

## DETECÇÃO AUTOMÁTICA DE MUDANÇA DE COMPORTAMENTO EM INSTRUMENTOS DE MONITORAMENTO DE BARRAGEM DECORRENTES DE SISMOS

Fernando M. Bando (UNIOESTE) fernandobando@gmail.com

Jair Mendes Marques (UFPR) jair.marques@utp.br

Josiele Patias (ITAIPU BINACIONAL) jpatias@itaipu.br

Luiz Albino Texeira Junior (UNILA) luiz.a.t.junior@gmail.com

**Resumo:** Uma usina hidrelétrica consiste em um empreendimento de grande relevância para o desenvolvimento econômico e social de um país. No entanto, este é um tipo de obra que requer muita vigilância, pois a ocorrência de comportamentos atípicos em sua estrutura podem resultar em consequências indesejáveis. Abalos sísmicos são um dos fenômenos que requerem muita atenção dos responsáveis pela segurança de uma barragem, pois a sua ocorrência pode afetar diretamente o comportamento da sua estrutura. Este artigo tem como objetivo apresentar uma metodologia para detectar automaticamente quais instrumentos de monitoramento sofreram alguma mudança de padrão em suas medidas após a ocorrência de um sismo. A técnica de detecção proposta se baseia em uma formulação neuro-fuzzy-bayesiana dividida em três etapas. Primeiramente uma clusterização dos pontos da série temporal é desenvolvida a partir de um mapa auto-organizável de Kohonen. Em seguida, é construído um conjunto fuzzy para fim de transformar a série temporal inicial, com distribuição arbitrária, em uma nova série com distribuição de probabilidade beta, e assim, possibilitar a detecção dos pontos de mudança através de uma simulação de Monte Carlo via cadeias de Markov. Para mostrar a eficiência da proposta, a metodologia foi aplicada em séries temporais geradas por instrumentos de monitoramento das estruturas de barramento da Usina Hidrelétrica de Itaipu, os quais apresentaram pequenas mudanças no comportamento após a ocorrência de um sismo no Chile em 2010.

**Palavras-chave:** Segurança de Barragem, Redes Neurais Artificiais, Conjuntos Fuzzy, Simulação Monte Carlo.

## DETECTION AUTOMATIC OF BEHAVIOR CHANGE IN DAM MONITORING INSTRUMENTS ARISING OUT OF EARTHQUAKES

**Abstract:** A hydroelectric power plant consists of a project of great relevance for economic and social development of a country. However, this is a kind of achievement requires a lot of monitoring, once atypical stochastic behaviors in its structure might result in undesirable consequences. Earthquakes are one of the phenomena that require close attention by the dam safety staff because their occurrence might directly affect the behavior of its structure. Thus, a methodology for automatically detecting changing points in instruments at a Dam after the occurrence of an earthquake is put forward here. The technique detection of atypical stochastic behaviors used here is based on the neuro-fuzzy-bayesian formulation, which can be generally divided into three steps. Firstly, the observed points of a given time series is clustered by means of a self-organizing map of Kohonen. Secondly, a fuzzy set is built up in order to transform the initial time series with an arbitrary distribution into new data with the Beta probability distribution. Thirdly, the detection of changed points happens by using Monte Carlo Markov chains. In order to show the efficiency of neuro-fuzzy-bayesian method used here, some time series generated by monitoring instruments at Itaipu Hydroelectric that exhibit small changes in their behaviors after occurrence of an earthquake, in Chile in 2010, have been used.

**Keywords:** Dam Safety, Artificial Neural Network, Sets Fuzzy, Monte Carlo Simulation.

### 1. INTRODUÇÃO

Uma usina hidrelétrica consiste em um empreendimento de grande relevância para o desenvolvimento econômico e social de um país e a sua manutenção demanda grande capacidade da engenharia, na qual requer-se o envolvimento de profissionais de alta capacidade técnica. No tocante estrutura de uma barragem, a ocorrência de comportamentos estocásticos (ou aleatórios) atípicos podem resultar em consequências indesejáveis a níveis econômicos, ambientais e na segurança de pessoas (ICOLD, 2003). Em todo o cenário mundial, o tema segurança de barragens consiste em um assunto amplamente debatido.

O Brasil se mostra preocupado com a saúde de suas barragens. Nesse sentido, em 20 de setembro de 2010 entrou em vigor a lei no. 12.334 (BRASIL, 2010), que estabelece a Política Nacional de Segurança de Barragens destinadas à acumulação de água para quaisquer usos, à disposição final ou temporária de rejeitos e à acumulação de resíduos industriais, neste contexto também foi criado o Sistema Nacional de Informações sobre Segurança de Barragens (SNISB). Em seguida veio a resolução no. 144 de 10 de julho de 2012 (BRASIL, 2012), estabelecendo diretrizes para a implantação da política nacional de segurança de barragens, aplicação de seus instrumentos e atuação do sistema nacional de informação sobre segurança de barragens. Atualmente, as empresas responsáveis por barragens brasileiras adotam políticas de segurança baseadas nessa lei, de maneira a monitorar a segurança através de um sistema de instrumentação instalado em pontos estratégicos da barragem, o que permite amplo acompanhamento da saúde estrutural da barragem, diante da ocorrência de diversos eventos aleatórios (temperatura ambiente e da água, nível do reservatório, variação pluviométrica).

Um fenômeno que promove a atenção dos responsáveis pela segurança de uma barragem, são os tremores de terras, gerados por sismos de grande ou pequena magnitude. A ocorrência de um abalo sísmico, mesmo em um local distante da barragem pode gerar mudanças no comportamento da sua estrutura. Com efeito, na ocorrência de um sismo, faz-se necessário analisar as aferições de um grande número de instrumentos, para identificar eventuais mudanças no comportamento da estrutura ou fundações da barragem. Assim, a identificação de mudanças no comportamento gerada por um sismo pode ser feita manualmente, por meio de inspeções visuais dos gráficos das séries temporais das aferições feitas pelos instrumentos de monitoramento instalados. Não obstante, no caso de uma quantidade elevada de instrumentos, pode-se aumentar, consideravelmente, o tempo para a conclusão de todas as análises necessárias à tomada de decisões. Deste modo, uma metodologia computacional capaz de detectar, de forma automática, mudança de comportamento dos blocos que compõe a estrutura de uma barragem, após a ocorrência de um sismo, é de grande interesse dos envolvidos no gerenciamento de segurança de barragem.

Na literatura especializada, existem alguns métodos numéricos para a detecção automática de pontos de mudanças em séries temporais, por exemplo (HINKEY, 1971), (BARRY; HARTIGAN, 1993) e (LOSCHI; CRUZ, 2005). Não obstante, em linhas gerais, as técnicas existentes para este fim dependem de conhecimentos *a priori* do comportamento da série temporal, oriundos de modelos determinísticos ou estatísticos. Em algumas séries temporais não é possível obter o conhecimento *a priori* necessário para a aplicação das técnicas citadas. Um estudo atual que busca uma solução para esta situação é apresentado no trabalho de D'Angelo *et al.* (2011a), onde uma formulação neuro-fuzzy-bayesiana é utilizada para a detecção de ponto de mudança em séries temporais sem necessidade de qualquer conhecimento *a priori* do conjunto de dados; além de ter a vantagem de também detectar mudanças incipientes, isto é, mudanças que afetam gradualmente o funcionamento normal da estrutura (SOUZA *et al.*, 2012).

Este artigo apresenta uma adaptação da formulação neuro-fuzzy-bayesiana de detecção automática de ponto de mudança em séries temporais para ser aplicada na identificação de mudança de comportamento em dados gerados por instrumentos de monitoramento da segurança de uma barragem. A fim de avaliá-lo, é realizada uma aplicação utilizando séries temporais de dados de leituras de instrumentos de monitoramento da barragem de Itaipu, localizada em Foz do Iguaçu, Paraná, Brasil, que registaram pequenas mudança de regime estocásticos em seus comportamentos (as mudanças foram pequenas e as medidas retornaram ao seu regime histórico em um curto espaço de tempo), decorrentes após o abalo sísmico ocorrido em 27 de fevereiro de 2010 no Chile.

## 2. REVISÃO DE LITERATURA

### 2.1 Segurança de Barragens

O conceito de Segurança de Barragens pode ser definido como sendo a providência de condições que vise manter a integridade estrutural e operacional da barragem e a preservação da vida, da saúde, da propriedade e do meio ambiente (BRASIL, 2010). Quanto às características envolvidas na segurança de barragens, devem ser consideradas no projeto e por toda a vida útil da barragem; nesta perspectiva, de acordo com Silveira (2003), uma forma de avaliar o comportamento e a integridade de uma barragem é a adoção de um sistema de instrumentação capaz de monitorar numericamente os seus estados geotécnico e estrutural. Um plano de instrumentação, tem como seu principal objetivo garantir um nível de segurança adequado, monitorando se as premissas estabelecidas em projeto se mantêm sob controle.

Em geral, um sistema de instrumentos de monitoramento segue a norma NBR 8681 – Ações e Segurança das Estruturas (ABNT, 2003), que estabelece as verificações necessárias correspondentes à análise de estabilidade de uma barragem de concreto, visando avaliar a segurança quanto aos movimentos: deslizamento, tombamento, flutuação, tensões na base da fundação e na estrutura, deformações, recalques e vibrações (SILVEIRA, 2003).

