


Método de Partição com Distâncias Adaptativas para Dados Intervalares



Introdução – Métodos de Partição



- Obter uma partição de um conjunto de objetos em um número predefinido de grupos de tal maneira que os grupos obtidos são os mais **homogêneos e bem separados** possíveis.
- Normalmente as partições são construídas otimizando um **critério de qualidade** sobre uma partição.
- O problema de classificação torna-se um problema perfeitamente definido em otimização discreta:
 - Encontrar, entre o conjunto de todas as partições possíveis, uma partição que otimize um critério definido à priori.

Método de Nuvens Dinâmicas



- Família de métodos de cluster não hierárquicos com o objetivo de obter simultaneamente:
 - Uma partição de um número predefinido de classes
 - Identificar um conjunto de representantes das classes ou protótipos
- A idéia principal é associar uma representação a um conjunto de elementos
 - Minimizando um critério **W** de adequação entre classes e protótipos
 - Uma das vantagens é poder formular um problema de classificação em termos de **otimização** de um critério
- Etapas importantes: **representação e alocação**

Método de Nuvens Dinâmicas (Diday 1972)



- Seja $\Omega = \{\omega_1, \dots, \omega_i, \dots, \omega_N\}$ um conjunto de N objetos ou indivíduos descrito por p variáveis e cada objeto ω_i descrito por p variáveis $x_i = \{x_{i1}, \dots, x_{ip}\}$.
- Seja $L = \{L_1, \dots, L_K\}$ o conjunto de representantes da partição $P = \{P_1, \dots, P_K\}$ onde L_k é representado por um vetor de p medidas

$$\left(y_i^1, \dots, y_i^j, \dots, y_i^p \right)^T$$

- O critério W é definido por

$$W(P, L) = \sum_{k=1}^K D(P_k, L_k) = \sum_{k=1}^K \sum_{i \in P_k} d(x_i, y_k)$$

onde $D(P_k, L_k)$ mede a adequação entre a classe P_k a sua representação L_k e $d(x_i, y_k)$ mede a distância entre x_i e y_k .

Método de Nuvens Dinâmicas (Diday 1972)



- O problema de otimização é definido por: encontrar uma partição $P = \{P_1, \dots, P_K\}$ e um conjunto de protótipos $L = \{L_1, \dots, L_K\}$ de P tal que minimize o critério

$$W(P, L) = \sum_{k=1}^K D(P_k, L_k) = \sum_{k=1}^K \sum_{i \in P_k} d(x_i, y_k)$$

ou

$$W(P^*, L^*) = \text{Min}\{W(P, L) / P \in P_k, L \in L_k\}$$

Algoritmo Geral (Nuvens Dinâmicas)



(1) inicialização

No início tem-se uma partição C ou um subconjunto de K elementos de Ω .

(2) Etapa de representação

Para todo j de 1 a K faça calcular o protótipo y_k

(3) Etapa de afetação

test ← 0

Para todo i de 1 a N faça

determinar *uma classe* C_{k^*} tal que $k^* = \arg \min_{j=1, \dots, K} d(x_i, y_j)$

se $j \neq k^$ então faça* *test* ← 1

$$C_{k^*} \leftarrow C_{k^*} \cup \{i\} \text{ e } C_j \leftarrow C_j - \{i\}$$

(4) se *test* $\neq 0$ vá para (2)

Método de Nuvens Dinâmicas



- Algoritmo de Nuvens Dinâmicas com **distâncias Fixas**
 - Distância L1 (City-Block)
 - Distância L2 (Euclidiana)
 - Distância de Mahalanobis
- Algoritmo de Nuvens Dinâmicas com **distâncias Adaptativas**
 - Distância L1 (City-Block) (**Diday e Govaert, 1977**)
 - Distância L2 (Euclidiana) (**De Carvalho et al, 2004**)
 - Distância de Mahalanobis
 - Distância L_{∞} (Chebychev)
- E suas respectivas versões para dados intervalares

Método de Nuvens Dinâmicas



Usando Distância L1 (City-Block) Fixa

- **Problema de otimização**

- Encontrar y_k^j tal que minimize

$$W(P, L) = \sum_{i \in C_k} \sum_{j=1}^p d(x_i^j, y_k^j) = \sum_{j=1}^p \sum_{i \in C_k} |x_i^j - y_k^j|$$

