



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE CIÊNCIAS E TECNOLOGIA AGROALIMENTAR
UNIDADE ACADÊMICA DE CIÊNCIAS E TECNOLOGIA AMBIENTAL
CURSO DE ENGENHARIA AMBIENTAL**

LUCAS NUNES BRASILIANO

**REGRAS OPERACIONAIS PARA RESERVATÓRIOS BASEADAS EM
OTIMIZAÇÃO ESTOCÁSTICA IMPLÍCITA E REDES NEURAIS DE
FUNÇÃO DE BASE RADIAL**

POMBAL-PB

2014

LUCAS NUNES BRASILIANO

**REGRAS OPERACIONAIS PARA RESERVATÓRIOS BASEADAS EM
OTIMIZAÇÃO ESTOCÁSTICA IMPLÍCITA E REDES NEURAIIS DE
FUNÇÃO DE BASE RADIAL**

Trabalho de Conclusão de Curso apresentado à
Coordenação do Curso de Engenharia Ambiental
da UACTA/CCTA/UFCG como requisito parcial
para a obtenção do título de Bacharel em
Engenharia Ambiental.

Orientador: Prof. Dr. Camilo Allyson Simões de
Farias

POMBAL-PB

2014

LUCAS NUNES BRASILIANO

**REGRAS OPERACIONAIS PARA RESERVATÓRIOS BASEADAS EM
OTIMIZAÇÃO ESTOCÁSTICA IMPLÍCITA E REDES NEURAIS DE
FUNÇÃO DE BASE RADIAL**

Trabalho de Conclusão de Curso apresentado à
Coordenação do Curso de Engenharia Ambiental
da UACTA/CCTA/UFCG como requisito parcial
para a obtenção do título de Bacharel em
Engenharia Ambiental.

Aprovado em 26 de Agosto de 2014.

BANCA EXAMINADORA

Prof. Dr. Camilo Allyson Simões de Farias
(CCTA/UFCG - Orientador)

Prof.^a Dr.^a Érica Cristine Medeiros Nobre Machado
(CCTA/UFCG - Examinador Interno)

Prof.^a Msc.^a Cristiane Queiroz Reis
(CCJS/UFCG - Examinador Externo)

**POMBAL-PB
2014**

*Dedico este trabalho a toda a minha família,
em especial aos meus pais Luiz e Vanda por
possibilitarem minha formação.*

AGRADECIMENTOS

Agradeço em primeiro lugar a Deus, por estar sempre me iluminando e guiando meus passos pelo melhor caminho a seguir.

Aos meus pais Luiz Coelho Brasileiro e Vanda Nunes Brasileiro, aos meus irmãos Luan Nunes Brasileiro e Lourran Nunes Brasileiro, pelo apoio e incentivo para a conclusão desse curso.

Ao meu orientador, Prof. Dr. Camilo Allyson Simões de Farias, pela orientação e dedicação para que o trabalho rendesse os melhores resultados possíveis.

Aos professores da Unidade Acadêmica de Ciências e Tecnologia Ambiental pelo conhecimento transmitido ao longo do curso.

Aos meus amigos e colegas de turma com quem convivi intensamente, tornando-se a minha outra família em Pombal, e com quem dividi bons e maus momentos ao longo do curso.

Aos meus amigos da Equipe do Metal pelo convívio, amizade, ajuda e parceria durante todos esses anos.

A todos (as), muito obrigado!

LISTA DE FIGURAS

Figura 1 - Função de Base Radial do tipo Gaussiana	17
Figura 2 - Influência do parâmetro σ^2 na função gaussiana	18
Figura 3 - Localização do Sistema Coremas – Mãe d'Água na bacia hidrográfica do Rio Piancó	19
Figura 4 - Localização dos reservatórios Coremas – Mãe d'Água na bacia hidrográfica do Rio Piancó	20
Figura 5 - Foto de satélite do Sistema Coremas – Mãe d'Água	21
Figura 6 - Política de Operação Linear Padrão	22
Figura 7 - Fluxograma representativo do Modelo OEI – RBF	23
Figura 8 - Fluxograma representativo dos modelos utilizados na pesquisa	23
Figura 9 - Comparação das propriedades estatísticas (média e desvio padrão) entre vazões sintéticas e históricas	25
Figura 10 - Configuração típica da RBF	27
Figura 11 - Volumes do reservatório para operação com todos os modelos	30
Figura 12 - Alocações de água para operação do reservatório com todos os modelos	31

LISTA DE TABELAS

Tabela 1 - Algumas Funções de Base Radial comumente utilizadas.....	17
Tabela 2 - Formas de uso da água para o Sistema Coremas – Mãe d'Água.....	21
Tabela 3 - Valores de correlações para os modelos RBF	29
Tabela 4 - Índice de vulnerabilidade para 10 novas simulações de 20 anos considerando todos os modelos.....	30