Do ponto de vista físico, tais movimentos ocorrem pelo fato de que a diferença de nível de água gera um gradiente hidráulico entre montante e jusante da barragem, fazendo com que a água do reservatório queira passar para a jusante buscando o equilíbrio hidráulico. Para tal, a água percola principalmente através do maciço de fundação da barragem. Durante este processo, a água infiltrada gera forças verticais que atuam de baixo para cima sob a barragem, denominadas supressões na fundação (denotado por  $F_{\text{supressão}}$  na Figura 1). Além disso, a água do reservatório gera forças horizontais que atuam de montante à jusante sobre a barragem, denominadas pressões hidrostáticas contra a parede da barragem (denotado por  $F_{\text{reservatório}}$  na Figura 1). Estes dois tipos principais de sollicitação são referidas como forças desestabilizadoras, que combinadas podem acarretar o tombamento ou deslizamento da barragem (Figura 1). Isso ocorre também pelos esforços e momentos diretamente aplicados quanto pelo alívio de peso próprio da estrutura (denotado por  $P$  na Figura 1) (SILVEIRA, 2003). escreva nesta seção os materiais utilizados nos procedimentos experimentais. Detalhe como foram realizados os experimentos.

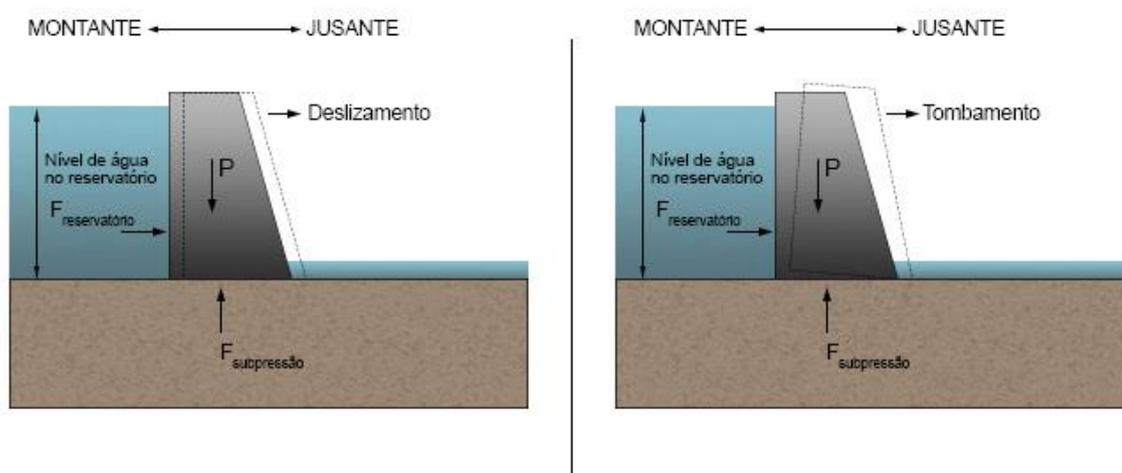


Figura 1 - Formas de desestabilização de uma barragem.

A fim de monitorar a estabilidade de uma estrutura, em termos de deslizamento ou tombamento, faz-se necessária a instalação de instrumentos capazes de medir os níveis das pressões

piezométricas na interface concreto-rocha e nas discontinuidades sub-horizontais existentes na fundação. Portanto, a medição da variável  $F_{\text{subpressão}}$  na fundação das barragens de concreto é de suma importância para a supervisão de suas condições de segurança, sendo os piezômetros os instrumentos mais indicados para realizar este monitoramento (ITAIPU, 2008).

## 2.2 Mapas Auto-Organizáveis de Kohonen

Mapas Auto-Organizáveis (SOM – *Self-Organizing Maps*) são algoritmos de clusterização baseados em redes neurais artificiais (RNA) com capacidade de auto-organização e de aprendizado não supervisionado (FAUSETT, 1994).

As arquiteturas auto-organizáveis, como propostas por T. Kohonen (1982), geram mapeamentos de um espaço de dimensão elevada em estruturas cuja dimensão topológica é inferior à original. Estes mapeamentos são capazes de preservar as relações de vizinhança dos dados de entrada.

Os mapas auto-organizáveis de Kohonen fazem parte de um grupo de RNA baseadas em modelos de competição, ou simplesmente, chamadas de redes competitivas. Estas redes combinam competição com uma forma de aprendizagem para fazer os ajustes de seus pesos. Outra característica importante, é o treinamento não-supervisionado, onde a rede busca encontrar similaridades baseando-se apenas nos padrões de entrada. O principal objetivo dos SOM é agrupar os dados de entrada que são semelhantes entre si formando *clusters* (CHUNG *et al.*, 2001).

Como em uma RNA a estrutura de um SOM é construída tendo o neurônio artificial como a unidade mais básica de processamento, cada um dos nós (neurônios) da rede possui uma posição topológica específica (uma coordenada  $x$  e  $y$ , por exemplo) e um vetor de pesos com a mesma dimensão que os vetores de entrada (HAYKIN, 2001).

Os nós do SOM são organizados em estruturas que podem corresponder a mapas unidimensionais ou  $n$ -dimensionais, variando de acordo com a aplicação. O aprendizado no SOM é baseado no aprendizado competitivo onde os nós de saída da rede que competem entre si para serem ativados. A formação do mapa ocorre em duas etapas: a estruturação inicial, que organiza os padrões de entrada no mapa, e a convergência final, responsável pelo refinamento (KOHONEN, 1990).

A segunda etapa leva mais tempo que a primeira, e é caracterizada pelos valores pequenos da taxa de aprendizado. Como muitas iterações através do conjunto de treinamento podem ser necessárias, costuma-se também estipular um máximo de iterações como condição de término do algoritmo (KASKI, 1997).

Durante a fase de aprendizado, calcula-se a distância de cada um dos nós para o padrão apresentado e identifica-se o vencedor. Isso permite especificar qual região do mapa será responsável por aprender o novo padrão.

O algoritmo de treinamento do SOM é apresentado abaixo (KASKI, 1997):

1. Inicialização e definições de parâmetros:

- Inicialize os pesos  $w_{ij}$ .
- Defina o Raio de vizinhança  $R$ .
- Defina o parâmetro de aprendizagem  $\alpha$ .

2. Enquanto a condição de parada é falsa, faça:

2.1. Para cada  $j$  calcule:

$$2.1.1. \quad D(j) = \sqrt{\sum_i (w_{ij} - x_i)^2}$$

2.1.2. Encontrar o índice  $J$  tal que  $D(J)$  é mínimo (vencedor).

2.1.3.  $\forall j$  pertencente a vizinhança definida por  $R$  de  $J$ , e  $\forall i$  faça:

$$w_{ij}(\text{nov}) = w_{ij}(\text{antigo}) + \alpha[x_i - w_{ij}(\text{antigo})].$$

2.2. Atualize a taxa de aprendizagem  $\alpha$ .

2.3. Reduza o raio de vizinhança  $R$ .

### 2.3 Conjuntos Fuzzy

A Teoria dos Conjuntos *Fuzzy* foi dada por L. A. Zadeh (1965), com a principal intenção de dar tratamento matemático a certos termos linguísticos subjetivos, como “muito”, “pequeno”, dentre outros. Esse foi o primeiro passo no sentido de se programar e armazenar conceitos vagos em computadores, tornando possível a produção de cálculos com informações imprecisas.

Segundo Dubois e Prade (1980) a formalização matemática de um conjunto *fuzzy*, baseia-se no fato de que qualquer conjunto clássico  $A \subset U$  pode ser descrito por sua função característica:  $\chi_A: U \rightarrow \{0,1\}$ , com  $\chi_A(x) = 1$  se  $x \in A$  e  $\chi_A(x) = 0$  se  $x \notin A$ .

A partir de uma “expansão” da imagem da função característica de um conjunto  $A$ , Zadeh sugeriu a formalização matemática de um conjunto *fuzzy*  $A$  (BARROS; BASSANEZI, 2010).

**Definição:** Um subconjunto *fuzzy*  $A$  do conjunto universo  $X$  é caracterizado por uma função  $\mu_A: X \rightarrow [0,1]$ , chamada função pertinência do conjunto *fuzzy*  $A$ .

O valor  $\mu_A(x) \in [0,1]$  indica o grau com que o elemento  $x$  de  $X$  pertence ao conjunto *fuzzy*  $A$ , com  $\mu_A(x) = 0$  e  $\mu_A(x) = 1$  indicando, respectivamente, a não pertinência e a pertinência completa de  $x$  ao conjunto *fuzzy*  $A$ .

Do ponto de vista formal, a definição de conjunto *fuzzy* foi obtida simplesmente ampliando-se o contra-domínio da função característica, que é o conjunto  $\{0,1\}$ , para o intervalo  $[0,1]$ . Neste sentido, pode-se dizer que um conjunto clássico é um caso particular de um dado conjunto *fuzzy*, cuja a função de pertinência é a sua função característica (ZIMMERMANN, 2010).

### 2.4 Amostrador de Monte Carlo via Cadeia de Markov

Segundo Box e Tiao (1992) a inferência Bayesiana é um método estatísticos que consiste em descrever as incertezas sobre quantidades de interesse de forma probabilística, tendo como característica a capacidade de combinar novas evidências com conhecimentos anteriores.

Quando o valor exato de uma quantidade  $\theta$  é desconhecido, a informação de que tem-se sobre  $\theta$ , resumida probabilisticamente por  $p(\theta)$ , pode ser aumentada através do conhecimento de informações aleatórias ( $X = x$ ) relacionadas com  $\theta$ . A regra de atualização que quantifica o aumento de informação é dada pelo Teorema de Bayes (JAMES, 2011),

$$p(\theta|x) = \frac{p(\theta, x)}{p(x)} = \frac{p(x|\theta)p(\theta)}{p(x)}. \quad (1)$$

Para um valor fixo de  $x$ , a função  $p(x|\theta)$  fornece a função de verossimilhança de cada um dos possíveis valores de  $\theta$ , denotada por  $l(\theta; x)$ , enquanto  $p(\theta)$  é chamada distribuição *a priori* de  $\theta$ , esta duas informações combinadas geram a distribuição *a posteriori* de  $\theta$ ,  $p(\theta|x)$  (PAULINO *et al.*, 2003).