- A solução para y_k^j é a **mediana** do conjunto $\{x_i^j\} \ i \in P_k$

Método de Nuvens Dinâmicas



Usando Distância L2 (Euclidiana) Fixa

- **Problema de otimização**

- Encontrar y_k^j tal que minimize

$$W(P, L) = \sum_{i \in C_k} \sum_{j=1}^p d^2(x_i^j, y_k^j) = \sum_{j=1}^p \sum_{i \in C_k} (x_i^j - y_k^j)^2$$

- A solução para y_k^j é a **média** do conjunto $\{x_i^j\} \ i \in P_k$

Nuvens Dinâmicas com Distâncias Adaptativas



- A idéia é associar uma distância diferente para cada classe que muda a cada iteração.
- O problema de otimização é definido por: encontrar uma partição $P=\{P_1,\dots,P_K\}$, um conjunto de protótipos $L=\{L_1,\dots,L_K\}$ de P e um conjunto de distâncias $d=\{d_1,\dots,d_k\}$ tal que minimize o critério

$$W(P, L, d) = \sum_{k=1}^K D(P_k, L_k, d_k) = \sum_{k=1}^K \sum_{i \in Q_k} d_k(x_i, y_k)$$

onde $d_k(x_i, y_k)$ é a distância adaptativa entre x_i e y_k

Algoritmo Geral (Versão Adaptativa)



(1) inicialização

No início tem-se uma partição C ou um subconjunto de K elementos de Ω .

(2) Etapa de representação

Para todo j de 1 a K faça calcular o protótipo y_k e a distância d_k

(3) Etapa de afetação

$test \leftarrow 0$

Para todo i de 1 a N faça

determinar uma classe C_{k^*} tal que $k^* = \arg \min_{j=1, \dots, K} d(x_i, y_j)$

se $j \neq k^*$ então faça $test \leftarrow 1$

$$C_{k^*} \leftarrow C_{k^*} \cup \{i\} \text{ e } C_j \leftarrow C_j - \{i\}$$

(4) se $test \neq 0$ vá para (2)

Método de Nuvens Dinâmicas



Usando Distância L1 (City-Block) Adaptativa

$$d_k(x_i, y_k) = \sum_{j=1}^p \lambda_k^j |x_i^j - y_k^j|$$

- **Problema de otimização** é dividido em duas partes
 - (1) Com a partição P e o conjunto de parâmetros fixos, encontrar o protótipo y_k^j tal que minimize

$$W(P, L, d) = \sum_{i \in C_k} d_k(x_i, y_k) = \sum_{i \in C_k} \sum_{j=1}^p \lambda_k^j |x_i^j - y_k^j| = \sum_{j=1}^p \lambda_k^j \left(\sum_{i \in C_k} |x_i^j - y_k^j| \right)$$

- A solução para y_k^j é a **mediana** do conjunto $\{x_i^j\} \mid i \in P_k$

Métodos de Nuvens Dinâmicas



Usando Distância L1 (City-Block) Adaptativa

- **Problema de otimização** é dividido em duas partes

(2) Com a partição P e o conjunto de protótipos fixos, encontrar o parâmetro λ_k^j tal que minimize

$$W(P, L, d) = \sum_{i \in C_k} d_k(x_i, y_k) = \sum_{i \in C_k} \sum_{j=1}^p \lambda_k^j |x_i^j - y_k^j| = \sum_{j=1}^p \lambda_k^j \left(\sum_{i \in C_k} |x_i^j - y_k^j| \right)$$

Satisfazendo as condições $\lambda_k^j > 0$ e $\prod_j \lambda_k^j = 1$

– A solução para λ_k^j é

$$\lambda_k^j = \frac{\prod_{h=1}^p \left(\sum_{i \in C_k} |x_i^h - y_k^h| \right)^{1/p}}{\sum_{i \in C_k} |x_i^j - y_k^j|}$$

Método de Nuvens Dinâmicas



Usando Distância L2 (Euclidiana) Adaptativa

$$d_k(x_i, y_k) = \sum_{j=1}^p \lambda_k^j (x_i^j - y_k^j)^2$$

- **Problema de otimização** é dividido em duas partes

(1) Com a partição P e o conjunto de parâmetros fixos, encontrar o protótipo y_k^j tal que minimize

$$W(P, L, d) = \sum_{i \in C_k} d_k(x_i, y_k) = \sum_{i \in C_k} \sum_{j=1}^p \lambda_k^j (x_i^j - y_k^j)^2 = \sum_{j=1}^p \lambda_k^j \left(\sum_{i \in C_k} (x_i^j - y_k^j)^2 \right)$$