SUMÁRIO

1	INTRODUÇÃO	10
2	OBJETIVOS	12
2.1	Geral.....	12
2.2	Específicos	12
3	REVISÃO BIBLIOGRÁFICA	13
3.1	Modelos de Otimização	13
3.1.1	Programação Linear.....	13
3.1.2	Programação Dinâmica.....	14
3.1.3	Programação Não-linear	14
3.2	Outras Técnicas de Otimização.....	14
3.2.1	Modelos de Otimização Determinísticos e Estocásticos	15
3.3	Redes Neurais Artificiais	16
3.3.1	Redes de Função de Base Radial.....	16
4	MATERIAIS E MÉTODOS	19
4.1	Área de Estudo.....	19
4.2	SLOP	22
4.3	Modelo OEI-RBF	23
4.3.1	Geração Estocástica de Vazões	24
4.3.2	Modelo de Otimização Determinístico.....	25
4.3.3	Regras OEI-RBF	27
5	APLICAÇÃO E RESULTADOS	28
5.1	Regras OEI-RBF	28
6	CONSIDERAÇÕES FINAIS	32
	REFERÊNCIAS BIBLIOGRÁFICAS	33

RESUMO

No presente trabalho apresenta-se regras mensais de operação baseadas em Otimização Estocástica Implícita (OEI) e Redes Neurais de Função de Base Radial (RBF) para um sistema hídrico Coremas - Mãe d'Água, localizado no semiárido Paraibano. Foi utilizada a técnica de OEI, que consiste em otimizar a operação do sistema usando um conjunto de possíveis cenários sintéticos de vazões como entrada e, em seguida, na utilização dos dados ótimos gerados para construção de regras operacionais. Os cenários sintéticos de vazões foram obtidos por meio do Método dos Fragmentos. Nesse estudo, a RBF relacionou o volume do reservatório e a vazão afluente com coeficientes de alocação para cada mês do ano. As regras operacionais mensais obtidas com o modelo OEI-RBF foram aplicadas para operação do sistema hídrico e um critério de vulnerabilidade foi utilizado para análise dos resultados. Observando os índices de vulnerabilidade, pode-se concluir que o modelo OEI-RBF foi superior as regras de operação padrão.

Palavras-Chave: Método dos Fragmentos, semiárido, inteligência artificial, otimização estocástica.

ABSTRACT

In this work, we present monthly operating rules based on Implicit Stochastic Optimization (OEI) and Radial Basis Function Neural Networks (RBF) for Coremas – Mãe D'Água reservoirs, which are located in a semiarid land of Paraíba State, Brazil. The OEI technique consists of optimizing the operation of the system considering a set of possible inflow scenarios, and then using the optimal data for constructing reservoir operating rules. The synthetic inflow scenarios were obtained by the Method of Fragments. In this study, the RBF was used to relate reservoir initial storage and current in flow with allocation coefficients for each month of the year. The monthly operating rules obtained with the OEI-RBF model were applied to the operation of the water system and a criterion of vulnerability was used in order to analyze the results. According to the vulnerability results, it can be concluded that the EIO-RBF model was superior to standard rules of operation.

Key-words: Method of Fragments, semiarid, artificial intelligence, stochastic optimization.

1 INTRODUÇÃO

A água é um recurso natural e vital para a manutenção da vida no planeta Terra, sendo a sua disponibilidade um indicador de desenvolvimento social e econômico. Existem várias formas de uso da água e dentre elas pode-se citar a produção de alimentos, geração de energia e abastecimento humano. Para que ocorra o desenvolvimento é necessário garantir qualidade e quantidade de água, porém isso não é fácil, principalmente quando leva-se em conta a má distribuição de água na superfície do planeta e a pouca quantidade de água doce.

Outro agravante é o crescimento populacional sem qualquer planejamento, que promove o aumento de demanda por recursos hídricos, consumo de energia e produção de alimentos. Atender a essa demanda que cresce diariamente é uma tarefa complicada, uma vez que se deve garantir a quantidade e qualidade de água à população de acordo com as políticas públicas.

Em regiões semiáridas, o manejo da água se torna ainda mais complexo por causa das altas taxas de evaporação e distribuição irregular da chuva no espaço e no tempo (CARNEIRO & FARIAS, 2013). Grande parte do estado da Paraíba tem clima semiárido e está inserido no “Polígono das secas”, dessa forma essa região está sujeita a longos períodos de estiagem.

Uma das maneiras de mitigar ou evitar os efeitos da seca e utilizar os recursos hídricos de forma mais sustentável é o uso de regras operacionais para guiar na operação de sistemas hídricos. O resultado disso é a minimização de prejuízos econômicos, ambientais e sociais. Nesses casos, os modelos de otimização são bastante utilizados e têm como base as variáveis presentes no balanço hídrico e uma função objetivo, linear ou não linear, que vai ser minimizada ou maximizada (BRAVO et al., 2005).

Segundo Labadie (2004), os modelos de otimização são vistos como um instrumento de suporte a decisão, colocando em ênfase a otimização como uma ferramenta controlada por gestores de sistemas de reservatórios. Com os sistemas de suporte à decisão, é possível prever um conjunto de cenários hipotéticos desde

os mais otimistas até os menos favoráveis, servindo de auxílio ao processo de tomada de decisão (CAMPOS & STUDART, 2001).

