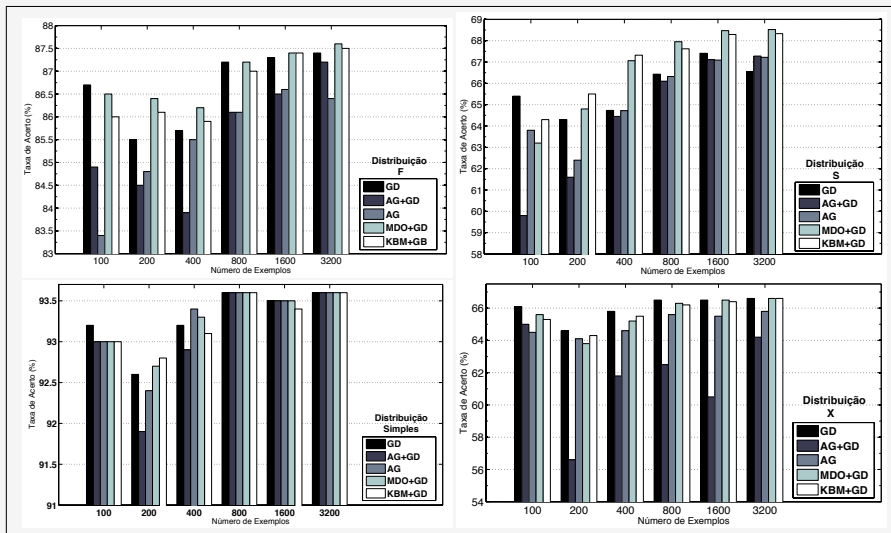
# Resultados para Dados Artificiais

## Experimentos

- Para cada distribuição, foram geradas 18 amostras;
- 16 treinamentos para cada amostra (**busca exaustiva**);
- Para cada algoritmo de treinamento: GD, AG+GD, AG, MDO+GD e KBM+GD;
- Aplicando as **três** variações de parâmetros;
- Ao total foram realizados: **16 056** treinamentos
  - 1 Busca exaustiva: 1 4975,
  - 2 *X-Means*: 1 080.

# Resultados para Dados Artificiais

## Experimento-1: Algoritmos de Treinamento



# Resultados para Dados Artificiais

## Experimento-1: Tabela de Resultados

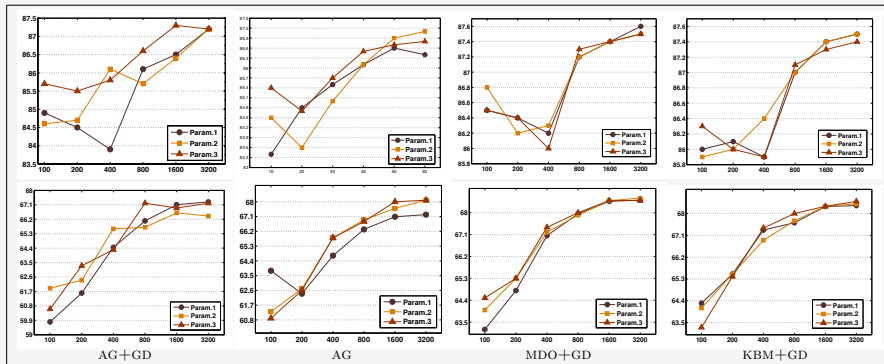
PORCENTAGEM DE ACERTO (%) PARA OS DIFERENTES ALGORITMOS DE TREINAMENTO																
		GD			AG+GD			AG			MDO+GD			KBM+GD		
EXEMPLOS	MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS	
F (87.66%)	100	<b>86.7</b>	0.04	3-3	84.9	0.67	4-4	83.4	4.60	3-2	<b>86.5</b>	0.25	1-4	<b>85.9</b>	0.70	2-4
	200	85.5	0.26	2-3	84.5	1.09	2-2	84.8	1.86	2-2	<b>86.4</b>	0.54	2-3	<b>86.1</b>	0.85	4-3
	400	85.7	0.99	3-4	83.9	1.47	4-4	85.5	0.19	4-4	<b>86.2</b>	0.58	1-2	<b>85.9</b>	0.59	3-3
	800	<b>87.2</b>	0.05	2-2	86.1	0.48	2-2	86.1	0.77	4-3	<b>87.2</b>	0.07	3-4	<b>87.0</b>	0.19	4-4
	1600	<b>87.3</b>	0.01	2-3	86.5	0.31	3-3	86.6	0.19	3-3	<b>87.4</b>	0.06	2-3	<b>87.4</b>	0.01	4-3
	3200	87.4	0.01	2-3	87.2	0.34	2-2	86.4	0.37	3-2	<b>87.6</b>	0.02	4-3	<b>87.5</b>	0.07	4-3
S (68.78%)	100	<b>65.4</b>	0.28	2-2	59.8	0.07	1-1	63.8	3.60	3-2	63.2	4.20	1-1	<b>64.3</b>	0.70%	2-3
	200	64.3	0.28	3-4	61.6	0.67	3-3	62.4	3.47	4-3	<b>64.8</b>	1.88	2-4	<b>65.5</b>	0.47	4-3
	400	64.7	3.81	1-2	64.5	2.36	2-2	64.7	1.50	4-4	<b>67.1</b>	0.98	1-2	<b>67.3</b>	0.82	2-4
	800	66.4	0.02	2-1	66.1	0.39	3-3	66.3	0.15	2-4	<b>67.9</b>	0.11	3-4	<b>67.6</b>	0.10	4-3
	1600	67.4	0.61	3-2	67.1	0.84	3-3	67.1	0.69	2-4	<b>68.5</b>	0.13	3-2	<b>68.3</b>	0.21	3-3
	3200	66.5	0.02	2-1	67.3	1.68	3-3	67.2	0.90	3-3	<b>68.5</b>	0.04	3-4	<b>68.3</b>	0.17	3-4
SIMPLES (93.90%)	100	<b>93.2</b>	0.01	1-2	92.9	0.01	1-1	93.0	0.13	2-1	<b>93.0</b>	0.03	4-4	<b>93.0</b>	0.06	2-3
	200	92.6	0.25	4-3	91.9	0.69	1-1	92.4	0.10	1-1	<b>92.7</b>	0.20	4-3	<b>92.8</b>	0.08	4-4
	400	93.2	0.29	4-3	92.9	0.35	3-2	<b>93.4</b>	0.18	2-1	<b>93.3</b>	0.13	2-1	93.1	0.06	3-2
	800	<b>93.6</b>	0.01	2-4	<b>93.6</b>	0.01	2-2	<b>93.6</b>	0.04	2-2	<b>93.6</b>	0.01	3-4	<b>93.6</b>	0.10	3-3
	1600	<b>93.5</b>	0.02	2-3	<b>93.5</b>	0.28	2-2	<b>93.5</b>	0.24	4-3	<b>93.5</b>	0.11	4-3	93.4	0.06	3-3
	3200	<b>93.6</b>	0.01	4-3	<b>93.6</b>	0.03	3-2	<b>93.6</b>	0.14	4-3	<b>93.6</b>	0.01	3-4	<b>93.6</b>	0.01	3-3
X (66.70%)	100	<b>66.1</b>	0.10	2-2	64.9	0.23	1-1	65.1	0.64	1-1	<b>65.5</b>	0.09	2-1	65.3	0.54	1-1
	200	<b>64.6</b>	1.41	1-1	56.6	1.85	2-3	64.1	0.89	2-2	63.8	1.36	2-2	<b>64.3</b>	1.13	1-2
	400	<b>65.8</b>	0.08	1-1	61.8	1.90	4-2	64.6	0.97	2-4	65.2	0.24	2-1	<b>65.5</b>	0.11	4-1
	800	<b>66.5</b>	0.00	1-1	62.5	1.12	2-3	65.6	0.28	2-4	<b>66.3</b>	0.25	1-2	66.2	0.20	3-1
	1600	<b>66.5</b>	0.01	1-1	60.5	3.56	4-3	65.5	0.42	4-2	<b>66.5</b>	0.08	1-3	66.4	0.05	1-1
	3200	<b>66.6</b>	0.01	2-2	64.2	2.47	3-2	65.8	0.12	4-4	<b>66.6</b>	0.06	2-4	<b>66.6</b>	0.02	4-2