Em geral, a inferência bayesiana consiste em calcular valores esperados para  $\theta$  segundo a sua distribuição *a posteriori*. Porém, a inferência exata só é possível se a integral envolvida no cálculo da esperança tem solução analítica, caso contrário, deve-se usar aproximações, e entre os métodos aproximados, o mais utilizado é dado pela simulação de Monte Carlo, que transforma o problema de avaliar a integral em um problema estatístico de gerar amostras de valores da distribuição *a posteriori* e estimar o valor médio da quantidade  $\theta$  (EHLERS, 2011).

Ainda, Ehlers (2011) descreve que, em muitas situações pode ser muito custoso ou mesmo impossível simular valores esperados da distribuição *a posteriori*. Neste caso, recorre-se a métodos de reamostragem, que geram valores de uma distribuição auxiliar e, em seguida, utilizam-se mecanismos para aceitar apenas valores que ao menos se aproximem da distribuição *a posteriori*. Contudo, como os valores gerados por reamostragem são independentes e não existe preocupação com a convergência, ocorre que em muitos casos, pode ser bastante difícil, ou mesmo impossível, encontrar uma densidade de valores que seja uma boa aproximação *a posteriori*.

Os métodos de Monte Carlos via cadeias de Markov (MCMC – *Monte Carlo Markov Chain*) são considerados alternativa para este problema (NOGUEIRA *et al.*, 2004). A ideia ainda é obter uma amostra da distribuição *a posteriori* e calcular estimativas amostrais de características desta distribuição. A diferença é que, neste caso, aplica-se técnicas de simulação iterativa, baseadas em cadeias de Markov, e assim os valores gerados não são independentes.

Segundo Norris (1997) uma cadeia de Markov é um processo estocástico  $\{X_0, X_1, \dots\}$  tal que a distribuição de probabilidade de  $X_t$ , dada as variáveis passadas, depende apenas de  $X_{t-1}$ , ou seja,  $p(X_t \in A | X_0, \dots, X_{t-1}) = p(X_t \in A | X_{t-1})$ . Desse modo, cada novo valor gerado pelo método MCMC depende do valor gerado anteriormente.

O algoritmo Metropolis-Hastings, desenvolvido inicialmente por Metropolis *et al.* (1953), e mais tarde, generalizado por Hastings (1970), é um métodos MCMV que possibilita a construção de uma cadeia de Markov, através da simulação de valores aleatórios de  $\theta$ , que convergem para a distribuição *a posteriori* de interesse.

A construção da cadeia de Markov via o algoritmo de Metropolis-Hastings é feita da seguinte maneira (EHLERS, 2011): Se a cadeia está no estado  $\theta$ , um novo valor  $\theta'$  é gerado a partir de uma distribuição proposta  $q(\cdot | \theta)$ , que depende do estado atual da cadeia  $\theta$ . A função  $q(\cdot)$  é conhecida como o núcleo de transição da cadeia de Markov. O valor candidato  $\theta'$  é aceito ou rejeitado a partir da análise da probabilidade de aceitação,

$$\alpha(\theta, \theta') = \min \left( 1, \frac{\pi(\theta')q(\theta|\theta')}{\pi(\theta)q(\theta'|\theta)} \right), \quad (2)$$

onde  $\pi$  é a distribuição de interesse.

Uma característica importante é que só precisa-se conhecer  $\pi$  parcialmente, isto é, a menos de uma constante já que neste caso a Equação (2) não se altera. Isto é fundamental em aplicações Bayesianas aonde não se conhece completamente *a posteriori*.

Em aplicações Bayesianas, é importante que a distribuição de interesse seja a própria *a posteriori*, isto é,  $\pi(\theta) = p(\theta|x)$ , assim, pelo teorema de Bayes, a probabilidade de aceitação assume a forma particular (EHLERS, 2011),

$$\begin{aligned} \alpha(\theta, \theta') &= \min \left( 1, \frac{p(\theta'|x)q(\theta|\theta')}{p(\theta|x)q(\theta'|\theta)} \right) = \min \left( 1, \frac{1/p(x)}{1/p(x)} \frac{p(x|\theta')p(\theta')}{p(x|\theta)p(\theta)} \frac{q(\theta|\theta')}{q(\theta'|\theta)} \right) \\ &= \min \left( 1, \frac{l(\theta';x)p(\theta')}{l(\theta;x)p(\theta)} \frac{q(\theta|\theta')}{q(\theta'|\theta)} \right), \end{aligned} \quad (3)$$

onde  $l(\theta; x)$  denota a função de verossimilhança de  $\theta$  e  $p(\theta)$  a distribuição *a priori* de  $\theta$ .

Em termos práticos, o algoritmo de Metropolis-Hastings pode ser especificado pelos seguintes passos (EHLERS, 2011):

1. Inicializar o contador de iterações  $i = 0$  e especifique um valor inicial  $\theta_i$ ;
2. Gerar um novo valor  $\theta'$  da distribuição  $q(\cdot | \theta_i)$ ;
3. Calcular a probabilidade de aceitação  $\alpha(\theta_i, \theta')$  e gerar  $u \sim U(0,1)$ ;
4. Se  $u \leq \alpha$  então aceitar o novo valor e fazer  $\theta_i = \theta'$ , caso contrário rejeitar e fazer  $\theta_{i+1} = \theta_i$ ;
5. Incrementar o contador de  $i$  para  $i + 1$  e voltar ao passo 2.

### 3. MÉTODO PROPOSTO

O método proposto neste artigo é uma adaptação dos trabalhos D'Angelo *et al.* (2011a), Souza *et al.* (2012) e D'Angelo *et al.* (2014) que têm como principal contribuição uma abordagem que permite a detecção de pontos de mudança em uma série temporal, sem a necessidade de conhecer previamente os modelos determinísticos ou probabilísticos que descrevam a coleção de dados.

O método é dividido em três passos: (1) clusterização dos dados da série temporal através de um mapa auto-organizável de Kohonen; (2) construção de uma nova série temporal por meio de uma fuzzificação da série temporal inicial; (3) aplicação de uma simulação Monte Carlo via algoritmo Metropolis-Hastings para a determinação do ponto de mudança. Estes três passos são ilustrados na Figura 2 e detalhados matematicamente em seguida.

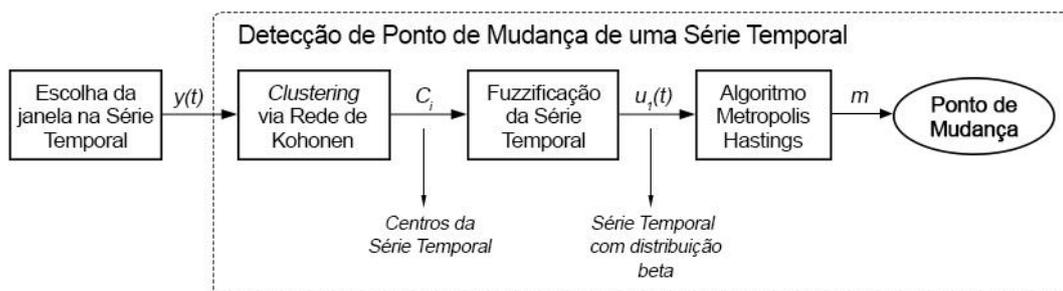


Figura 2 - Etapas da metodologia para a detecção de ponto de mudança de uma série temporal.

### Passo 1: Clusterização Via Rede de Kohonen.

A metodologia escolhida para a clusterização dos dados é baseada em um algoritmo de RNA auto-organizada de Kohonen. A escolha da clusterização via Rede de Kohonen é dada pelo fato de que este método permite um agrupamento adaptativo, isto é, que determina, além dos centros, uma quantidade adequada de grupos, eliminando grupos desnecessários. Este é um fator muito importante para o objetivo do presente trabalho, pois, possibilita a identificação se houve ou não a ocorrência de mudança na série temporal.

A rede de Kohonen é desenvolvida a partir do algoritmo descrito na Seção 2.1. Como neste estudo, tem-se interesse em apenas séries temporais de uma única dimensão, utiliza-se para esta rede somente entradas de uma única variável, que são as medidas geradas pelo instrumento de monitoramento de barragem. Como o objetivo é identificar apenas uma mudança na série temporal, a rede é inicializada com apenas dois neurônios, cujo os pesos iniciais são definidos por: valor mínimo da série temporal ( $w_1$ ) e metade da subtração entre o valor mínimo e o valor máximo da série temporal ( $w_2$ ). Esta escolha garante que o segundo neurônio somente tem alguma associação com os dados se, de fato, ocorreu alguma mudança de comportamento na série temporal, isto é o que, possibilita o método afirmar se houve ou não ocorrência de mudança.

Ainda no início do processo é definido um limite máximo de 1.000 iterações, uma taxa de aprendizagem  $\alpha = 0,1$  para a primeira etapa do método e raio de vizinhança igual a 1. Como apenas um único neurônio vencedor de cada iteração é ajustado, não é necessário a atualização do raio de vizinhança.