Atualmente existem várias técnicas, métodos ou procedimentos que ajudam na tomada de decisão em relação à gestão dos recursos hídricos, principalmente no que diz respeito à otimização de reservatórios. Entre elas, pode-se citar: algoritmos genéticos, redes neurais artificiais, otimização de curvas guias etc.

Nesse trabalho, buscar-se-á desenvolver e verificar a aplicabilidade de uma metodologia baseada em Otimização Estocástica Implícita e Redes de Função de Base Radial capaz de incorporar as incertezas hidrológicas para operar de forma mais sustentável sistemas hídricos localizados no semiárido do estado da Paraíba.

2 OBJETIVOS

2.1 Geral

Gerar e analisar regras baseadas em Otimização Estocástica Implícita (OEI) e Redes de Função de Base Radial (RBF) para operação de um sistema de reservatórios no semiárido paraibano.

2.2 Específicos

- Caracterizar a operação do sistema de reservatórios Coremas – Mãe D'Água;
- Implementar um modelo de simulação para representar o funcionamento do sistema hídrico estudado;
- Desenvolver regras para operação de reservatórios baseados em OEI e RBF;
- Comparar as regras operacionais geradas com uma política de operação padrão.

3 REVISÃO BIBLIOGRÁFICA

3.1 Modelos de Otimização

Modelos de otimização são frequentemente usados para prover um melhor planejamento e operação de sistemas de abastecimento de água (DURANYILDIZ & BAYAZIT, 1988; EMCH & YEH, 1998; NEELAKANTAN & PUNDARIKANTHAN, 1999; LABADIE, 2004; PULIDO-VELÁZQUEZ et al., 2006; Farias, 2009).

A procura por políticas ótimas para sistemas hídricos está diretamente relacionada com a seleção das variáveis de operação (LOUCKS et al., 1981). Estas variáveis podem ser divididas em dois grupos: variáveis de decisão e de estado. As variáveis de decisão representam a solução ótima, enquanto as variáveis de estado são consequências dos valores atribuídos às variáveis de decisão. A procura pela combinação ótima das variáveis de decisão, de forma a minimizar ou maximizar um objetivo (função-objetivo) sujeito a restrições, é a grande finalidade das técnicas de otimização. Em geral, os modelos matemáticos de otimização podem ser classificados como:

- Programação linear;
- Programação dinâmica; e
- Programação não-linear.

3.1.1 Programação Linear

A programação linear é definida como uma técnica de otimização usada para maximizar ou minimizar uma função-objetivo linear, com igualdades e/ou desigualdades também lineares. O problema geral da programação linear foi primeiro formulado por Dantzig, em 1947, com o desenvolvimento do método simplex. A partir daí, a programação linear passou a ser bastante aplicada para o gerenciamento dos recursos hídricos (HIEW et al., 1989; CRAWLEY & DANDY, 1993; NEEDHAM et al., 2000; etc.).

3.1.2 Programação Dinâmica

A programação dinâmica é um procedimento que consiste na quebra de um grande problema em subproblemas, cujas soluções sejam mais fáceis e rápidas do que resolver o problema completo. Esta estrutura permite que os tomadores de decisão resolvam o problema passo-a-passo até o resultado final. Este procedimento é baseado no princípio de Bellman (1957).

Aplicações de programação dinâmica para operação de reservatórios podem ser vistas nos trabalhos de Young (1967), Jacobson & Mayne (1970), Murray & Yakowitz (1979), Houck (1982), Karamouz et al. (1992), Draper (2001) etc.

3.1.3 Programação Não-linear

Muitas das funções encontradas nos problemas de sistemas hídricos são não-lineares. A programação não-linear (PNL) é um procedimento de otimização usado para maximizar ou minimizar uma função-objetivo, com igualdades e/ou desigualdades, de maneira que pelo menos uma das restrições ou a função-objetivo seja não-linear.

Chu & Yeh (1978) aplicou PNL para operação horária e em tempo real de reservatórios. Martin (1987) usou PNL para operação diária do sistema de água superficial do Lower Rio Grande, no Texas, Estados Unidos. Celeste (2004) e Farias (2009) utilizaram PNL para a operação diária e em tempo real do reservatório que abastece a cidade de Matsuyama, Japão. Outras aplicações podem ser encontradas nos trabalhos de Tejada-Guibert et al. (1990), Teegavarapu & Simonovic (2000), Barros et al. (2003), e Tu et al. (2008).

3.2 Outras Técnicas de Otimização

Existem muitas outras técnicas sendo aplicadas para otimização da operação de sistemas hídricos. Algumas destas técnicas podem ser listadas a seguir:

- Algoritmos genéticos (AG);

- Lógica *Fuzzy* ou Difusa (LD);
- Redes neurais artificiais (RNA);
- Colônia de formigas (CF), etc.