### Conclusões:

- Apresentaram bons resultados os algoritmos MDO+GD e KBM+GD;
- Para a distribuição X o melhor algoritmo de treinamento foi GD;
- Na distribuição Simples, os 5 algoritmos testados atingiram um valor próximo do acerto de Bayes;

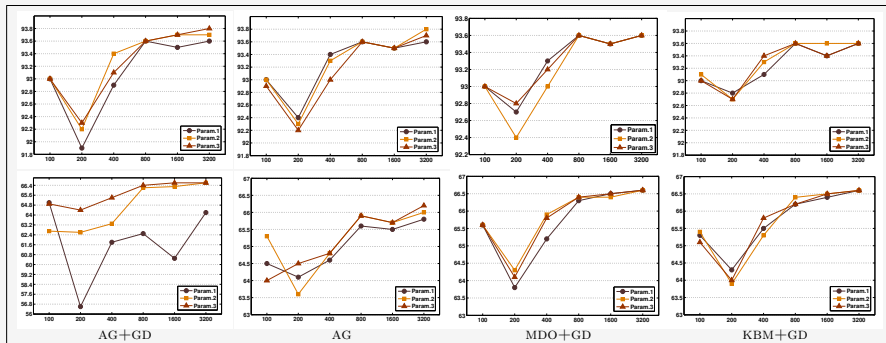
# Resultados para Dados Artificiais

## Experimento-2: Conjuntos de Parâmetros



# Resultados para Dados Artificiais

## Experimento-2: Conjuntos de Parâmetros



# Resultados para Dados Artificiais

## Experimento-2: Tabela de Resultados (AG+GD) e (AG)

	Parâmetros 1				Parâmetros 2			Parâmetros 3		
	EXEMPLOS	MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS
F (87.66%)	100	84.9	0.67	4-4	84.6	3.01	4-3	<b>85.7</b>	0.28	2-1
	200	84.5	1.09	2-2	84.7	0.81	3-3	<b>85.5</b>	0.44	4-2
	400	83.9	1.47	4-4	<b>86.1</b>	0.87	3-2	85.8	0.83	3-4
	800	86.1	0.48	2-2	85.7	1.11	2-2	<b>86.6</b>	0.31	4-3
	1600	86.5	0.31	3-3	86.4	0.07	4-4	<b>87.3</b>	0.06	2-2
	3200	87.2	0.34	2-2	<b>87.2</b>	0.16	2-2	<b>87.2</b>	0.17	3-4
S (68.78%)	100	59.8	0.07	2-2	<b>61.9</b>	2.00	1-4	60.6	1.84	2-3
	200	61.6	0.67	3-2	62.4	0.30	3-2	<b>63.3</b>	2.04	4-2
	400	64.5	2.36	2-1	<b>65.6</b>	1.13	3-4	64.3	1.53	3-2
	800	66.1	0.39	1-2	65.7	0.89	3-2	<b>67.2</b>	0.93	4-4
	1600	<b>67.1</b>	0.84	4-4	66.6	0.41	4-3	66.9	0.67	4-4
	3200	<b>67.2</b>	1.68	4-4	66.4	1.52	4-4	<b>67.2</b>	0.56	4-4
SIMPLES (93.90%)	100	<b>93.2</b>	0.01	1-1	93.0	0.02	2-1	93.0	0.01	4-2
	200	<b>92.6</b>	0.25	1-1	92.2	0.42	1-3	92.3	0.42	2-2
	400	93.2	0.29	3-2	<b>93.4</b>	0.17	3-3	93.1	0.47	2-3
	800	<b>93.6</b>	0.00	2-2	93.6	0.10	4-2	<b>93.6</b>	0.01	2-2
	1600	93.5	0.02	2-2	93.7	0.15	4-2	<b>93.7</b>	0.01	4-4
	3200	93.6	0.00	3-2	93.7	0.17	3-2	<b>93.8</b>	0.06	1-1
X (66.70%)	100	<b>65.0</b>	0.23	1-1	62.7	0.92	3-3	64.9	1.09	1-4
	200	56.6	1.85	2-3	62.6	1.27	1-4	<b>64.4</b>	0.69	1-1
	400	61.8	1.90	4-2	63.3	1.84	3-3	<b>65.4</b>	0.18	2-2
	800	62.5	1.12	2-3	66.2	0.10	2-3	<b>66.4</b>	0.03	2-2
	1600	60.5	3.58	4-3	66.3	0.20	2-2	<b>66.6</b>	0.01	2-3
	3200	64.2	2.47	3-2	<b>66.6</b>	0.02	2-2	66.6	0.89	4-2