A segunda parte do algoritmo consiste em um treinamento não supervisionado e competitivo da rede neural (KOHONEN, 1990). Assim, para cada iteração ( $i$ ), os valores da série temporal são percorridos, calculando-se para cada valor, as distâncias euclidianas entre o valor e cada um dos neurônios. O neurônio que obtém a menor distância é considerado o vencedor e apenas o peso deste neurônio é ajustado através da equação descrita no passo 2.1.3 do algoritmo da Seção 2.1. Em seguida, a taxa de aprendizagem  $\alpha$  é atualizada de forma linear pela equação  $\alpha = 0,1 - (9 \times 10^{-5})i$ . Este processo é repetido até finalizar a quantidade escolhida de iterações.

Por fim, o algoritmo utiliza um processo de eliminação por critérios de baixo desempenho, assim, é definido um índice de desempenho que quantifica o número de associações que cada neurônio tem com as entradas. Se um dos neurônios não tem nenhuma associação, ou seja, o índice de desempenho é nulo, o algoritmo indica que a série temporal não teve mudança de comportamento. Caso contrário, os pesos dos dois neurônios são definidos como os centros dos *clusters* para serem utilizados na próxima etapa do método.

Assim sendo, esta primeira etapa da metodologia, dada pelo algoritmo de clusterização dos dados via rede do Kohonen, possibilita a detecção da existência ou não de um ponto de

mudança na série temporal. Caso seja confirmada a existência de uma mudança, as próximas etapas são desenvolvidas para indicar o momento em que ocorreu esta mudança.

Passo 2: Fuzzificação da Série Temporal.

Os métodos clássicos de agrupamentos separam os dados em categorias, entretanto, em muitos casos, alguns elementos não podem pertencer a uma categoria específica, pois pertencem a duas ou mais categorias simultaneamente. A utilização de conjuntos *fuzzy* como métodos de agrupamentos são boas alternativas de resolver tal problema, pois assim, um elemento pode pertencer a mais de uma categoria simultaneamente (PEDRYCZ, 1985).

Para o método aqui apresentado, utilizou-se um método de agrupamento *fuzzy* para gerar uma nova série temporal baseada nos centros de *clusters* calculados pela rede de Kohonen desenvolvida na etapa anterior.

Desta maneira, dada uma série temporal  $y(t)$  com  $n$  pontos, os centros de *clusters* encontrados anteriormente são os valores  $C_1$  e  $C_2$  que resolvem o seguinte problema de minimização

$$\min \sum_{i=1}^2 \sum_{t=1}^n \|y(t) - C_i\|^2. \tag{4}$$

Assim, a função definida por

$$\mu(t) = \left[ \sum_{j=1}^k \frac{\|y(t) - C_1\|^2}{\|y(t) - C_j\|^2} \right]^{-1}, \tag{5}$$

tem sua imagem contida no intervalo  $[0,1]$  e, desse modo, pode-se considerar  $\mu(t)$  como sendo um conjunto *fuzzy* que descreve o grau de pertinência do ponto  $y(t)$  em relação *cluster* de centro  $C_1$ .

O mais importante para este estudo, é o fato de que usando testes estatísticos (D'ANGELO *et al.*, 2011b), conclui-se que a função  $\mu(t)$  pode ser aproximada por uma função de distribuição beta com diferentes parâmetros de entrada, ou seja, uma distribuição  $beta(a, b)$  para  $t \leq m$  e uma distribuição  $beta(c, d)$  para  $t > m$ , ou seja, a distribuição de probabilidade das variáveis  $\mu_1(t)$  depende de cinco parâmetros  $(a, b, c, d, m)$  e tem aproximação dada por

$$f(\mu|a, b, c, d, m) \sim \prod_{i=1}^m \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} \mu(i)^{a-1} (1-\mu(i))^{b-1} \prod_{i=m+1}^n \frac{\Gamma(c+d)}{\Gamma(c)\Gamma(d)} \mu(i)^{c-1} (1-\mu(i))^{d-1}, \tag{6}$$

sendo  $\Gamma(x) = \int_0^\infty u^{x-1} e^{-u} du$  a função gama.

Assim sendo, esta etapa da metodologia proposta, através do conjunto *fuzzy* (Equação 5), pretende transformar um conjunto de dados de uma série temporal sem qualquer conhecimento *a priori*, em uma série temporal com informações estatísticas suficientes para a aplicação de métodos de inferência bayesiana, possibilitando estimar os parâmetros da distribuição beta

(Equação 6). Em especial, o parâmetro  $m$ , que é o instante em que ocorre a mudança de comportamento da série temporal  $y(t)$ .

Passo 3: Algoritmo Metropolis-Hastings

Uma vez que as etapas anteriores transformam a série original, com uma distribuição de probabilidade qualquer, em uma nova série temporal  $\mu(t)$  com uma função de distribuição de probabilidade beta, então, o novo modelo estatístico fixado é considerado em uma formulação bayesiana para estimar os parâmetros da distribuição beta que se aproxima da nova série temporal, e com isso, estima-se o parâmetro  $m$  (D'ANGELO *et al.*, 2011b). Nesta etapa, o algoritmo de Metropolis-Hastings (Seção 2.3) é utilizado para efetuar a simulação Monte Carlo via cadeia de Markov, com o fim de estimar os parâmetros.

Em termos práticos, o algoritmo Metropolis-Hastings, apresentado na Seção 2.3, é especificado sobre o fato de que nas etapas anteriores a série temporal transformada  $\mu(t)$  segue as seguintes distribuições:  $\mu(t) \sim \text{beta}(a, b)$  para  $t = 1, \dots, m$  e  $\mu(t) \sim \text{beta}(c, d)$  para  $t = m + 1, \dots, n$ . Assim, os parâmetros que devem ser estimados pelo algoritmo são  $a, b, c, d$  e o ponto de mudança  $m$ .

Como os valores  $a, b, c$  e  $d$  devem ser parâmetros de uma distribuição beta, então, devem ser números reais positivos, assim, utiliza-se como distribuição proposta  $q(\cdot)$  para gerar candidatos a estes parâmetros, a distribuição  $\text{Gama}(0,1, 0,1)$ . Já no caso do valor  $m$ , que deve pertencer ao conjunto discreto  $\{1, 2, \dots, n\}$ , a distribuição proposta  $q(\cdot)$  para gerar candidatos ao valor  $m$ , é dada pela distribuição Uniforme  $U\{1, 2, \dots, n\}$ . Deste modo, um vetor  $\theta' = (a', b', c', d', m')$  gerado pela distribuição proposta  $q(\cdot)$  tem  $a', b', c', d' \sim \text{Gama}(0,1, 0,1)$  e  $m' \sim U\{1, 2, \dots, n\}$ .

Para a distribuição de interesse  $\pi(\theta)$ , é adotada a distribuição *a posteriori* de  $\theta$ , determinada pela série temporal  $\mu(t)$ , isto é,  $p(\mu|\theta)$ . Assim, a função de verossimilhança  $l(\mu; \theta)$  é dada pela função  $f(\mu|a, b, c, d, m)$  da Equação 3, e as distribuições *a priori* de  $\theta = (a, b, c, d, m)$ , é a distribuição  $\text{Gama}(0,1, 0,1)$  para os parâmetros  $a, b, c$  e  $d$  e  $U\{1, 2, \dots, n\}$  para o parâmetro  $m$ . Logo, as probabilidades são calculadas por:

$$p(x) = \frac{0,1^{0,1} x^{0,1-1} e^{-0,1x}}{\Gamma(0,1)}, \tag{7}$$

para  $x = a, b, c$  ou  $d$  e

$$p(m) = \frac{1}{n}. \tag{8}$$

Desta forma, se a cadeia está no estado  $\theta_i = (a_i, b_i, c_i, d_i, m_i)$ , a probabilidade de aceitação (Equação 2) para cada parâmetro do novo valor  $\theta' = (a', b', c', d', m')$  gerado por  $q(\cdot)$ , é calculada por:

1. Parâmetro  $a$ :

$$\begin{aligned} \alpha(a_i, a') &= \min \left( 1, \frac{l(a', b_i, c_i, d_i, m_i; \mu) \cdot p(a') \cdot q(a_i|a')}{l(a_i, b_i, c_i, d_i, m_i; \mu) \cdot p(a_i) \cdot q(a'|a_i)} \right) \\ &= \min \left( 1, \frac{f(\mu|a', b_i, c_i, d_i, m_i) \cdot p(a') \cdot p(a') p(b_i) p(d_i) p(m_i)}{f(\mu|a_i, b_i, c_i, d_i, m_i) \cdot p(a_i) \cdot p(b_i) p(c_i) p(d_i) p(m_i)} \right) \end{aligned}$$

$$\begin{aligned}
 &= \min \left( 1, \frac{\prod_{j=1}^{m_i} \frac{\Gamma(a' + b_i)}{\Gamma(a')\Gamma(b_i)} \mu(j)^{a'-1} (1 - \mu(j))^{b_i-1}}{\prod_{j=1}^{m_i} \frac{\Gamma(a_i + b_i)}{\Gamma(a_i)\Gamma(b_i)} \mu(j)^{a_i-1} (1 - \mu(j))^{b_i-1}} \right. \\
 &\quad \left. \cdot \frac{\prod_{j=m_i+1}^n \frac{\Gamma(c_i + d_i)}{\Gamma(c_i)\Gamma(d_i)} \mu(j)^{c_i-1} (1 - \mu(j))^{d_i-1} \cdot \frac{p(a')^2}{p(a_i)^2}}{\prod_{j=m_i+1}^n \frac{\Gamma(c_i + d_i)}{\Gamma(c_i)\Gamma(d_i)} \mu(j)^{c_i-1} (1 - \mu(j))^{d_i-1}} \right) \\
 &= \min \left( 1, \frac{\prod_{j=1}^{m_i} \frac{\Gamma(a' + b_i)}{\Gamma(a')\Gamma(b_i)} \mu(j)^{a'-1}}{\prod_{j=1}^{m_i} \frac{\Gamma(a_i + b_i)}{\Gamma(a_i)\Gamma(b_i)} \mu(j)^{a_i-1}} \cdot \left( \frac{(0,1^{0,1} a'^{0,1-1} e^{-0,1 a'} \Gamma(0,1)^{-1})^2}{(0,1^{0,1} a_i^{0,1-1} e^{-0,1 a_i} \Gamma(0,1)^{-1})^2} \right) \right) \\
 &= \min \left( 1, \left( \left[ \frac{a_i}{a'} \right]^{0,9} e^{-0,1(a'-a_i)} \right)^2 \cdot \left[ \frac{\Gamma(a' + b_i)\Gamma(a_i)}{\Gamma(a_i + b_i)\Gamma(a')} \right]^{m_i} \cdot \prod_{j=1}^{m_i} \mu(j)^{a'-a_i} \right).
 \end{aligned}$$

Analogamente, pode-se definir as probabilidades de aceitação dos outros parâmetros.