A técnica de AG tem sido amplamente utilizada para o gerenciamento de sistemas hídricos e algumas de suas aplicações podem ser vistas nos trabalhos desenvolvidos por Goldberg (1989), Oliveira & Loucks (1997), Celeste (2002) etc. Trabalhos com RNA podem ser encontrados em Raman & Chandramouli (1996), Neelakantan & Pundarikanthan (1999), Chandramouli & Deka (2005) e Farias et al. (2006). Aplicações de LD podem ser encontradas nos estudos de Shrestha et al. (1996), Fontane et al. (1997) e Akter & Simonovic (2004). Um exemplo de CF aplicado aos recursos hídricos é dado por Kumar & Reddy (2006).

3.2.1 Modelos de Otimização Determinísticos e Estocásticos

Os modelos de otimização podem ser classificados como determinísticos ou estocásticos. Modelos determinísticos descrevem o comportamento de um sistema no qual as variáveis de entrada são admitidas como certas, ou seja, as variáveis independentes têm um impacto conhecido sobre as variáveis dependentes. Em contraste, os modelos estocásticos consideram a existência de variáveis incertas no sistema.

Os modelos mais comuns de otimização estocástica são Otimização Estocástica Implícita (OEI) e Otimização Estocástica Explícita (OEE). O modelo de OEI considera a variabilidade das entradas do sistema (e.g., vazões afluentes) através do uso de longas séries de valores históricos ou sintéticos por modelos determinísticos de otimização (Young, 1967; Karamouz et al., 1992; Willis et al., 1984; Nandalal & Bogardi, 2007). Já a técnica de OEE integra diretamente modelos probabilísticos das variáveis de entrada no processo de otimização (FLETCHER et al., 1994).

3.3 Redes Neurais Artificiais

Uma rede neural artificial (RNA) é um sistema de processamento de informação que têm como principal fonte de inspiração as redes neurais biológicas (SILVA, 2005).

Segundo Silva (2005), as redes neurais artificiais têm sido desenvolvidas como generalizações de modelos matemáticos da cognição humana ou biologia neural, assumindo que:

- o processamento da informação ocorre em vários elementos chamados *neurônios*;
- os sinais são propagados de um elemento a outro através de *conexões*;
- cada conexão possui um *peso* associado, que, em uma rede neural típica, pondera o sinal transmitido; e
- cada neurônio (ou unidade) aplica uma *função de ativação* (geralmente não-linear) à sua entrada de rede (soma ponderada dos sinais de entrada) para determinar sua saída.

Ainda segundo Silva (2005), uma rede neural pode ser caracterizada por três aspectos principais: (1) o padrão de conexões entre as unidades (*arquitetura*), (2) o método de determinação dos pesos das conexões (*algoritmo de treinamento ou aprendizado*) e (3) suas *funções de ativação*.

3.3.1 Redes de Função de Base Radial

Em geral, as redes neurais de função de base radial, do inglês *radial basis function* (RBF), são empregadas em problemas que envolvem aproximação de funções como também classificação de padrões. Esse tipo de rede é não-linear e utilizada como base em qualquer modelo de regressão não-linear. As RBFs são compostas por apenas uma camada intermediária, na qual as funções de ativação podem ser do tipo gaussiana, multi-quadrática, multi-quadrática inversa etc. (Tab.1). E uma camada de saída, com função de ativação linear.

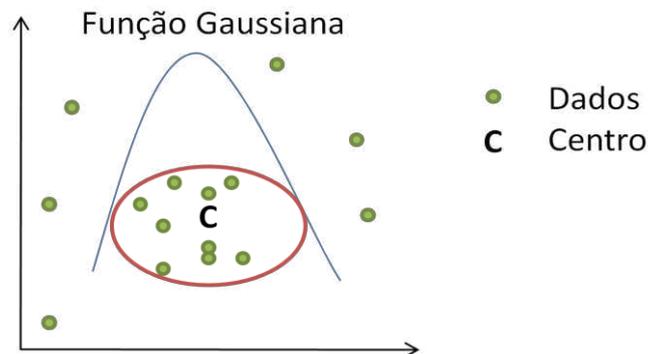
Tabela 1 - Algumas funções de base radial comumente utilizadas

Lâmina <i>spline</i> fina	$\phi(\zeta) = \frac{\zeta}{\sigma^2} \log \frac{\zeta}{\sigma}$
Multi – quadrática	$\phi(\zeta) = \sqrt{\zeta^2 + \sigma^2}$
Multi – quadrática inversa	$\phi(\zeta) = \frac{1}{\sqrt{\zeta^2 + \sigma^2}}$
Gaussiana	$\phi(\zeta) = \exp\left(-\frac{\zeta^2}{2\sigma^2}\right)$

Fonte: Castro, 2001

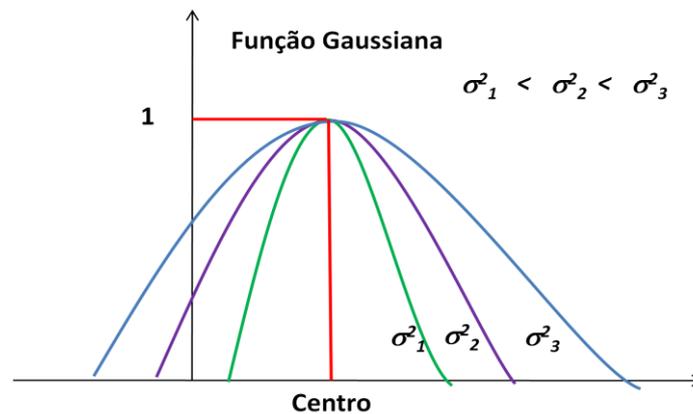
Segundo Castro (2001) a função de base radial do tipo gaussiana é a mais comumente utilizada em aplicações práticas. O parâmetro σ equivale ao desvio-padrão da função Gaussiana e, dessa forma, σ define a distância euclidiana média que mede o espalhamento dos dados representados pela função de base radial em torno do seu centro, conforme mostrado na Fig. 1.