	Parâmetros 1			Parâmetros 2			Parâmetros 3		
	MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS
F	82.7	4.60	3-2	84.5	0.72	3-3	<b>85.4</b>	1.14	3-2
	83.9	1.85	2-2	83.6	2.61	3-4	<b>84.7</b>	1.96	4-2
	85.2	0.19	4-4	85.0	0.43	3-3	<b>85.7</b>	0.94	2-3
	83.4	0.76	4-3	86.1	0.51	4-3	<b>86.5</b>	0.17	4-2
	86.0	0.19	3-3	<b>86.9</b>	0.26	2-3	86.7	0.63	2-4
	86.1	0.37	3-2	<b>87.1</b>	0.24	4-3	86.8	0.33	4-3
S	<b>63.8</b>	3.60	3-2	61.3	2.80	2-1	60.9	2.21	2-1
	62.4	3.47	4-3	<b>62.7</b>	2.94	1-2	62.6	3.98	2-3
	64.7	1.50	4-4	65.8	0.68	3-3	<b>65.8</b>	0.49	3-2
	66.3	0.15	2-4	<b>66.9</b>	0.60	2-3	66.8	0.78	1-2
	67.1	0.69	2-4	67.6	0.51	2-3	<b>68.0</b>	0.39	4-4
	67.2	0.90	3-3	68.1	0.39	3-4	<b>68.1</b>	0.07	2-4
SIMPLES	93.0	0.13	4-4	<b>93.0</b>	0.03	2-1	92.9	0.10	3-3
	<b>92.4</b>	0.09	4-3	92.3	0.26	1-1	92.2	0.43	3-4
	<b>93.4</b>	0.18	2-1	93.3	0.17	3-4	93.0	0.49	4-3
	93.6	0.04	3-4	93.6	0.05	4-4	<b>93.6</b>	0.04	1-1
	93.5	0.23	4-3	93.5	0.21	2-4	<b>93.5</b>	0.18	3-4
	93.6	0.14	3-4	<b>93.8</b>	0.06	1-1	93.7	0.09	3-4
X	64.5	0.64	2-1	<b>65.3</b>	0.65	1-2	64.0	0.19	1-2
	64.1	0.89	2-2	63.6	0.94	1-1	<b>64.5</b>	1.55	2-2
	64.6	0.97	2-1	64.8	0.71	1-1	<b>64.8</b>	0.63	2-2
	65.6	0.28	1-2	<b>65.9</b>	0.40	1-1	65.9	0.40	3-2
	65.5	0.42	1-3	<b>65.7</b>	0.41	1-1	65.7	0.48	2-2
	65.8	0.12	2-4	66.0	0.37	1-1	<b>66.2</b>	0.24	1-1



# Resultados para Dados Artificiais

## Experimento-2: Tabela de Resultados (MDO+GD) e (KBM+GD)

		Parâmetros 1				Parâmetros 2				Parâmetros 3			
		MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS	MÉDIA	DESVIO	SLSS
F (87.66%)	100	86.5	0.25	1-4	<b>86.8</b>	0.29	<b>1-4</b>	86.5	0.50	3-4	86.0	0.70	2-4
	200	86.4	0.54	2-3	86.2	0.77	2-4	<b>86.4</b>	0.49	<b>3-2</b>	<b>86.1</b>	0.85	<b>4-3</b>
	400	86.2	0.58	1-2	<b>86.3</b>	0.35	<b>1-2</b>	86.0	0.08	1-2	85.9	0.59	3-3
	800	87.2	0.07	3-4	87.2	0.03	4-2	<b>87.3</b>	0.15	<b>3-2</b>	87.0	0.19	4-4
	1600	<b>87.4</b>	0.06	<b>2-3</b>	87.4	0.08	3-3	87.4	0.09	3-4	<b>87.4</b>	0.01	<b>4-3</b>
	3200	<b>87.6</b>	0.02	<b>4-3</b>	87.5	0.04	4-3	87.5	0.02	3-3	87.5	0.06	4-3
S (68.78%)	100	63.2	4.20	1-1	64.0	3.50	4-1	<b>64.5</b>	1.79	<b>1-1</b>	<b>64.3</b>	0.70	<b>2-3</b>
	200	64.8	1.88	2-4	65.3	1.60	2-2	<b>65.3</b>	0.97	<b>3-2</b>	<b>65.5</b>	0.47	<b>4-3</b>
	400	67.1	0.98	1-2	67.2	0.27	2-4	<b>67.4</b>	0.35	<b>1-2</b>	67.3	0.82	2-4
	800	67.9	0.11	3-4	67.9	0.11	3-4	<b>68.0</b>	0.07	<b>3-2</b>	67.6	0.10	4-3
	1600	68.5	0.13	3-2	68.5	1.03	4-1	<b>68.5</b>	0.06	<b>4-3</b>	68.3	0.21	3-3
	3200	68.5	0.04	3-4	<b>68.6</b>	0.05	<b>2-4</b>	68.5	0.05	4-4	68.3	0.17	3-4
SIMPLES (93.90%)	100	93.0	0.03	4-4	<b>93.0</b>	0.01	<b>3-2</b>	93.0	0.03	3-3	93.0	0.06	2-3
	200	92.7	0.20	4-3	92.4	0.24	1-1	<b>92.8</b>	0.10	<b>3-4</b>	<b>92.8</b>	0.08	<b>4-4</b>
	400	<b>93.3</b>	0.13	<b>2-1</b>	93.0	0.60	3-4	93.2	0.30	4-3	93.1	0.06	3-2
	800	93.6	0.01	3-4	<b>93.6</b>	0.00	<b>4-4</b>	93.6	0.02	1-1	93.6	0.10	3-3
	1600	93.5	0.11	4-3	<b>93.5</b>	0.03	<b>2-4</b>	93.5	0.13	3-4	93.4	0.06	3-3
	3200	93.6	0.01	3-4	<b>93.6</b>	0.01	<b>1-1</b>	93.6	0.04	3-4	<b>93.6</b>	0.01	<b>3-3</b>
X (66.70%)	100	65.6	0.09	2-1	65.6	0.46	1-2	<b>65.6</b>	0.07	<b>2-1</b>	65.3	0.54	1-1
	200	63.8	1.36	2-2	<b>64.3</b>	1.55	<b>1-1</b>	64.1	0.86	1-1	<b>64.3</b>	1.13	<b>1-2</b>
	400	65.2	0.24	2-1	<b>65.9</b>	0.12	<b>1-1</b>	65.8	0.02	1-1	65.5	0.11	4-1
	800	66.3	0.25	1-2	66.4	0.07	1-1	<b>66.4</b>	0.01	<b>1-1</b>	66.2	0.20	3-1
	1600	66.5	0.08	1-3	66.4	0.08	1-1	<b>66.5</b>	0.01	<b>1-1</b>	66.4	0.05	1-1
	3200	66.6	0.06	2-4	66.6	0.03	1-1	<b>66.6</b>	0.02	<b>1-1</b>	66.6	0.02	4-2