- A solução para y_k^j é a **média** do conjunto $\{x_i^j\} \mid i \in P_k$

Método de Nuvens Dinâmicas



Usando Distância L2 (Euclidiana) Adaptativa

- **Problema de otimização** é dividido em duas partes

(2) Com a partição P e o conjunto de protótipos fixos, encontrar o parâmetro λ_k^j tal que minimize

$$W(P, L, d) = \sum_{i \in C_k} d_k(x_i, y_k) = \sum_{i \in C_k} \sum_{j=1}^p \lambda_k^j (x_i^j - y_k^j)^2 = \sum_{j=1}^p \lambda_k^j \left(\sum_{i \in C_k} (x_i^j - y_k^j)^2 \right)$$

Satisfazendo as condições $\lambda_k^j > 0$ e $\prod_j \lambda_k^j = 1$

– A solução para λ_k^j é

$$\lambda_k^j = \frac{\prod_{h=1}^p \left(\sum_{i \in C_k} (x_i^h - y_k^h)^2 \right)^{1/p}}{\sum_{i \in C_k} (x_i^j - y_k^j)^2}$$

Nuvens Dinâmicas versão para Intervalo



- O problema de otimização é definido por: encontrar uma partição $P = \{P_1, \dots, P_K\}$ e um conjunto de protótipos $L = \{L_1, \dots, L_K\}$ de P tal que minimize o critério

$$W(P, L) = \sum_{k=1}^K D(P_k, L_k) = \sum_{k=1}^K \sum_{i \in P_k} d(x_i, y_k)$$

ou

$$W(P^*, L^*) = \text{Min}\{W(P, L) / P \in P_k, L \in L_k\}$$

Nuvens Dinâmicas versão para Intervalo



Representação

- x_i é representado por um vetor de intervalos $x_i = (x_i^1, \dots, x_i^p)^T$, $x_i^j = [a_i^j, b_i^j]$ $a \leq b$.
- y_k é representado por um vetor de intervalos $y_k = (y_k^1, \dots, y_k^p)^T$, $y_k^j = [\alpha_k^j, \beta_k^j]$ $\alpha \leq \beta$.
- Um intervalo $[a, b]$ é considerado como um ponto (a, b) em \mathbb{R}^2 onde o eixo x é representado pelo **limite inferior a** e o eixo y é representado pelo **limite superior b**.

Nuvens Dinâmicas versão para Intervalo



Usando Distância L1 (City-Block) Fixa com intervalo

● Problema de otimização

- Encontrar y_k^j tal que minimize

$$W(P, L) = \sum_{i \in C_k} \sum_{j=1}^p d(x_i^j, y_k^j) = \sum_{j=1}^p |a_i^j - \alpha_k^j| + |b_i^j - \beta_k^j|$$

As diferenças entre os
limites inferiores

As diferenças entre os
limites superiores

- A solução para $y_k^j = [\alpha_k^j, \beta_k^j]$ é:

α_k^j



A mediana de $\{a_i^j, i \in C_k\}$, o conjunto dos **limites inferiores** dos intervalos de C_k .

β_k^j



A mediana de $\{b_i^j, i \in C_k\}$, o conjunto dos **limites superiores** dos intervalos de C_k .

Nuvens Dinâmicas versão para Intervalo



Usando Distância L2 (Euclidiana) Fixa com intervalo

● Problema de otimização

- Encontrar y_k^j tal que minimize

$$W(P, L) = \sum_{i \in C_k} \sum_{j=1}^p d(x_i^j, y_k^j) = \sum_{j=1}^p (a_i^j - \alpha_k^j)^2 + (b_i^j - \beta_k^j)^2$$

As diferenças entre os
limites inferiores

As diferenças entre os
limites superiores

- A solução para $y_k^j = [\alpha_k^j, \beta_k^j]$ é:

α_k^j



A média de $\{a_i^j, i \in C_k\}$, o conjunto dos limites inferiores dos intervalos de C_k .

β_k^j



A média de $\{b_i^j, i \in C_k\}$, o conjunto dos limites superiores dos intervalos de C_k .