Figura 1 - Função de Base Radial do tipo Gaussiana



Fonte: Elaborado pelo autor

Silva et al. (2010) citam que quando mais próxima uma série de dados do centro mais significativa será seu valor, sendo este tendendo para 1. O neurônio produzirá respostas similares para todos aqueles dados que estejam a uma mesma distância radial do centro, de acordo com a Fig. 2.

Figura 2 - Influência do parâmetro σ^2 na função gaussiana

Fonte: Elaborado pelo autor

Silva et al. (2010) ainda citam a estratégia para o ajuste de pesos de suas duas únicas camadas neurais, que está dividida em duas etapas. A primeira fase está associada com os ajustes de pesos dos neurônios na camada intermediária, que adota um método de aprendizado não-supervisionado que depende apenas das características dos dados de entrada. Na segunda etapa vincula-se aos ajustes dos pesos dos neurônios da camada de saída. O processo de treinamento inicia-se nos neurônios da camada intermediária e encerra-se nos neurônios da camada de saída.

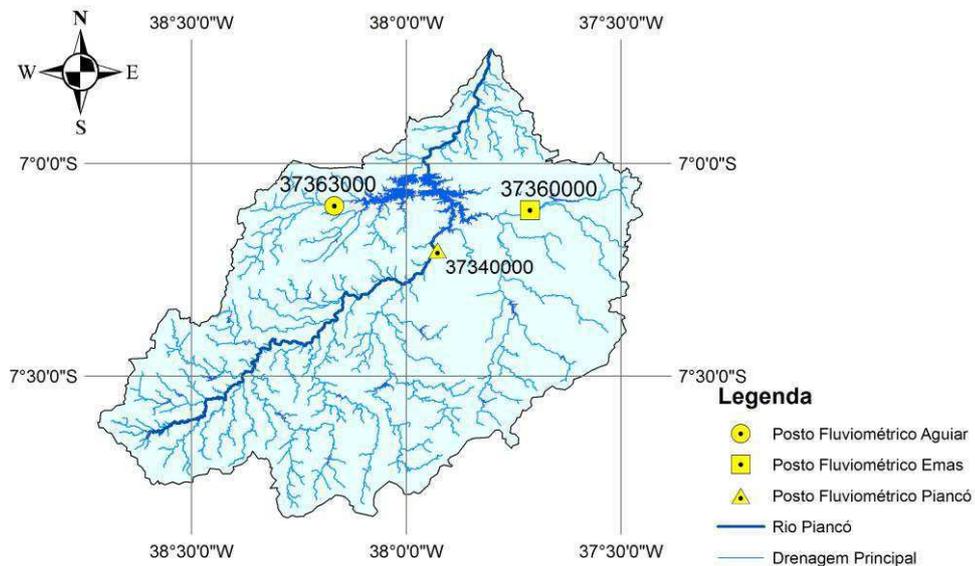
4 MATERIAIS E MÉTODOS

4.1 Área de Estudo

Todos os procedimentos e modelos desenvolvidos neste trabalho foram aplicados para operação do sistema hídrico Coremas – Mãe d'Água, localizado no semiárido paraibano.

No extremo sudoeste da Paraíba, na sub-bacia do Rio Piancó, encontra-se o sistema Coremas – Mãe d'Água. Segundo Lima (2004), a temperatura média anual da região é superior a 24°C e a precipitação média anual é de 821 mm, sendo que nos meses de fevereiro, março e abril a precipitação representa 60% deste valor. A evaporação é de quase 3000 mm, com as maiores taxas mensais no período de setembro a dezembro. Esse sistema recebe contribuições afluentes de outros tributários, porém três deles merecem destaque: riacho Aguiar, riacho Emas e rio Piancó, como mostrado na (Fig. 3).