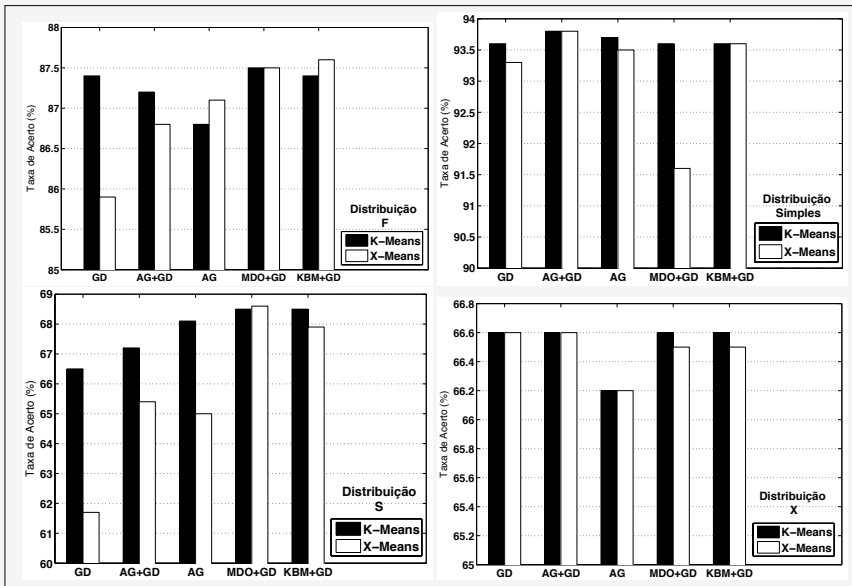
# Resultados para Dados Artificiais

## Experimento-2: Conclusões

- Para a maioria dos algoritmos de treinamento, a execução deles usando os **Parâmetros-3**, conseguiram obter as máximas porcentagens de acerto,
- Podemos concluir que aplicar qualquer uma das variações de parâmetros vai produzir resultados bons, pois os resultados indicam que os algoritmos são pouco sensíveis à variação de parâmetros.

# Resultados para Dados Artificiais

## Experimento-3: Estimação de Segmentos de Retas



# Resultados para Dados Artificiais

## Experimento-3: Tabela de Segmentos de Reta

DIST.	GD		AG+GD		AG		MDO+GD		KBM+GD	
	SLS-K	SLS-X	SLS-K	SLS-X	SLS-K	SLS-X	SLS-K	SLS-X	SLS-K	SLS-X
F	2-3	4-3	2-2	4-3	3-2	4-3	4-3	4-3	4-3	4-3
S	2-1	2-2	2-2	2-2	3-2	2-2	3-4	2-2	3-4	2-2
SIMPLES	4-3	4-4	3-2	4-4	4-3	4-4	3-4	4-4	3-3	4-4
X	2-2	2-2	3-2	2-2	4-4	2-2	2-4	2-2	4-2	2-2