Nuvens Dinâmicas versão para Intervalo



Usando Distância L_∞ (Chebychev) Fixa com intervalo

● Problema de otimização

- Encontrar y_k^j tal que minimize

$$W(P, L) = \sum_{i \in C_k} \sum_{j=1}^p d(x_i^j, y_k^j) = \sum_{j=1}^p \max \{ |a_i^j - \alpha_k^j|, |b_i^j - \beta_k^j| \}$$

As diferenças entre os
limites inferiores

As diferenças entre os
limites superiores

- A solução para $y_k^j = [\alpha_k^j, \beta_k^j]$ é:

α_k^j



A mediana do conjunto dos pontos médios dos intervalos de C_k - a mediana do conjunto dos comprimentos médios dos intervalos de C_k .

β_k^j



A mediana do conjunto dos comprimentos médios dos intervalos de C_k + a mediana do conjunto dos comprimentos médios dos intervalos de C_k .

Nuvens Dinâmicas versão para Intervalo



- Nuvens Dinâmicas com **distâncias Adaptativas de um componente**
 - Distância L1 (City-Block) (**De Souza e De Carvalho, 2004**)
 - Distância L2 (Euclidiana) (**De Carvalho et al, 2002**)
 - Distância L_∞ (Chebychev) (**Chavent e Lechevalier, 2002**)
- Nuvens Dinâmicas com **distâncias Adaptativas de dois componentes**
 - Distância L1 (City-Block) (**De Souza e De Carvalho, 2004**)
 - Distância L2 (Euclidiana) (**De Souza e De Carvalho, 2003**)
 - Distância L_∞ (Chebychev) (**De Souza e De Carvalho, 2004**)
- **O problema de otimização depende da escolha**
 - ⇒ Protótipo: $\{y_k^1, \dots, y_k^p\}$ com $y_k^j = [\alpha_k^j, \beta_k^j]$;
 - ⇒ Coeficientes: $\{\lambda_k^1, \dots, \lambda_k^p\}$.

Nuvens Dinâmicas versão para Intervalo



Usando Distância L1 (City-Block) **Adapt.** com intervalo

- **Um componente**

$$d(x_i^j, y_k^j) = \sum_{j=1}^p \lambda_k^j (|a_i^j - \alpha_k^j| + |b_i^j - \beta_k^j|)$$


- λ_k^j é um coeficiente que define d_k .

- **Dois componentes**


$$d(x_i^j, y_k^j) = \sum_{j=1}^p \lambda_{kL}^j (|a_i^j - \alpha_k^j|) + \lambda_{kU}^j (|b_i^j - \beta_k^j|)$$

- λ_{kL}^j é o coeficiente do limite inferior
- λ_{kU}^j é o coeficiente do limite superior

Nuvens Dinâmicas versão para Intervalo



Usando Distância L1 (City-Block) Adapt. com um componente



Mediana dos limites inferiores



Mediana dos limites superiores

O coeficiente λ_k^j é obtido como descrito em Diday e Govaert (1977) .

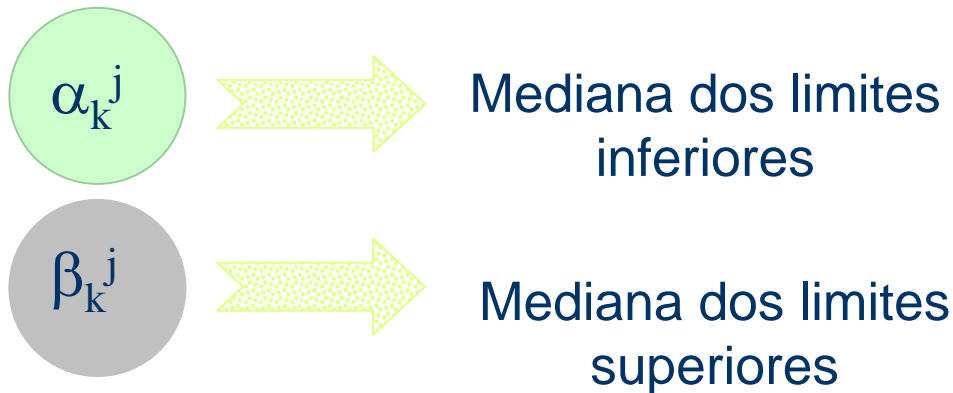
$$\lambda_k^j = \frac{\prod_{h=1}^p \left(\sum_{i \in C_k} \phi(x_i^h, y_k^h) \right)^{1/p}}{\sum_{i \in C_k} \phi(x_i^j, y_k^j)}$$