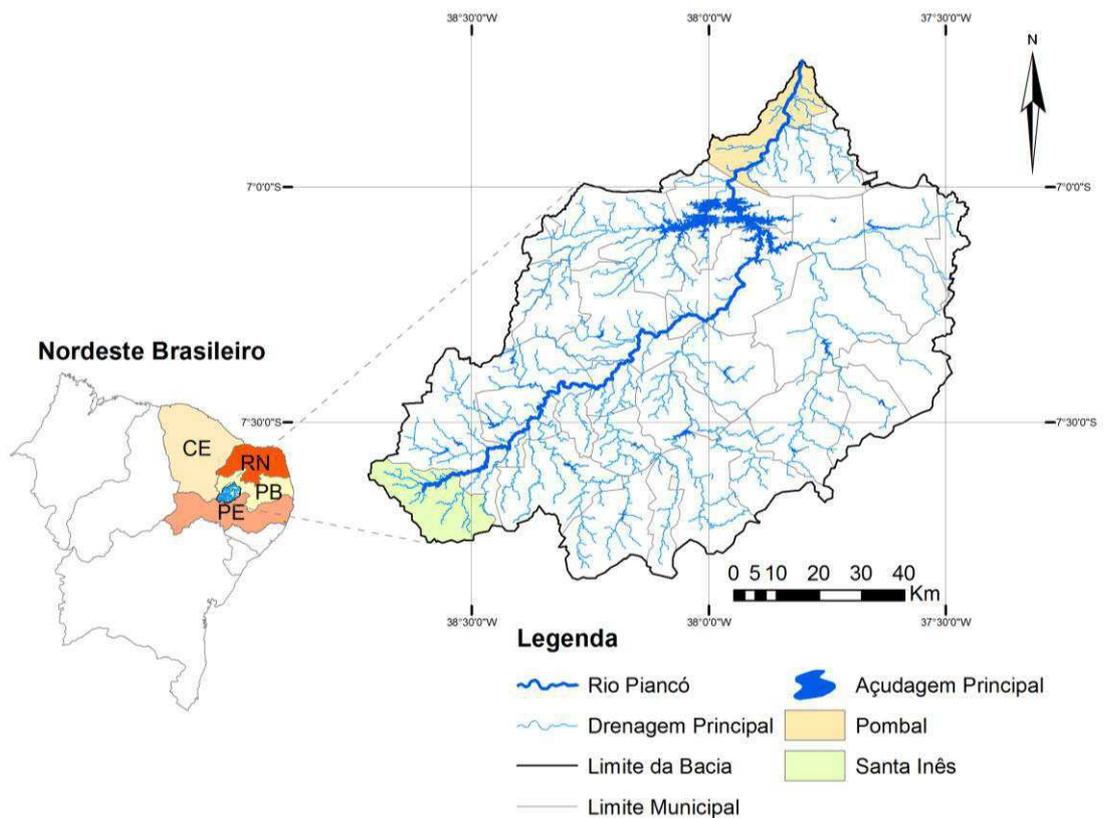
Figura 3 - Localização do Sistema Coremas – Mãe d'Água na bacia hidrográfica do Rio Piancó



Fonte: Carneiro e Farias, 2013.

Segundo o Plano Diretor de Recursos Hídricos do Estado da Paraíba – PDRH/PB (SICENTEC, 1997), o rio Piancó nasce na Serra do Umbuzeiro, município de Santa Inês (Fig.4) e deságua no rio Piranhas em Pombal – PB. Ao longo desse percurso, conta com 1336 açudes, sendo que 90,6% são pequenos reservatórios.

Figura 4 - Localização dos reservatórios Coremas – Mãe d'Água na bacia hidrográfica do Rio Piancó



Fonte: Lourenço, 2013.

O Sistema Coremas – Mãe D'Água é composto por dois reservatórios: o açude Estevam Marinho (Coremas) e Mãe D'Água. Esses açudes quando cheios, formam um só reservatório, o sistema Coremas – Mãe D'Água. Segundo Lima (2004), os açudes são interligados por um canal com capacidade máxima de vazão igual a $12 \text{ m}^3/\text{s}$. Na cota máxima, os reservatórios formam um lago com superfície líquida de $115,6 \times 10^6 \text{ m}^2$ (Fig.5).



Fonte: Google Earth, 2014.

Segundo Lima (2004), os açudes têm várias formas de uso, como o controle de cheias da região, irrigação, piscicultura, aproveitamento de culturas nas áreas a montante, abastecimento de água para as populações urbanas e geração de energia (Tab. 2). Além dessas demandas, existe a exigência de vazão ecológica igual ou superior à 1,0 m³/s na divisa entre os estados da Paraíba e Rio Grande do Norte (Agência Nacional de Águas, 2004)

Tabela 2 - Formas de uso da água para o Sistema Coremas – Mãe d'Água

	Irrigação	Abastecimento humano	Piscicultura	Total (m³/s)
Janeiro	8,12	2,28	0,049	10,45
Fevereiro	7,45	2,28	0,049	9,78
Março	6,77	2,28	0,049	9,10
Abril	6,68	2,28	0,049	9,01
Mai	6,51	2,28	0,049	8,84
Junho	6,64	2,28	0,049	8,97
Julho	7,11	2,28	0,049	9,44
Agosto	7,92	2,28	0,049	10,25
Setembro	8,40	2,28	0,049	10,73
Outubro	8,70	2,28	0,049	11,03
Novembro	8,72	2,28	0,049	11,04
Dezembro	8,21	2,28	0,049	10,54

Fonte: Lima, 2004.