# Resultados para Dados Artificiais

## Experimento-3: Tabela de Porcentagens

Ex	GD				AG+GD			AG			MDO+GD			KBM+GD		
	sls-X	Méd-X	Méd-K	sls-K	Méd-X	Méd-K	sls-K	Méd-X	Méd-K	sls-K	Méd-X	Méd-K	sls-K	Méd-X	Méd-K	sls-K
100	2-2	85.9	86.7	3-3	80.3	84.9	4-4	82.7	83.4	3-2	85.3	86.5	1-4	84.0	85.9	2-4
200	3-2	84.7	85.5	2-3	76.0	84.5	2-2	83.9	84.8	2-2	85.3	86.4	2-3	84.0	86.1	4-3
400	3-3	83.9	85.7	3-4	80.5	83.9	4-4	85.2	85.5	4-4	85.3	86.2	1-2	84.6	85.9	3-3
800	3-2	84.9	87.2	2-2	73.5	86.1	2-2	83.4	86.1	4-3	87.1	87.2	3-4	86.9	87.0	4-4
1600	4-2	83.2	87.3	2-3	82.5	86.5	3-3	86.0	86.6	3-3	87.4	87.4	2-3	87.2	87.4	4-3
3200	4-3	87.0	87.4	2-3	81.2	87.2	2-2	86.1	86.4	3-2	87.4	87.6	4-3	87.4	87.5	4-3
100	2-2	63.9	65.4	2-2	45.1	59.8	1-1	58.8	63.8	3-2	62.6	63.2	1-1	62.4	64.3	2-3
200	2-2	63.9	64.3	3-4	44.8	61.6	3-3	62.1	62.4	4-3	65.9	64.8	2-4	64.4	65.5	4-3
400	2-2	59.5	64.7	1-2	63.0	64.5	2-2	61.0	64.7	4-4	66.1	67.1	1-2	65.2	67.3	2-4
800	2-2	59.8	66.4	2-1	45.8	66.1	3-3	65.5	66.3	2-4	67.6	67.9	3-4	67.3	67.6	4-3
1600	2-2	59.8	67.4	3-2	58.9	67.1	3-3	65.3	67.1	2-4	67.9	68.5	3-2	68.0	68.3	3-3
3200	2-2	59.9	66.5	2-1	63.1	67.3	3-3	67.1	67.2	3-3	68.3	68.5	3-4	66.8	68.3	3-4
100	2-2	92.8	93.2	1-2	92.9	92.9	1-1	92.0	93.0	2-1	92.9	93.0	4-4	93.0	93.0	2-3
200	2-2	92.3	92.6	4-3	92.4	91.9	1-1	92.0	92.4	1-1	92.5	92.7	4-3	92.2	92.8	4-4
400	3-4	93.1	93.2	4-3	91.4	92.9	3-2	92.8	93.4	2-1	93.2	93.3	2-1	92.9	93.1	3-2
800	4-4	92.7	93.6	2-4	93.5	93.6	2-2	93.3	93.6	2-2	93.5	93.6	3-4	93.5	93.6	3-3
1600	4-4	92.7	93.5	2-3	92.1	93.5	2-2	93.2	93.5	4-3	93.5	93.5	4-3	93.4	93.4	3-3
3200	4-4	92.9	93.6	4-3	93.4	93.6	3-2	93.2	93.6	4-3	93.6	93.6	3-4	93.5	93.6	3-3
100	2-2	66.1	66.1	2-2	60.3	64.9	1-1	63.8	65.1	1-1	65.1	65.5	2-1	65.4	65.3	1-1
200	2-2	64.5	64.6	1-1	46.2	56.6	2-3	60.6	64.1	2-2	63.1	63.8	2-2	61.9	64.3	1-2
400	2-2	65.3	65.8	1-1	59.1	61.8	4-2	63.3	64.6	2-4	64.9	65.2	2-1	64.8	65.5	4-1
800	2-2	66.3	66.5	1-1	55.6	62.5	2-3	64.7	65.6	2-4	66.2	66.3	1-2	66.2	66.2	3-1
1600	2-2	66.3	66.5	1-1	58.2	60.5	4-3	64.2	65.5	4-2	66.3	66.5	1-3	66.3	66.4	1-1
3200	2-2	66.6	66.6	2-2	48.4	64.2	3-2	65.3	65.8	4-4	66.6	66.6	2-4	66.5	66.6	4-2

- Podemos dizer que usar o *X-Means* como técnica para determinar quantos segmentos representarão às classes, é uma boa alternativa pois a diferença entre as taxas de classificação para ambas técnicas é mínima,
- Enquanto ao tempo de treinamento, o algoritmo de *X-Means* representa uma boa alternativa para poupar tempo e conseguir resultados comparáveis com o melhor da busca exaustiva.