$$\phi(x_i^j, y_k^j) = |a_i^j - \alpha_k^j| + |b_i^j - \beta_k^j|$$

Nuvens Dinâmicas versão para Intervalo



Usando Distância L1 (City-Block) Adapt. com dois componente



A solução é a mesma da versão de um componente

$$\lambda_{kL}^j = \frac{\prod_{h=1}^p \left(\sum_{i \in C_k} |a_i^h - \alpha_k^h| \right)^{1/p}}{\sum_{i \in C_k} |a_i^j - \alpha_k^j|} \quad \lambda_{kU}^j = \frac{\prod_{h=1}^p \left(\sum_{i \in C_k} |b_i^h - \beta_k^h| \right)^{1/p}}{\sum_{i \in C_k} |b_i^j - \beta_k^j|}$$

Nuvens Dinâmicas versão para Intervalo



Usando Distância L2 (Euclidiana) **Adapt.** com intervalo

- **Um componente**

$$d(x_i^j, y_k^j) = \sum_{j=1}^p \lambda_k^j [(a_i^j - \alpha_k^j)^2 + (b_i^j - \beta_k^j)^2]$$

- λ_k^j é um coeficiente que define d_k .

- **Dois componentes**


$$d(x_i^j, y_k^j) = \sum_{j=1}^p \lambda_{kL}^j (a_i^j - \alpha_k^j)^2 + \lambda_{kU}^j (b_i^j - \beta_k^j)^2$$

- λ_{kL}^j é o coeficiente do limite inferior
- λ_{kU}^j é o coeficiente do limite superior


Nuvens Dinâmicas versão para Intervalo



Usando Distância L2 (Euclidiana) Adapt. com um componente



Média dos limites inferiores



Média dos limites superiores

O coeficiente λ_k^j é obtido como descrito em Diday e Govaert (1977) .

$$\lambda_k^j = \frac{\prod_{h=1}^p \left(\sum_{i \in C_k} \phi(x_i^h, y_k^h) \right)^{1/p}}{\sum_{i \in C_k} \phi(x_i^j, y_k^j)}$$

$$\phi(x_i^j, y_k^j) = (a_i^j - \alpha_k^j)^2 + (b_i^j - \beta_k^j)^2$$

Nuvens Dinâmicas versão para Intervalo



Usando Distância L2 (Euclidiana) Adapt. com dois componente

α_k^j



Média dos limites inferiores

β_k^j



Média dos limites superiores

A solução é a mesma da versão de um componente

$$\lambda_{kL}^j = \frac{\prod_{h=1}^p \left(\sum_{i \in C_k} (a_i^h - \alpha_k^h)^2 \right)^{1/p}}{\sum_{i \in C_k} (a_i^j - \alpha_k^j)^2} \quad \lambda_{kU}^j = \frac{\prod_{h=1}^p \left(\sum_{i \in C_k} (b_i^h - \beta_k^h)^2 \right)^{1/p}}{\sum_{i \in C_k} (b_i^j - \beta_k^j)^2}$$

Nuvens Dinâmicas versão para Intervalo



Usando Distância L_∞ (Chebychev) **Adapt.** com intervalo

- **Um componente**


$$d(x_i^j, y_k^j) = \sum_{j=1}^p \lambda_k^j (\max\{|a_i^j - \alpha_k^j|, |b_i^j - \beta_k^j|\})$$

- λ_k^j é um coeficiente que define d_k .


Nuvens Dinâmicas versão para Intervalo



Usando Distância L_∞ (Chebychev) Adapt. com um componente



A mediana do conjunto dos pontos médios dos intervalos de C_k – a mediana do conjunto dos comprimentos médios dos intervalos de C_k .



A mediana do conjunto dos comprimentos médios dos intervalos de C_k + a mediana do conjunto dos comprimentos médios dos intervalos de C_k .