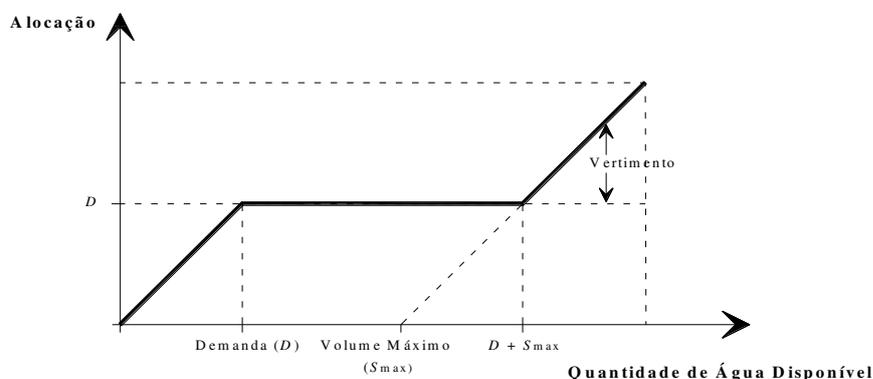
A vegetação natural da região é pertencente ao bioma caatinga com plantas do tipo xerófitas. Esse tipo de vegetação é caracterizado por possuir folhas reduzidas, muitas vezes do tipo espinhosas, raízes longas e com capacidade de armazenar água e geralmente caule carnudo. Essas particularidades são mecanismos de sobrevivência em regime de água escasso (LIMA, 2004).

Muito usada para a produção de lenha na região, a vegetação da caatinga é explorada de maneira não sustentável. Segundo Lima (2004) degradação da vegetação na bacia está bastante acentuada. A área ocupada pelo homem já supera a metade das terras da bacia, causando um elevado grau de degradação e contribuindo para a intensificação de processos de aridez na região. Vale ressaltar ainda que a remoção da vegetação ciliar provoca fenômenos como assoreamento e eutrofização de corpos hídricos.

4.2 SLOP

Uma das regras de operação mais simples é a Política Operacional Linear Padrão, do inglês *Standard Linear Operation Policy* (SLOP). Nesse modelo, que é mostrado na Fig.6, estabelece-se que quando a água disponível é igual ou inferior à demanda, toda a água armazenada é alocada, e quando a água disponível é superior à demanda, a mesma é atendida e o excedente começa a ser acumulado no reservatório até atingir seu volume máximo e, por ventura, gera vertimento (LOUCKS et al., 1981; CELESTE, 2004).

Figura 6 - Política de Operação Linear Padrão



Fonte: Farias, 2009

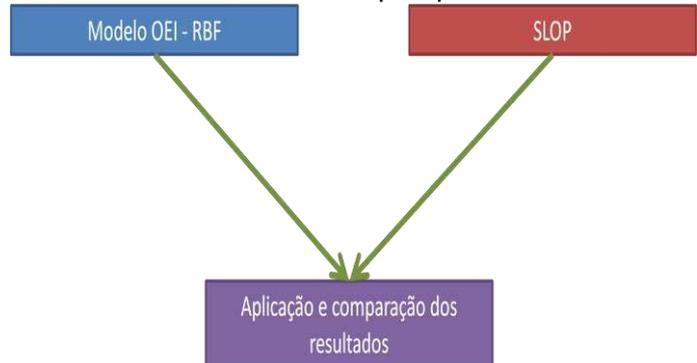
4.3 Modelo OEI-RBF

Todos os procedimentos e etapas para obtenção do modelo OEI - RBF podem ser visualizadas na Fig.7 e Fig.8.

Figura 7- Fluxograma representativo do Modelo OEI – RBF



Figura 8 - Fluxograma representativo dos modelos utilizados na pesquisa



Fonte: Elaborado pelo autor

O Modelo OEI-RBF é fruto da combinação do modelo de Otimização Estocástica Implícita com Redes Neurais de Função de Base Radial. O modelo RBF relaciona as alocações ótimas com outras variáveis do sistema. Normalmente, essas alocações ótimas são modeladas por meio de regressão linear. Entretanto, quase sempre essas variáveis seguem uma tendência não linear. Segundo Silva et al. (2010), funções de base radial são não-lineares e podem ser utilizadas como base em qualquer modelo de regressão não-linear. O modelo criado será comparado com a política de operação padrão (SLOP), conforme ilustrado na Fig.8.

4.3.1 Geração Estocástica de Vazões

O uso de um modelo de OEI requer dados sintéticos de vazões que possuam propriedades estatísticas semelhantes aos dados observados. Para gerar esse tipo de dado, foi utilizado o Método dos Fragmentos (MF), que foi inicialmente proposto por Svanidze (1980) e que vem sendo largamente utilizado (CELESTE et al., 2007; Carneiro & Farias, 2013).

Esse método consiste em desagregar vazões anuais em vazões mensais conforme um método padronizado (CELESTE et al. 2007). Com o MF é possível criar M séries de vazões sintéticas mensais afluentes ao reservatório, considerando diversos de cenários probabilísticos. Os fragmentos são calculados pela divisão das vazões mensais em um determinado ano pelo somatório de todas as vazões mensais do respectivo ano como mostrado na Equação (1):

$$f(i, m) = \frac{Q(i, m)}{\sum_{j=1}^{12} Q(i, m)} \quad (1)$$

onde $f(i, m)$ e $Q(i, m)$ são, respectivamente, o fragmento e a vazão do mês m do ano i .