# Resultados para Dados Artificiais

		PARÂMETROS-1					PARÂMETROS-2					PARÂMETROS-3						
F	1-1	0.8	0.8	0.7	0.9	0.9	1-1	0.8	0.8	0.8	0.9	0.9	1-1	0.8	0.8	0.8	0.9	0.8
	1-2	0.8	0.8	0.8	0.9	0.8	1-2	0.8	0.8	0.8	0.9	0.8	1-2	0.8	0.9	0.9	0.9	0.9
	1-3	0.8	0.8	0.8	0.9	0.8	1-3	0.8	0.9	0.8	0.9	0.9	1-3	0.8	0.9	0.8	0.9	0.8
	1-4	0.8	0.7	0.8	0.9	0.6	1-4	0.8	0.9	0.8	0.9	0.8	1-4	0.8	0.9	0.8	0.9	0.9
	2-1	0.9	0.8	0.8	0.9	0.6	2-1	0.9	0.9	0.8	0.9	0.9	2-1	0.9	0.9	0.8	0.9	0.9
	2-2	0.8	0.9	0.8	0.9	0.9	2-2	0.8	0.9	0.9	0.9	0.9	2-2	0.8	0.9	0.9	0.9	0.9
	2-3	0.9	0.8	0.9	0.9	0.9	2-3	0.9	0.9	0.9	0.9	0.9	2-3	0.9	0.9	0.9	0.9	0.9
	2-4	0.9	0.8	0.9	0.9	0.9	2-4	0.9	0.9	0.9	0.9	0.9	2-4	0.9	0.9	0.9	0.9	0.9
	3-1	0.8	0.8	0.8	0.9	0.8	3-1	0.8	0.8	0.8	0.9	0.9	3-1	0.8	0.9	0.8	0.9	0.9
	3-2	0.9	0.6	0.9	0.9	0.9	3-2	0.9	0.9	0.9	0.9	0.9	3-2	0.9	0.9	0.9	0.9	0.9
	3-3	0.8	0.9	0.9	0.9	0.9	3-3	0.8	0.9	0.9	0.9	0.9	3-3	0.8	0.9	0.9	0.9	0.9
	3-4	0.9	0.7	0.9	0.9	0.9	3-4	0.9	0.9	0.9	0.9	0.9	3-4	0.9	0.9	0.9	0.9	0.9
	4-1	0.8	0.8	0.8	0.9	0.8	4-1	0.8	0.8	0.8	0.9	0.8	4-1	0.8	0.9	0.8	0.9	0.9
	4-2	0.8	0.8	0.9	0.9	0.9	4-2	0.8	0.9	0.9	0.9	0.9	4-2	0.8	0.9	0.9	0.9	0.9
4-3	0.9	0.8	0.9	0.9	0.9	4-3	0.9	0.9	0.9	0.9	0.9	4-3	0.9	0.9	0.9	0.9	0.9	
4-4	0.9	0.9	0.9	0.9	0.9	4-4	0.9	0.9	0.9	0.9	0.9	4-4	0.9	0.9	0.9	0.9	0.9	
*XM	0.9	0.8	0.9	0.9	0.9	*XM	0.9	0.9	0.9	0.9	0.9	*XM	0.9	0.9	0.9	0.9	0.9	
		GD	AG+GD	AG	MDO+GD	KBM+GD		GD	AG+GD	AG	MDO+GD	KBM+GD		GD	AG+GD	AG	MDO+GD	KBM+GD
S	1-1	0.6	0.6	0.6	0.7	0.6	1-1	0.6	0.6	0.6	0.6	0.6	1-1	0.6	0.6	0.6	0.7	0.6
	1-2	0.6	0.6	0.6	0.7	0.6	1-2	0.6	0.6	0.6	0.7	0.6	1-2	0.6	0.7	0.6	0.7	0.6
	1-3	0	0.5	0.7	0.7	0.7	1-3	0	0.6	0.7	0.7	0.6	1-3	0	0.6	0.6	0.7	0.6
	1-4	0	0.5	0.6	0.7	0.6	1-4	0	0.6	0.7	0.7	0.6	1-4	0	0.6	0.7	0.7	0.6
	2-1	0.7	0.6	0.6	0.7	0.6	2-1	0.7	0.6	0.6	0.7	0.6	2-1	0.7	0.6	0.6	0.7	0.7
	2-2	0.6	0.7	0.7	0.7	0.7	2-2	0.6	0.6	0.7	0.7	0.7	2-2	0.6	0.6	0.7	0.7	0.7
	2-3	0.6	0.6	0.7	0.7	0.7	2-3	0.6	0.7	0.7	0.7	0.7	2-3	0.6	0.6	0.7	0.7	0.7
	2-4	0	0.5	0.7	0.7	0.7	2-4	0	0.7	0.7	0.7	0.7	2-4	0	0.6	0.7	0.7	0.7
	3-1	0.4	0.5	0.6	0.7	0.6	3-1	0.4	0.6	0.7	0.7	0.6	3-1	0.4	0.6	0.6	0.7	0.6
	3-2	0.6	0.6	0.7	0.7	0.7	3-2	0.6	0.6	0.7	0.7	0.7	3-2	0.6	0.6	0.7	0.7	0.7
	3-3	0.6	0.7	0.7	0.7	0.7	3-3	0.6	0.6	0.7	0.7	0.7	3-3	0.6	0.7	0.7	0.7	0.7
	3-4	0.6	0.5	0.7	0.7	0.7	3-4	0.6	0.6	0.7	0.7	0.7	3-4	0.6	0.7	0.7	0.7	0.7
	4-1	0	0.5	0.6	0.7	0.6	4-1	0	0.6	0.7	0.7	0.6	4-1	0	0.6	0.7	0.7	0.6
	4-2	0.6	0.7	0.7	0.7	0.7	4-2	0.6	0.7	0.7	0.7	0.7	4-2	0.6	0.7	0.7	0.7	0.7
4-3	0.6	0.6	0.7	0.7	0.7	4-3	0.6	0.7	0.7	0.7	0.2	4-3	0.6	0.7	0.7	0.7	0.7	
4-4	0.6	0.7	0.7	0.7	0.7	4-4	0.6	0.7	0.7	0.7	0.7	4-4	0.6	0.7	0.7	0.7	0.7	
*XM	0.6	0.6	0.7	0.7	0.7	*XM	0.6	0.6	0.7	0.7	0.7	*XM	0.6	0.7	0.6	0.7	0.7	
		GD	AG+GD	AG	MDO+GD	KBM+GD		GD	AG+GD	AG	MDO+GD	KBM+GD		GD	AG+GD	AG	MDO+GD	KBM+GD