2. Parâmetro  $b$ :

$$\alpha(b_i, b') = \min \left( 1, \left( \left[ \frac{b_i}{b'} \right]^{0,9} e^{-0,1(b'-b_i)} \right)^2 \cdot \left[ \frac{\Gamma(a_i + b')\Gamma(b_i)}{\Gamma(a_i + b_i)\Gamma(b')} \right]^{m_i} \cdot \prod_{j=1}^{m_i} (1 - \mu(j))^{b'-b_i} \right).$$

3. Parâmetro  $c$ :

$$\alpha(c_i, c') = \min \left( 1, \left( \left[ \frac{c_i}{c'} \right]^{0,9} e^{-0,1(c'-c_i)} \right)^2 \cdot \left[ \frac{\Gamma(c' + d_i)\Gamma(c_i)}{\Gamma(c_i + d_i)\Gamma(c')} \right]^{m_i} \cdot \prod_{j=m_i+1}^n \mu(j)^{c'-c_i} \right).$$

4. Parâmetro  $d$ :

$$\alpha(d_i, d') = \min \left( 1, \left( \left[ \frac{d_i}{d'} \right]^{0,9} e^{-0,1(d'-d_i)} \right)^2 \cdot \left[ \frac{\Gamma(c_i + d')\Gamma(d_i)}{\Gamma(c_i + d_i)\Gamma(d')} \right]^{m_i} \cdot \prod_{j=m_i+1}^n (1 - \mu(j))^{d'-d_i} \right).$$

5. Parâmetro  $m$  (lembrando-se que  $m \sim U\{1, 2, \dots, n\}$ ):

$$\begin{aligned}
 \alpha(m_i, m') &= \min \left( 1, \frac{l(a_i, b_i, c_i, d_i, m'; \mu) \cdot p(m') \cdot q(m_i | m')}{l(a_i, b_i, c_i, d_i, m_i; \mu) \cdot p(m_i) \cdot q(m' | m_i)} \right) \\
 &= \min \left( 1, \frac{f(\mu | a_i, b_i, c_i, d_i, m') \cdot p(m') \cdot p(a_i) p(b_i) p(d_i) p(m')}{f(\mu | a_i, b_i, c_i, d_i, m_i) \cdot p(m_i) \cdot p(b_i) p(c_i) p(d_i) p(m_i)} \right) \\
 &= \min \left( 1, \frac{f(\mu | a_i, b_i, c_i, d_i, m') \cdot (1/n)^2}{f(\mu | a_i, b_i, c_i, d_i, m_i) \cdot (1/n)^2} \right) \\
 &= \min \left( 1, \left[ \frac{\Gamma(a_i + b_i)}{\Gamma(a_i)\Gamma(b_i)} \right]^{m'-m_i} \left[ \frac{\Gamma(c_i + d_i)}{\Gamma(c_i)\Gamma(d_i)} \right]^{m_i-m'} \right)
 \end{aligned}$$

$$\frac{\prod_{j=1}^{m'} \mu(j)^{a_i-1} (1 - \mu(j))^{b_i-1}}{\prod_{j=1}^{m_i} \mu(j)^{a_i-1} (1 - \mu(j))^{b_i-1}} \cdot \frac{\prod_{j=m'+1}^n \mu(j)^{c_i-1} (1 - \mu(j))^{d_i-1}}{\prod_{j=m_{i+1}}^n \mu(j)^{c_i-1} (1 - \mu(j))^{d_i-1}}$$

Após o cálculo das probabilidades de aceitação de cada parâmetro, um valor  $u$  é sorteado a partir da distribuição  $U(0,1)$ , e cada parâmetro do novo vetor  $\theta_{i+1} = (a_{i+1}, b_{i+1}, c_{i+1}, d_{i+1}, m_{i+1})$  é construído através da regra: Se  $u < \alpha(x_i, x')$ , então aceitar o novo valor e fazer  $x_{i+1} = x'$ , caso contrário, rejeitar e fazer  $x_{i+1} = x_i$ , com  $x = a, b, c, d$  e  $m$ .

Em seguida, o valor da iteração  $i$  é ajustado para  $i + 1$ , um novo vetor  $\theta'$  é gerado por  $q(\cdot)$  e o processo é repetido. Para este trabalho, foram escolhidas 1.000 iterações, que ao final geram uma cadeia de Markov com 1.000 estimativas para o vetor  $\theta = (a, b, c, d, m)$ .

Como o objetivo desta etapa é determinar a melhor estimativa do parâmetro  $m$ , o método é finalizado com a escolha do valor que ocorre com maior frequência entre as 1.000 estimativas para  $m$ , pois, este é valor, entre os estimados, que tem a maior probabilidade de ser o parâmetro  $m$  da distribuição beta que aproxima-se das distribuição dos dados da série temporal  $\mu(t)$ , e consequentemente, é o instante de mudança de comportamento da série temporal  $y(t)$ .

#### 4. EXPERIMENTOS NUMÉRICOS

Itaipu é considerado um dos maiores projetos hidrelétricos do mundo, é resultado dos esforços e empenho de dois países vizinhos, Brasil e Paraguai. Encontra-se localizado no rio Paraná, onde os dois países fazem fronteira, 14 km a montante da ponte internacional que liga a cidade de Foz do Iguaçu, no Brasil, à Ciudad del Este, no Paraguai (ITAIPU: USINA HIDRELÁTRICA, 2009).

A Barragem de Itaipu é uma estrutura (concreto, enrocamento e terra) que serve para represar a água e obter o desnível de 120m (queda brutal nominal) que permite a operação das turbinas. Na parte superior da barragem principal, estão situadas as tomadas de água, estruturas com comportas que permitem que a água, passando por elas e pelos condutos forçados, alcance a caixa espiral, onde faz a turbina girar. A barragem da Itaipu tem 7.919 metros de extensão e altura máxima de 196 metros (ITAIPU, 2008).

Devido ao grande porte de sua barragem, a Usina Hidrelétrica de Itaipu tem mantido desde seu projeto, constante atenção sobre a segurança de sua barragem. Itaipu está isenta das obrigações da lei 12.334, devido a sua binacionalidade, porém foi uma das apoiadoras dessa lei, e adota procedimentos internacionalmente aceitos que a tornam uma das maiores referências mundiais em segurança de barragem (NEUMANN JR *et al.*, 2011).

Atualmente, a barragem de Itaipu possui um rigoroso sistema de monitoramento constituído por cerca de 2.792 instrumentos instalados, sendo que 10% destes receberam um sistema de aquisição automática de dados, que tem o objetivo de supervisionar o comportamento estrutural da usina através de medições referentes a tensões, deformações, deslocamentos, pressões, infiltrações, níveis do rio a jusante e a montante, temperatura e pluviometria. Esses instrumentos possibilitam a aquisição das leituras com uma frequência parametrizável de 5 a 30 minutos, esses valores são processados, armazenados e transmitidos para uma estação central, localizada no setor responsável pelo tratamento dos dados, que envolve análises, comparações e acionamento de alarmes (ITAIPU, 2008).

Dentre os fenômenos monitorados pela Itaipu, os tremores de terras, gerados por sismos de grande ou pequena magnitude merecem atenção, pois, alguns abalos sísmicos, mesmo localizados em pontos distantes da barragem, foram registrados pela rede sismográfica de Itaipu e acusaram mudanças temporárias no comportamento de alguns instrumentos automatizados.

O monitoramento sísmico do reservatório de Itaipu iniciou-se em 1978, quatro anos antes do início do enchimento do lago. Inicialmente, com uma única estação analógica, com gravação local, enfumaçado e, posteriormente, com uma rede telemétrica de até oito estações, com os dados transmitidos para uma central de recepção e registro onde eram também gravados em papel enfumaçado. Atualmente, funciona uma rede de seis estações, três no Paraguai e três no Brasil e uma estação acelerográfica. Os dados das sete estações são digitalizados a uma taxa de 100 amostras por segundo e gravados paralelamente em dois sistemas de aquisição (BARROS *et al.*, 2010).