O coeficiente λ_k^j é obtido como descrito em Diday and Govaert (1977) .

$$\lambda_k^j = \frac{\prod_{h=1}^p \left(\sum_{i \in C_k} \phi(x_i^h, y_k^h) \right)^{1/p}}{\sum_{i \in C_k} \phi(x_i^j, y_k^j)}$$

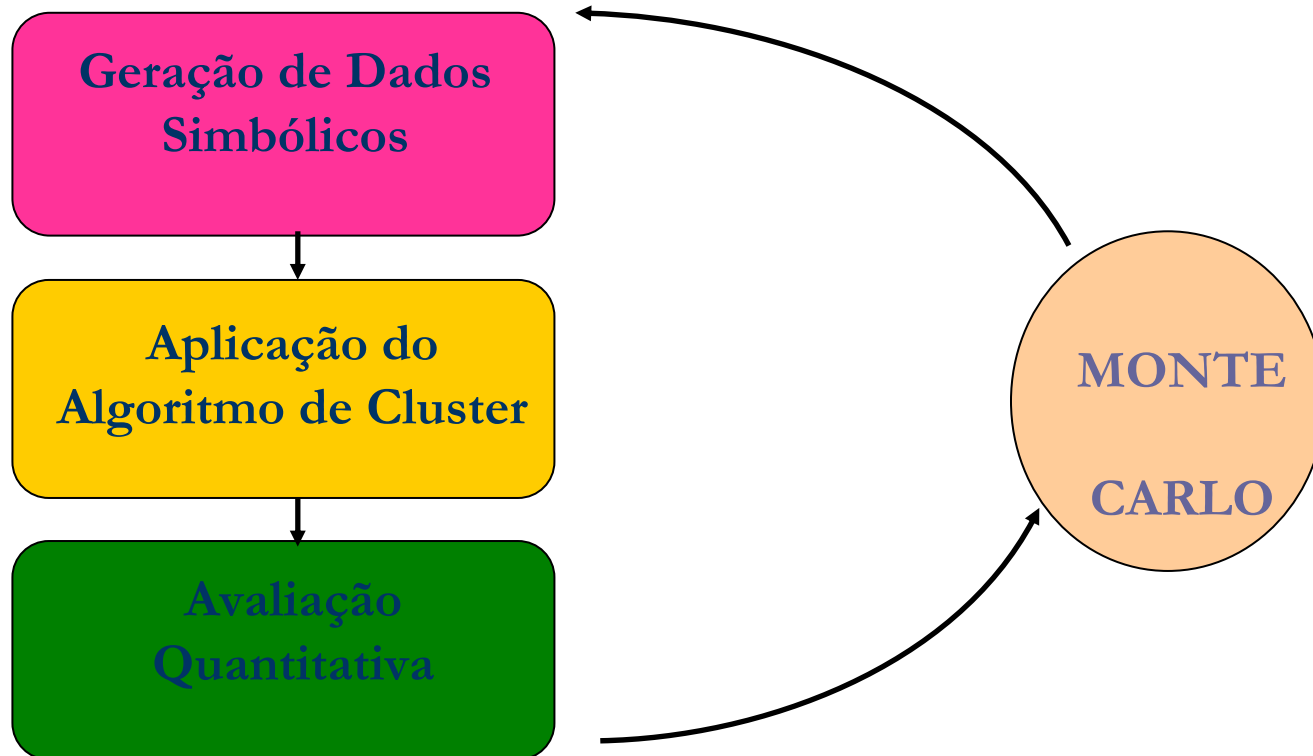
$$\phi(x_i^j, y_k^j) = \max\{|a_i^j - \alpha_k^j|, |b_i^j - \beta_k^j|\}$$