# Resultados para Dados Artificiais

		PARÂMETROS-1					PARÂMETROS-2					PARÂMETROS-3				
Sp	1-1	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
	1-2	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
	1-3	0	0.9	0.9	0.9	0.9	0	0.9	0.9	0.9	0.9	0	0.9	0.9	0.9	0.9
	1-4	0	0.9	0.9	0.9	0.9	0	0.9	0.9	0.9	0.9	0	0.9	0.9	0.9	0.9
	2-1	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
	2-2	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
	2-3	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
	2-4	0	0.9	0.9	0.9	0.9	0	0.9	0.9	0.9	0.9	0	0.9	0.9	0.9	0.9
	3-1	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
	3-2	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
	3-3	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
	3-4	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
	4-1	0	0.9	0.9	0.9	0.6	0	0.9	0.9	0.9	0.9	0	0.9	0.9	0.9	0.9
	4-2	0.9	0.9	0.9	0.9	0.6	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
	4-3	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
4-4	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	
*XM	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	
		GD	AG+GD	AG	MDO+GD	KBM+GD	GD	AG+GD	AG	MDO+GD	KBM+GD	GD	AG+GD	AG	MDO+GD	KBM+GD
X	1-1	0.7	0.6	0.2	0.7	0.7	0.7	0.3	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7
	1-2	0.2	0.5	0.6	0.7	0.7	0.2	0.4	0.7	0.7	0.7	0.2	0.7	0.7	0.7	0.7
	1-3	0.2	0.4	0.7	0.7	0.7	0.2	0.5	0.7	0.7	0.7	0.2	0.7	0.7	0.7	0.7
	1-4	0.2	0.4	0.6	0.7	0.7	0.2	0.5	0.7	0.7	0.7	0.2	0.7	0.7	0.7	0.7
	2-1	0.2	0.4	0.6	0.7	0.7	0.2	0.6	0.7	0.7	0.7	0.2	0.6	0.7	0.7	0.7
	2-2	0.7	0.6	0.6	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7
	2-3	0.2	0.6	0.7	0.7	0.7	0.2	0.7	0.7	0.7	0.7	0.2	0.7	0.7	0.7	0.7
	2-4	0.2	0.6	0.6	0.7	0.7	0.2	0.7	0.7	0.7	0.7	0.2	0.7	0.6	0.7	0.7
	3-1	0.2	0.4	0.6	0.7	0.7	0.2	0.5	0.6	0.7	0.7	0.2	0.7	0.7	0.7	0.7
	3-2	0.2	0.6	0.6	0.7	0.7	0.2	0.6	0.7	0.7	0.7	0.2	0.7	0.6	0.7	0.7
	3-3	0.7	0.6	0.7	0.7	0.7	0.7	0.6	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7
	3-4	0.2	0.6	0.7	0.7	0.7	0.2	0.7	0.7	0.7	0.7	0.2	0.7	0.7	0.7	0.7
	4-1	0.2	0.3	0.6	0.7	0.5	0.2	0.6	0.7	0.7	0.7	0.2	0.7	0.6	0.7	0.7
	4-2	0.2	0.6	0.6	0.4	0.7	0.2	0.7	0.7	0.7	0.7	0.2	0.7	0.6	0.7	0.7
	4-3	0.2	0.6	0.7	0.7	0.7	0.2	0.7	0.7	0.7	0.7	0.2	0.7	0.7	0.7	0.7
4-4	0.7	0.5	0.7	0.7	0.7	0.7	0.6	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	
*XM	0.7	0.5	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7	
		GD	AG+GD	AG	MDO+GD	KBM+GD	GD	AG+GD	AG	MDO+GD	KBM+GD	GD	AG+GD	AG	MDO+GD	KBM+GD



- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
  - Dados Artificiais
  - Dados Reais
- 5 Considerações Finais

# Resultados para Dados Reais

## Atributos dos Dados

BD	Exemplos	Dimensão
Australian Credit Approval	690	14
Breast Cancer Winsconsin	683	9
Pima Indians Diabetes	768	8
German Credit Data	1000	20
Heart	270	13
Ionosphere	351	33
Liver Disorders	345	6
Sonar (Mines vs Rocks)	208	60

# Resultados para Dados Reais <sup>6</sup>

## Tabela de Porcentagens

DADOS PÚBLICOS	ALGORITMOS DE TREINAMENTO - PROPOSTA					MELHORES % - ORIGINAL	
	GD	AG+GD	AG	MDO+GD	KBM+GD	CLASS. SLS	SVM
AUSTRALIAN	<b>76.9</b> (0.6)	75,0(2,7e-04)	75,0 (2,7e-04)	75,0 (1,9e-04)	75,4 (0,6)	87.0 (1.8)	<u>87.4</u> (1.6)
BREAST-CANCER	<b>76.9</b> (2.4)	75.2 (0.4)	75.0 (0.0)	75.0 (0.0)	75.0 (0.0)	<u>98.1</u> (0.7)	97.9 (0.9)
DIABETES	75.9 (0.2)	81.2 (0.9)	75.1 (0.03)	<b>81.5</b> (1.1)	81.4 (0.7)	76.4 (1.8)	<u>77.8</u> (1.8)
GERMAN	76.5 (0.5)	80.5 (0.8)	75.2 (0.03)	80.7 (1.1)	<b>80.9</b> (0.7)	<u>76.7</u> (2.2)	77.3 (0.5)
HEART	75.5 (0.5)	77.0 (1.1)	75.0 (0.01)	<b>77.9</b> (1.7)	77.1 (0.9)	82.2 (3.3)	<u>85.1</u> (3.3)
IONOSPHERE	81.0 (3.5)	<b>94.7</b> (1.1)	74.5 (3.7)	<b>95.1</b> (1.1)	93.1 (1.8)	95.2 (2.6)	<u>96.0</u> (2.1)
LIVER-DISORDERS	75.8 (0.5)	<b>78.9</b> (1.9)	75.5 (0.3)	77.3 (1.8)	76.3 (1.2)	70.1 (2.8)	<u>72.7</u> (2.7)
SONAR	80.9 (1.8)	<b>88.9</b> (0.8)	75.3 (0.09)	87.6 (2.8)	87.8 (1.4)	86.3 (4.1)	<u>88.4</u> (4.2)

DADOS PÚBLICOS	X-MEANS	K-MEANS
	SLSS	SLSS
AUSTRALIAN	9-1	8-8
BREAST-CANCER	3-1	4-4
DIABETES	<b>3-5</b>	1-1
GERMAN	<b>5-3</b>	2-2
HEART	3-2	10-10
IONOSPHERE	2-8	10-10
LIVER-DISORDERS	<b>4-2</b>	3-3
SONAR	<b>2-2</b>	4-4

<sup>6</sup> A. Asuncion e D.J. Newman. UCI Machine Learning Repository. <http://archive.ics.uci.edu/ml/>, 2007.