A sismicidade do Brasil é bem menor do que as observada nos países andinos vizinhos. Entretanto, essas duas sismicidade têm gênese e natureza bem diferente: uma é interplaca e a outra é intraplaca. A sismicidade interplaca andina, resulta da interação entre a placa de Nazca com a placa Sul-Americana, onde há uma maior concentração de esforços e, portanto, uma sismicidade mais frequente e intensa. Dada a extensão desses limites, quando ocorrem deslizamentos de uma extensa área no contato dessas duas placas é gerado um grande terremoto. Já a sismicidade intraplaca, resulta principalmente das forças de limites de placas que se transmitem para o seu interior e, eventualmente, produzem rupturas ao longo de zonas de fraquezas, conhecidas como falhas geológicas (BARROS E CARVALHO, 1995).

Entre 2006 e 2010, a rede sismográfica de Itaipu registrou sete telessismos (eventos localizados a uma distância epicentral acima de 1.500 km da estação de registro) importantes, dos quais dois com epicentro no Brasil; um em Carabaibas/Itacarambi, localizado no extremo norte de Minas Gerais, em 09/12/2007, com magnitude 4,9mb. O segundo ocorreu em Cruzeiro do Sul - AC (24/05/2010), com magnitude 6,5mb. Outros telessismos importantes ocorreram na Argentina (13/11/2006) com magnitude 6,0mb, no Pisco-Peru (15/08/2007) com magnitude 8,0mb, no Equador (16/11/2007) com magnitude 6,8mb, no Haiti (12/01/2010) com magnitude 7,0mb e em Maule-Chile (27/02/2010) com magnitude de 8,8mb (BARROS *et al.*, 2010).

Segundo Barros *et al.* (2010) os terremotos de Pisco-Peru e Maule-Chile são particularmente importantes. Além de ambos serem detectados pela rede sismográfica, eles também foram acusados por alguns instrumentos do sistema de auscultação de Itaipu, visto que foram terremotos de maior magnitude, acima de 8,0mb (Escala Richter). Na ocasião, verificou-se que alguns instrumentos do sistema de monitoramento das barragens de Itaipu registraram mudanças em seu comportamento padrão que podem estar relacionadas com estes eventos.

A maior parte dos instrumentos que mostrou este efeito foram os automatizados, que pode ser explicado pelo fato de realizarem mais medições em um intervalo de tempo. Os instrumentos automatizados que mostraram esta oscilação foram pêndulos diretos e invertidos, piezômetros e medidores de vazão. Alguns instrumentos com leituras manuais, como extensômetros e bases de alongamento também registraram alterações. A mudança de comportamento dos instrumentos foi momentânea, voltando ao seu comportamento histórico alguns dias após o evento.

Ressalta-se que os valores lidos durante estes eventos não ultrapassaram valores históricos, sendo que, na maioria das vezes, quando se avaliam gráficos com escala anual as oscilações são imperceptíveis.

Para mostrar a eficiência da abordagem neuro-*fuzzy*-bayesiana na detecção automática de pontos de mudança em séries temporais aplicada em problemas reais, foram escolhidas para este trabalho, três séries temporais geradas pelos piezômetros, nomeados PS-D-21, PS-D-60 e PS-F-31, responsáveis pelo monitoramento do contato entre o maciço rochoso e a barragem de concreto da Usina Hidrelétrica de Itaipu.

Estes piezômetros são instrumentos automatizados que registraram, através de análise visual das suas séries temporais, pequenas mudanças de comportamento após a ocorrência do terremoto de Maule-Chile (8,8mb). O conjunto de dados de cada um dos instrumentos escolhidos, contém 48 pontos referentes às medidas realizadas a cada trinta minutos no dia 27/02/2010 quando ocorreu o sismo (Figuras 3, 4 e 5).

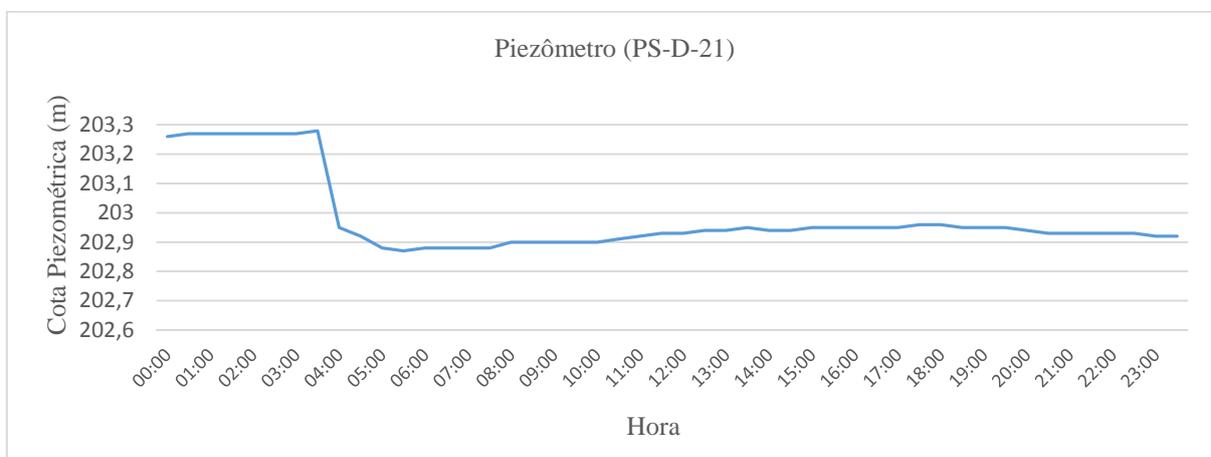


Figura 3. Leituras automáticas do piezômetro PS-D-21 (contato concreto-rocha) - Sismo Chile(27/02/2010).

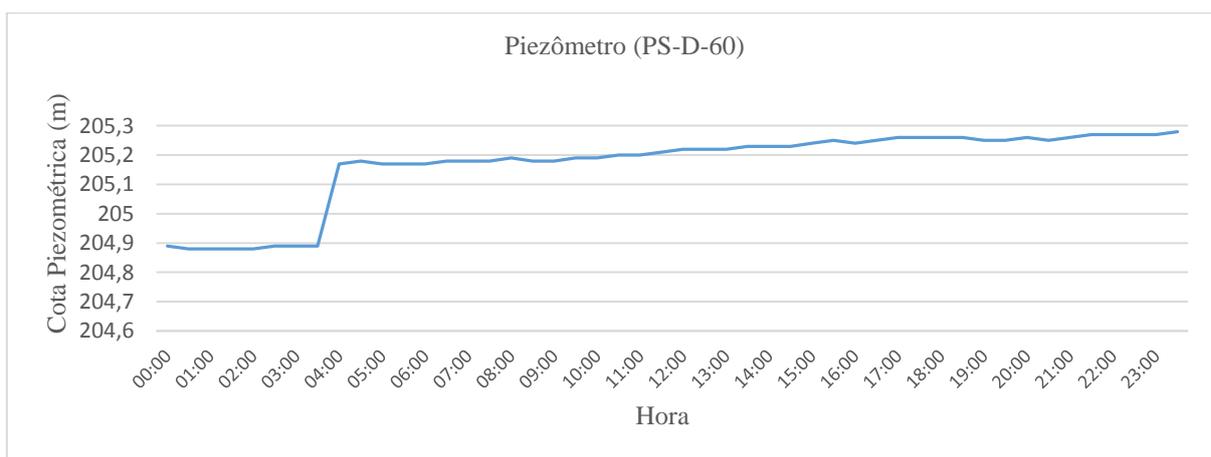


Figura 4. Leituras automáticas do piezômetro PS-D-60 (contato concreto-rocha) - Sismo Chile (27/02/2010).

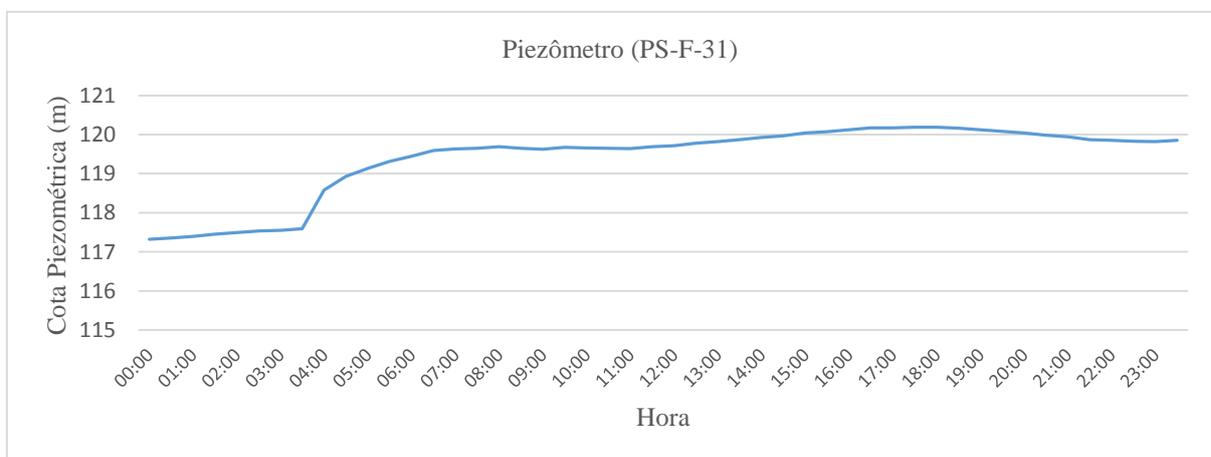


Figura 5. Leituras automáticas do piezômetro PS-F-31 (contato concreto-rocha) - Sismo Chile (27/02/2010).

O terremoto do Chile de 2010, ocorreu às 03:34:08, hora local, mesmo fuso horário de região onde se localiza Itaipu (UTC-03). Nos gráficos apresentados é possível identificar que as mudanças de comportamento das séries temporais ocorreram também por volta deste mesmo horário (entre as medidas 03:30 e 04:00), possibilitando relacionar as variações nas séries temporais com a ocorrência do sismo.