Resultados do Experimentos com Dados Artificiais e Reais



Estrutura do Sistema



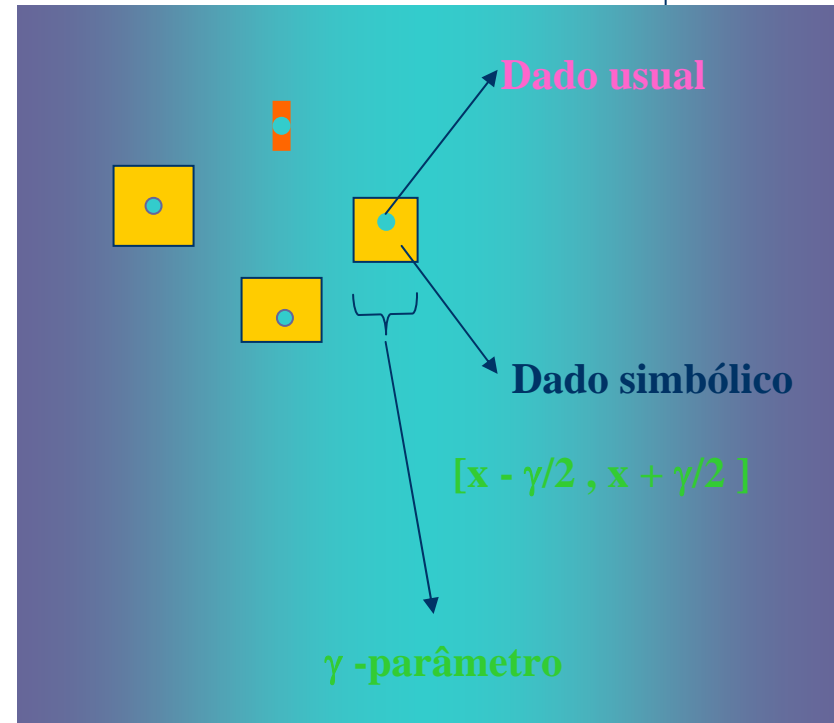


Etapa de geração de Dados Simbólicos

1) Geração de dados usuais

Sementes: Dados normais bidimensionais assumindo independência entre as variáveis

2) Geração de dados do tipo intervalo



A partir de um intervalo pré-definido, selecionar aleatoriamente dois valores para um parâmetro γ e obter o hipercubo.



Etapa de avaliação Quantitativa

Índice de Rand Corrigido mede a dissimilaridade entre uma partição a priori e uma partição obtida por um algoritmo de classificação.

$U = \{u_1, \dots, u_i, \dots, u_R\}$ - uma partição obtida por um método

$V = \{v_1, \dots, v_j, \dots, v_C\}$ - uma partição a priori

$$CR = \frac{\sum_{i=1}^R \sum_{j=1}^C \binom{n_{ij}}{2} - \binom{n}{2} - \binom{n}{2}^{-1} \sum_{i=1}^R \binom{n_i}{2} \sum_{j=1}^C \binom{n_j}{2}}{\frac{1}{2} \left[\sum_{i=1}^R \binom{n_i}{2} + \sum_{j=1}^C \binom{n_j}{2} \right] - \binom{n}{2}^{-1} \sum_{i=1}^R \binom{n_i}{2} \sum_{j=1}^C \binom{n_j}{2}}$$

n_{ij} representa o número de objetos que estão nas classes u_i e v_j ;

n_i representa o número de objetos que estão na classe u_i ;

n_j representa o número de objetos que estão na classe v_j ;

Configuração dos Experimentos



- Para cada conjunto de dados usuais foram obtidos cinco conjuntos de dados de intervalos. O parâmetro γ foi selecionado aleatoriamente nos intervalos $[1,8]$, $[1,16]$, $[1,24]$, $[1,32]$ e $[1,40]$.
- O desempenho dos métodos foi avaliado pelo **índice de Rand**
- Foram consideradas **100 réplicas** para cada conjunto de intervalos. A estimativa do índice de Rand foi a média dos 100 valores observados nas 100 replicações.
- **50 iterações** são consideradas para cada procedimento. Em cada iteração o algoritmo é executado até a convergência.


Resultados dos Experimentos



- Dois conjunto de dados de intervalo (três classes)


Conjunto 1

Classes bem Separadas




Conjunto 2

Classes com Overlapping



Resultados dos Experimentos – L1



Índice de Rand

Conjunto 1
(três classes)

Parâmetro γ	Método Adaptativo 1	Método Adaptativo 2	Método Não Adaptativo
[1,8]	0,933	0,939	0,680
[1,16]	0,934	0,932	0,651
[1,24]	0,887	0,884	0,630
[1,32]	0,764	0,766	0,620
[1,40]	0,683	0,691	0,619

Conjunto 2
(três classes)

Parâmetro γ	Método Adaptativo 1	Método Adaptativo 2	Método Não Adaptativo
[1,8]	0,464	0,464	0,382
[1,16]	0,426	0,425	0,366
[1,24]	0,399	0,399	0,360
[1,32]	0,385	0,385	0,359
[1,40]	0,368	0,367	0,354

Resultados dos Experimentos





- Dois conjunto de dados de intervalo (quatro classes)

Conjunto 1


Classes bem Separadas

Conjunto 2

Classes com Overlapping



Resultados dos Experimentos – L2



Índice de Rand

Conjunto 1
(quatro classes)

Parâmetro γ	Método Adaptativo 1	Método Adaptativo 2	Método Não Adaptativo
[1,8]	0,944	0,948	0,710
[1,16]	0,934	0,927	0,711
[1,24]	0,887	0,882	0,705
[1,32]	0,823	0,830	0,711
[1,40]	0,781	0,776	0,716