# Resultados para Dados Reais

## Tempos de Execução

<u>BD</u>	GD	AG+GD	AG	MDO+GD	KBM+GD
	Média-sec (Desvíó)	Média (Desvíó)	Média (Desvíó)	Média (Desvíó)	Média (Desvíó)
Australian Credit Approval	3.31 (1.6)	2.20 (0.1)	1.08 (0.1)	1.88 (0.1)	13.51 (1.6)
Breast Cancer Winsconsin	0.34 (0.01)	1.01 (0.3)	0.38 (0.01)	1.67 (0.1)	3.75 (0.1)
Pima Indians Diabetes	5.31 (7.1)	1.46 (0.1)	0.76 (0.01)	2.75 (0.2)	8.11 (0.9)
German Credit Data	11.28 (0.9)	3.26 (1.2)	2.01 (0.01)	5.78 (0.5)	18.92 (0.8)
Heart	0.38 (0.4)	0.58 (0.1)	0.22 (0.01)	0.67 (0.03)	2.78 (0.1)
Ionosphere	4.49 (0.2)	3.79 (0.1)	1.05 (0.01)	1.80 (0.1)	12.91 (1.8)
Liver Disorders	0.70 (0.5)	77.74 (2.2)	75.40 (0.2)	77.14 (1.6)	76.49 (1.1)
Sonar (Mines vs Rocks)	8.36 (1.0)	1.26 (0.2)	0.45 (0.01)	1.03 (0.8)	3.95 (0.2)

- Podemos dizer também que o número de segmentos de reta utilizados tem grande influencia nos resultados.
- Não podemos garantir que o *X-Means* vai encontrar, para todos os casos, o número ótimo de segmentos de reta.

- 1 Introdução
- 2 Fundamentos Teóricos
  - Classificador SLS
  - Algoritmos de Agrupamento
  - Algoritmos de Otimização
- 3 Proposta
  - Métodos Híbridos de Treinamento
  - Estimar o Número de Segmentos de Reta
- 4 Resultados
- 5 Considerações Finais

- Aplicação de diferentes algoritmos evolutivos de otimização, os quais em combinação com o Gradiente Descendente permitam atingir um incremento na acurácia do classificador SLS.



# Considerações Finais

## Conclusões

- Aplicação de diferentes algoritmos evolutivos de otimização, os quais em combinação com o Gradiente Descendente permitam atingir um incremento na acurácia do classificador SLS.
- Uma contribuição deste trabalho foi o método híbrido de treinamento MDO+GD, cujos resultados foram apresentados no Sibgrapi 2011.<sup>7</sup>

---

<sup>7</sup> R.A. Medina e R.F. Hashimoto. Combining Dialectical Optimization and Gradient Descent methods for improving the accuracy of Straight Line Segments Classifiers. Em *Sibgrapi 2011: 24th Conference on Graphics, Patterns and Images Proceedings*

# Considerações Finais

## Conclusões

- Aplicação de diferentes algoritmos evolutivos de otimização, os quais em combinação com o Gradiente Descendente permitam atingir um incremento na acurácia do classificador SLS.
- Uma contribuição deste trabalho foi o método híbrido de treinamento MDO+GD, cujos resultados foram apresentados no Sibgrapi 2011.<sup>7</sup>
- Mostramos duas formas para estimar o número de segmentos de reta a serem usados no classificador SLS. Sendo a segunda opção (*X-Means*) a alternativa que propomos para ser usada a futuro no classificador.

---

<sup>7</sup> R.A. Medina e R.F. Hashimoto. Combining Dialectical Optimization and Gradient Descent methods for improving the accuracy of Straight Line Segments Classifiers. Em *Sibgrapi 2011: 24th Conference on Graphics, Patterns and Images Proceedings*

- A análise dos algoritmos evolutivos e parâmetros aplicados nas distribuições artificiais, não apresentou diferenças significativas. Pretendemos usar outras distribuições para conferir nossos resultados.

- A análise dos algoritmos evolutivos e parâmetros aplicados nas distribuições artificiais, não apresentou diferenças significativas. Pretendemos usar outras distribuições para conferir nossos resultados.
- Enquanto aos resultados dos dados reais, mostramos que uma combinação do Gradiente Descendente com outros algoritmos evolutivos pode gerar melhores resultados.

- Embora a proposta melhore a taxa de classificação o tempo de treinamento, foi incrementado, devido às múltiplas iterações próprias dos algoritmos evolutivos.

- Embora a proposta melhore a taxa de classificação o tempo de treinamento, foi incrementado, devido às múltiplas iterações próprias dos algoritmos evolutivos.
- As taxas de acerto não serão sempre as melhores, pois como mostramos nos resultados o *X-Means* pode encontrar um número errado de segmentos de reta.

- Embora a proposta melhore a taxa de classificação o tempo de treinamento, foi incrementado, devido às múltiplas iterações próprias dos algoritmos evolutivos.
- As taxas de acerto não serão sempre as melhores, pois como mostramos nos resultados o *X-Means* pode encontrar um número errado de segmentos de reta.
- Uma boa alternativa para o treinamento do classificador SLS é a combinação MDO+GD, já que apresentou bons resultados e ao contrário dos outros algoritmos evolutivos o número de soluções vai se reduzindo na execução do algoritmo.

- 1 Utilizar outros tipos de cálculo de distância,



- 1 Utilizar outros tipos de cálculo de distância,
- 2 Estender o classificador SLS a problemas de multiclassificação,

# Considerações Finais

## Trabalhos Futuros

- 1 Utilizar outros tipos de cálculo de distância,
- 2 Estender o classificador SLS a problemas de multiclassificação,
- 3 Aplicar o classificador em outros problemas reais além dos dados públicos disponíveis na Internet e,

# Considerações Finais

## Trabalhos Futuros

- 1 Utilizar outros tipos de cálculo de distância,
- 2 Estender o classificador SLS a problemas de multiclassificação,
- 3 Aplicar o classificador em outros problemas reais além dos dados públicos disponíveis na Internet e,
- 4 Investigar e estudar se é possível utilizar os segmentos de reta como descritores de formas.

# Algoritmos Evolutivos aplicados ao Classificador Baseado em Segmentos de Retas

Defesa de Mestrado

Aluna: Rosario A. Medina Rodríguez  
Orientador: Ronaldo Fumio Hashimoto

Instituto de Matemática e Estatística  
IME - USP

3 de Julho do 2012