Como foi descrito anteriormente, o objetivo deste trabalho, não visa à detecção da ocorrência do evento sísmico, mas sim o de identificar de forma automática, quais instrumentos de monitoramento sofreram mudanças de comportamento após a ocorrência do fenômeno já detectado. Para isso, foi implementado um algoritmo no *software* MATLAB R2011 com base na metodologia descrita anteriormente (Seção 3) e aplicado nas três séries temporais (Figuras 3, 4 e 5). O algoritmo foi programado para seguir as três etapas da metodologia e gerar resultados numéricos e gráficos para análises.

### 5. RESULTADOS

A primeira fase do algoritmo consiste na metodologia de clusterização via rede de Kohonen (Passo1 da Seção 3) aplicado nas séries temporais de cada piezômetros escolhido. Os resultados da clusterização estão apresentados na Figura 6, onde, se observar que para cada uma das três séries temporais, foram encontrados dois centros de *clusters*,  $C_1$  e  $C_2$ , o que confirma a existência de mudança de comportamento nas séries temporais e possibilita a execução da próxima etapa da metodologia.

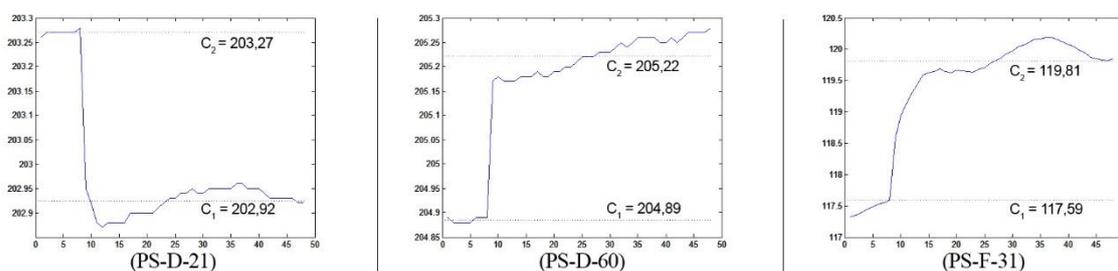


Figura 6 - Resultado da clusterização via rede de Kohonen das séries temporais.

Na segunda fase do algoritmo, é feita a fuzzificação (Passo 2 da Seção 4) de cada uma das três séries temporais, definindo novas séries temporais. A Figura 7 apresenta as séries temporais transformadas, denotadas por  $\mu(t)$ , que de acordo com a teoria exposta neste artigo, têm distribuições que podem ser descritas por uma distribuições beta com parâmetros  $(a, b, c, d, m)$ . Assim, a próxima etapa do método é responsável por estimar o parâmetro  $m$  através de uma simulação Monte Carlo.

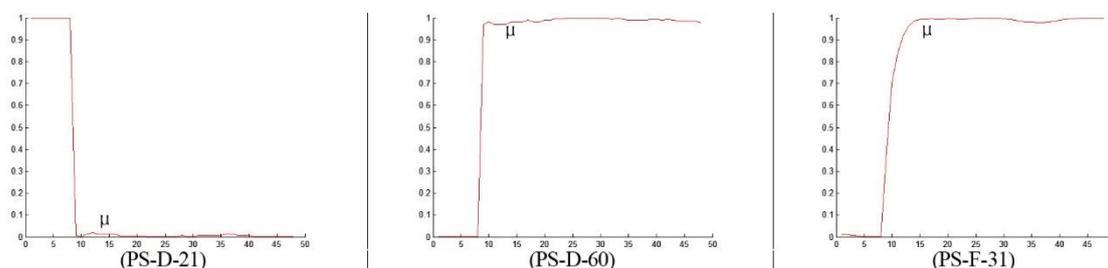


Figura 7: Séries temporais obtidas através da fuzzificação da série temporal original.

Em seguida, o algoritmo Metropolis-Hastings descrito no Passo 3 da Seção 4 é aplicado em cada uma das séries temporais transformadas pela etapa anterior, construindo cadeias de Markov com 1.000 estimativas para cada parâmetro  $(a, b, c, d, m)$  das possíveis distribuições

beta. Como o objetivo final é obter apenas o parâmetro  $m$  de cada série temporal, a Figura 8, mostra as seqüências dos 1.000 valores estimados para  $m$  de cada uma das séries temporais avaliadas.

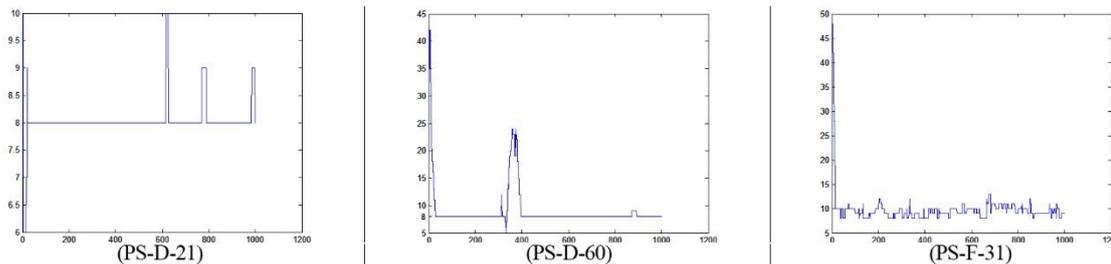


Figura 8: Estimativas para o parâmetro  $m$  geradas pelo algoritmo Metropolis-Hastings.

O algoritmo Metropolis-Hastings constrói uma cadeia de Markov aceitando como um novo valor apenas os valores que têm maior probabilidade de satisfazer a distribuição *a posteriori* dos dados. Então, o termo que ocorre com maior frequência na seqüência de valores simulados é considerado a melhor estimativa para ser o parâmetro  $m$  desejado. De acordo com os histogramas apresentados na Figura 9, tem-se que para a série PS-D-21, o valor  $m = 8$  ocorreu com maior frequência, isto é, em torno de 910 vezes entre os 1.000 valores simulados, deste modo,  $m = 8$  é considerado o ponto de mudança da série temporal gerada pelo piezômetro PS-D-21. Analogamente, tem-se que o valor  $m = 8$  é considerado a melhor estimativa para o ponto de mudança da série temporal gerada pelo piezômetro PS-D-60, assim como  $m = 9$  é aceito pelo método como sendo o ponto de mudança da série temporal do piezômetro PS-F-31.

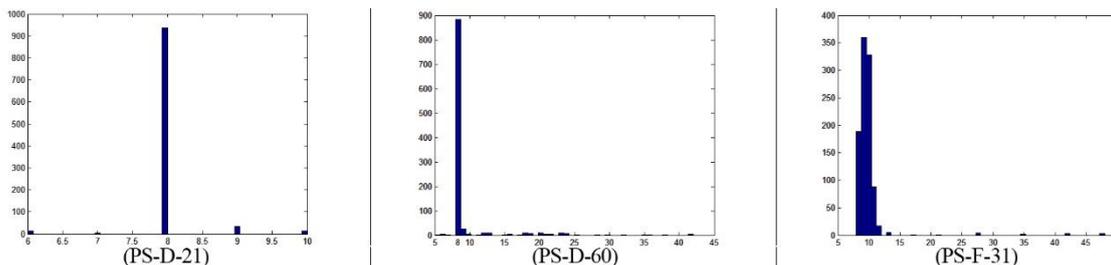


Figura 9: Histograma com as frequências dos valores de  $m$  simulados pelo algoritmo Metropolis-Hastings.

Por último, a Figura 10 apresenta os gráficos das séries temporais originais plotadas com seus respectivos pontos de mudança detectados pelo método proposto.

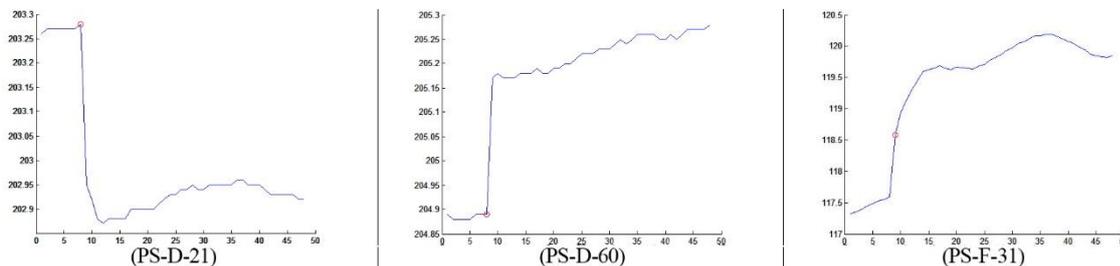


Figura 10: Séries temporais com seus respectivos pontos de mudança detectados pelo método proposto.

Assim, tem-se que a metodologia proposta detectou que as séries temporais PS-D-21 e PS-D-60 sofreram mudança de comportamento após o instante 8 (oito). Como cada entrada das séries temporais representam as medidas realizadas a partir das 00:00 do dia 27/02/2010 e aferidas a cada 30 minutos, o ponto 8 (oito) detectado é relativo a medida realizada às 03:30 desse dia. Isto implica, que a mudança identificada ocorreu entre as medidas registradas às 03:30 e 04:00, assim, o fato do sismo ter ocorrido às 03:34:08, induz relacionar a mudança detectada com o evento sísmico, o que corrobora os resultados obtidos pelo método.