Conjunto 2
(quatro classes)

Parâmetro γ	Método Adaptativo 1	Método Adaptativo 2	Método Não Adaptativo
[1,8]	0,523	0,525	0,404
[1,16]	0,496	0,495	0,408
[1,24]	0,473	0,477	0,404
[1,32]	0,449	0,442	0,405
[1,40]	0,397	0,374	0,394

Resultados dos Experimentos – L_{∞}



Índice de Rand

Conjunto 1
(quatro classes)

Parâmetro γ	Método Adaptativo	Método Não Adaptativo
[1,8]	0,942	0,800
[1,16]	0,936	0,789
[1,24]	0,933	0,787
[1,32]	0,920	0,798
[1,40]	0,904	0,769

Conjunto 2
(quatro classes)

Parâmetro γ	Método Adaptativo	Método Não Adaptativo
[1,8]	0,492	0,436
[1,16]	0,483	0,432
[1,24]	0,463	0,430
[1,32]	0,436	0,390
[1,40]	0,340	0,329

Conclusão para os conjuntos 1 e 2




- A estimativa da média do índice de Rand para os métodos adaptativos é maior do que a estimativa para o método não adaptativo .
- Os testes t-Student emparelhados, em nível de 5% de significância, evidenciam a hipótese que o desempenho dos métodos adaptativos é superior ao do método não adaptativo e não existe diferença significativa entre os desempenhos dos métodos adaptativos 1 e 2.

Dados Reais: Conjunto de espécies de peixes




```
Espécies = (  
  (0,"AA00", "Ageneiosusbrevifili 1" ),  
  (1,"AA01", "Cynodongibbus 1" ),  
  (2,"AA02", "Hopliasaimara 1" ),  
  (3,"AA03", "Potamotrygonhystrix 1" ),  
  (4,"AA04", "Leporinusfasciatus 3" ),  
  (5,"AA05", "Leporinusfrederici 3" ),  
  (6,"AA06", "Dorasmicropoeus 2" ),  
  (7,"AA07", "Platydorascostatus 2" ),  
  (8,"AA08", "Pseudoancistrusbarbatus 2" ),  
  (9,"AA09", "Semaprochilodusvari 2" ),  
  (10,"AA10", "Acnodonoligacanthus 4" ),  
  (11,"AA11", "Myleusrubripinis 4" )  
  ),
```

```
Classes = (  
  (1 ,"AO01" ,"Carnivores" ,0),  
  (2 ,"AO02" ,"Détritivores" ,0),  
  (3 ,"AO03" ,"Omnivores" ,0),  
  (4 ,"AO04" ,"Herbivores" ,0 )  
  )
```



Conjunto com 12 elementos agrupados em quatro classes.



Cada elemento é descrito por 13 variáveis do tipo intervalo.

Conjuntos de espécies de peixes



Espécie / classe	Variáveis do tipo intervalo				
	Comprimento	Peso		Músculo/ Intestin	Músculo/ Estom.
Ageneiosusbrevifili 1	[22.5:35.5]	[170:625]	...	[0.23:0.63]	[0:0.55]
Cynodongibbus 1	[19:32]	[77:359]	...	[0:0.5]	[0.2:1.24]
Hopliasaïmara 1	[25.5:63]	[340:5500]		[0.11:0.49]	[0.09: 0.4]
:	:	:	...	:	:
Semaprochilodusvari 2	[22:28]	[330:700]		[0.4:1.68]	[0:1.25]
Acnodonoligacanthus 4	[10:16.2]	[34.9:154.7]	...	[0:2.16]	[0.23: 5.97]
Myleusrubripinis 4	[2.7:8,4]	[2.7:8.7]	...	[8.2:20]	[5.1:13.3]

Resultados da classificação usando o conjunto de peixes usando a distancia City-Block



Índice de Rand Corrigido

Classe 1: 1 2 6
Classe 2: 4 5 8 10 11
Classe 3: 0 9
Classe 4: 3 7



Método Não Adaptativo: 0.016

Classe 1: 10 11
Classe 2: 0 1 2
Classe 3: 6 7 9
Classe 4: 3 4 5 8



Método Adaptativo 1: 0.34

Classe 1: 1 9
Classe 2: 4 6 7
Classe 3: 5 8 10 11
Classe 4: 0 2 3



Método Adaptativo 2: 0.139