Para a série temporal PS-F-31, o algoritmo detectou a mudança de comportamento após o instante 9 (nove), ou 04 horas, diferente dos outros dois casos analisados. Esta pequena diferença pode ser explicada devido ao fato de que a mudança ocorrida nesta série temporal não é de forma tão abrupta, como acontece nas outras. A mudança ocorre de forma incipiente, ou seja, suas variações são mais lentas em relação ao tempo. Confirmando uma das vantagens listadas da metodologia proposta, que refere-se ao potencial de detecção de mudanças incipientes, já que em outros métodos, a detecção deste ponto não seria possível.

## 6. CONCLUSÕES

Neste artigo, é proposto um método de detecção de mudança de comportamentos em séries temporais geradas por instrumentos de monitoramento usados no gerenciamento da segurança de barragens. O método associa conceitos de redes neurais artificiais, teoria de conjuntos *fuzzy* e inferência bayesiana, e tem como principal fator, a identificação de pontos de mudança em séries temporais, sem a necessidade de conhecimento *a priori* do conjunto de dados, além de possibilitar a detecção de mudanças que variam mais lentamente em relação ao tempo.

A eficiência do método foi testada através da aplicação em séries temporais reais, utilizadas no monitoramento da barragem de Itaipu, nas quais, foram detectadas, através de análises manuais, pequenas mudanças de comportamento após a ocorrência de um sismo. Os resultados obtidos pelo método foram coerentes com as análises feitas manualmente, onde todas as mudanças ocorridas foram detectadas automaticamente, e o valor estimado para o instante de ocorrência foi próximo ao momento em que foi registrada a ocorrência do evento sísmico, possível responsável pelas mudanças detectadas.

A importância da metodologia se justifica pelo fato de que, em grandes barragens, como a de Itaipu, em que cada evento sísmico, a empresa necessita revisar manualmente a mudança de comportamento em um número muito grande de instrumentos, a utilização desta metodologia é de enorme interesse, pois aceleraria as decisões a serem tomadas, melhorando o gerenciamento da segurança de sua barragem.

Portanto, a aplicação do método proposto em dados reais envolvidos no monitoramento da segurança da barragem de Itaipu, confirma a importância de uma ferramenta para avaliar de forma automática as mudanças de comportamento nas medidas realizadas por instrumentos de monitoramento e garante a eficiência do método, que além de detectar todas as mudanças previstas, também determina uma estimativa plausível para o momento de ocorrência da mudança, possibilitando relacionar a mudança de comportamento com sua possível causa.

## AGRADECIMENTOS

Os autores agradecem o apoio financeiro da Fundação Araucária e o suporte técnico e científico do PPGMNE-UFPR (Programa de Pós-Graduação em Métodos Numéricos em Engenharia da Universidade Federal do Paraná), CEASB (Centro Avançados em Segurança de Barragens – [www.pti.org.br/ceasb](http://www.pti.org.br/ceasb)) e Itaipu Binacional.

## REFERÊNCIAS

**ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS.** *Ações e Seguranças nas Estruturas (NBR 8681)*. 2003.

**BARROS, L. C. DE; BASSANEZI, R. C.** *Tópicos de Lógica Fuzzy e Biomatemática*. 2<sup>a</sup>. ed. Campinas - SP: Unicamp/IMECC, 2010.

**BARROS, L. V.; CARVALHO, J. M.** *Relatório de Viagem: Implantação do Sistema Digital de Registro e Análise de Dados Sísmicos de Itaipu Binacional*, p.14, 1995.

**BARROS, L. V.; PATIAS, J.; CAIXETA, D. F.** *Effects of Large Andean Earthquakes in the Itaipu Binational Dam. Foz do Iguaçu, Brasil: American Geophysical Union*, 2010.

**BARRY, D.; HARTIGAN, J. A.** *A Bayesian Analysis for Chance Point Problems. Journal of the American Statistical Association*, v. 88(421), p. 309–319, 1993.

**BOX, G. E. P.; TIAO, G. C.** *Bayesian Inference in Statistical Analysis*. New York: J. Wiley, 1992.

**BRASIL.** *Lei nº 12.334, de 20 de setembro 2010.*

**BRASIL.** *Resolução nº 144 de 10 de julho de 2012.*

**CHUNG, L. F.; HU, T. C.; LUK, R.** *Pattern Discovery from Stock Time Series Using Self-Organizing Maps. Anais... The 7th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2001) Workshop on Temporal Data Mining*. p.27–37, San Francisco, Califórnia, 2001.

**D'ANGELO, M. F. S. V.; PALHARES, R. M.; COSME, L. B.; et al.** *Fault detection in dynamic systems by a Fuzzy/Bayesian network formulation. Applied Soft Computing Journal*, v. 21, p. 647–653, 2014.

**D'ANGELO, M. F. S. V.; PALHARES, R. M.; TAKAHASHI, R. H. C.; et al.** *Incipient fault detection in induction machine stator-winding using a fuzzy-Bayesian change point detection approach. Applied Soft Computing*, v. 11, p. 179–192, 2011.

**D'ANGELO, M. F. S. V.; PALHARES, R. M.; TAKAHASHI, R. H. C.; LOSCHI, R. H.** *Fuzzy/Bayesian change point detection approach to incipient fault detection. IET Control Theory and Applications*, v. 5, p. 539, 2011.

**DUBOIS, D.; PRADE, H.** *Fuzzy Sets and Systems: Theory and Applications*. New York: Academic Press, 1980.

**EHLERS, R.** *Introdução à Inferência Bayesiana. Notas de Aula, São Paulo - SP: USP, 2011. Disponível em: <<http://www.icmc.usp.br/~ehlers/bayes/bayes.pdf>>. Acesso em: 05 de nov. 2015.*

**FAUSETT, L.** *Fundamentals of Neural Network - Architectures, Algorithms and Applications*. New Jersey: Prentice Hall, 1994.

**HASTINGS, K. W.** *Monte Carlo Sampling Methods Using Markov Chains and their Applications. Biometrika*, v. 57, p. 97–109, 1970.

**HAYKIN, S.** *Redes Neurais: Princípios e Práticas. Tradução: Paulo Martins Engel. Porto Alegre: Bookman, 2001.*

**HINKEY, D. V.** *Inference About the Change From Cumulative Sum Test. Biometria*, v. 26, p. 279–284, 1971.

**ICOLD.** *Critérios de Projeto Civil de Usinas Hidrelétricas. Centrais Elétricas Brasileiras S.A. ELETROBRÁS, p. 279, 2003.*

**ITAIPU.** *Usina Hidrelétrica de Itaipu: Aspectos Técnicos das Estruturas. Foz do Iguaçu - PR, 2008.*

**ITAIPU: USINA HIDRELÉTRICA.** *Projeto: Aspectos de Engenharia. Foz do Iguaçu - PR, 2009.*

**JAMES, B. R.** *Probabilidade: Um Curso em Nível Intermediário. Rio de Janeiro: IMPA - Coleção Projeto Euclides, 2011.*

**KASKI, S.** *Data Exploration Using Self-Organizing Maps. Tese de Doutorado, Escola Politécnica Escandinávia, Finlândia, 1997.*

**KOHONEN, T.** *Self-Organized Formation of Topologically correct feature maps. Biological Cybernetics, v. 43, p. 59-69, 1982.*

**KOHONEN, T.** *The Self-Organizing Map. Proceedings of the IEEE, v. 78, n. 9, p. 1464-1480, 1990.*

**LOSCHI, R. H.; CRUZ, F. R. B.** *Extension to the Product Partition Model: Computing the Probability of a Change. Computational Statistics and Data Analysis, v. 42(2), p. 255-268, 2005.*

**METROPOLIS, N.; ROSENBLUTH, A. W.; ROSENBLUTH, M. N.; TELLER, H. A.; E. TELLER.** *Equations of State Calculations by Fast Computing Machines. Journal of Chemical Physics, v. 21, p. 1087-1092, 1953.*

**NEUMANN JR, C.; OSAKO, C.; PATIAS, J.; PORCHETTO, C.** *Reflexos da Lei de Segurança de Barragens na Itaipu Binacional. Rio de Janeiro - RJ: XXVIII Seminário Nacional de Grandes Barragens, p. 1-11, 2011.*

**NOGUEIRA, D. A.; SÁFADI, T.; FERREIRA, D. F.** *Avaliação de Critérios de Convergência para o Método de Monte Carlo via Cadeias de Markov. Revista Brasileira de Estatística, v. 65, p. 59-88, 2004.*

**NORRIS, J. R.** *Markov Chains. Cambridge: University Press, 1997.*

**PAULINO, C. D.; TURKMAN, A. A.; MURTEIRA, B.** *Estatística Bayesiana. Lisboa: Fundação Calouste Gulbenkian, 2003.*

**PEDRYCZ, W.** *Fuzzy Clustering with Partial Supervision. Pattern Recognition Letters, v. 3 (1), p. 13-20, 1985.*

**SILVEIRA, J. F. A.** *Instrumentação e Comportamento de Fundações de Barragens de Concreto. São Paulo - SP: Oficina de Textos, 2003.*

**SOUZA, R.; PALHARES, R. M.; D'ANGELO, M. F. S. V.; CAMINHAS, W.** *Atualização de Distribuições de Probabilidade e Taxas de Confiabilidade Utilizando Técnicas de Detecção de Falhas. Anais... XIX Congresso Brasileiro de Automática, CBA. p.3164-3169, Campina Grande, 2012.*

**ZADEH, L. A.** *Fuzzy Sets. Information and Control*, v. 8, p. 338-353, 1965.

**ZIMMERMANN, H. J.** *Fuzzy set Theory. Wiley Interdisciplinary Reviews: Computational Statistics*, v. 2, p. 317-332, 2010.