Segundo Carneiro & Farias (2013), o passo seguinte é investigar a correlação linear no conjunto de vazões anuais observadas, caso sejam dependentes serialmente, utilizar modelos estatísticos para obter uma série de resíduos independentes. Após isso, os resíduos da série de vazões anuais históricas são modelados a uma função de densidade de probabilidade apropriada.

Em seguida, as vazões anuais geradas são desagregadas pelo seguinte processo:

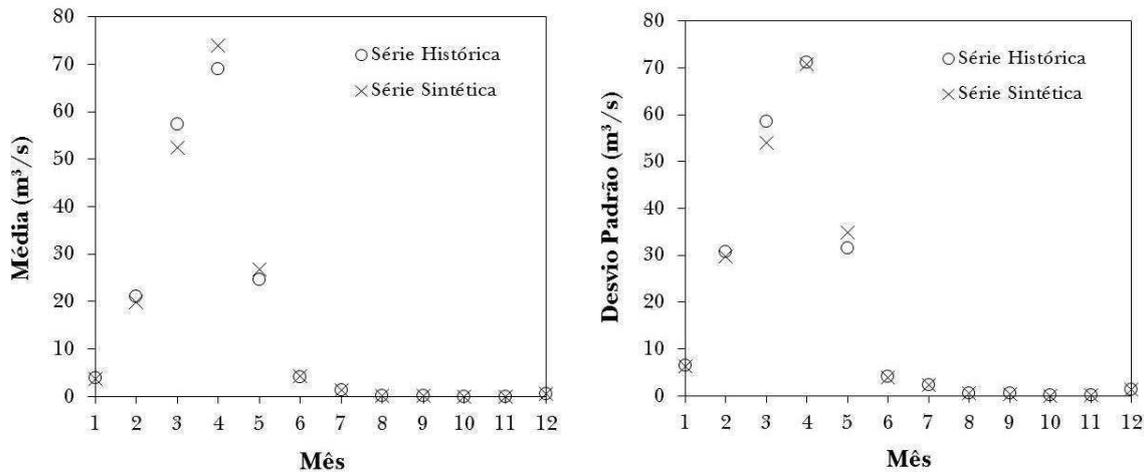
- (1) ordena-se as vazões anuais dos dados históricos em ordem crescente, de forma que a primeira classe tenha limite inferior igual a zero e a última classe tenha limite superior igual a infinito;
- (2) as classes intermediárias são definidas pelas médias de duas vazões anuais sucessivas e cada vazão anual gerada pertencerá a uma classe correspondente;

- (3) as vazões mensais são obtidas pela multiplicação dos fragmentos daquela classe pelo valor anual sintético.

Os dados utilizados no MF são o somatório das vazões mensais dos postos fluviométricos de Aguiar, Emas e Piancó entre os anos de 1964 a 1984 para o reservatório Coremas – Mãe d'Água, a base de dados foi a HidroWeb da agência Nacional de Águas (ANA).

Para esse trabalho foi gerada uma sequência de 1000 anos de vazões sintéticas afluentes ao reservatório Coremas – Mãe d'Água e, assim como no trabalho de Carneiro & Farias (2013), as suas propriedades estatísticas foram comparadas com as observadas nas vazões históricas (Fig.9). Os resultados se mostraram satisfatórios.

Figura 9 - Comparação das propriedades estatísticas (média e desvio padrão) entre vazões sintéticas e históricas



Fonte: Elaborado pelo autor

4.3.2 Modelo de Otimização Determinístico

Nesse modelo assume-se que o principal objetivo da operação é encontrar alocações de água que melhor satisfazem as demandas sem comprometer o sistema. A função objetivo está mostrada na Equação (2) do problema de otimização.

$$\min \sum_{t=1}^N \left(\frac{R(t) - D(t)}{D(t)} \right)^2 \quad (2)$$

em que N é o horizonte de operação; $R(t)$ é a alocação no mês t ; e $D(t)$ a demanda no mês t .

Alocações e volumes de cada período são relacionados com vazão afluyente, evaporação e vertimento pelas Equações (3-4):

$$S(1) = S(0) + Q(1) - R(1) - E(1) - Sp(1) \quad (3)$$

$$S(t) = S(t - 1) + Q(t) - R(t) - E(t) - Sp(t); \quad \forall t = 2, \dots, N \quad (4)$$

em que $S(t)$ é o volume do reservatório no final do mês t ; $S(0)$ é o volume inicial; $Q(t)$ é a vazão afluyente ao sistema durante o mês t ; $E(t)$ é a evaporação sobre a superfície líquida do reservatório durante o mês t ; e $Sp(t)$ é o vertimento que eventualmente pode ocorrer durante o período t .

Nas Equações (5-8) definem-se as limitações físicas do sistema e as restrições para alocações, volume e vertimento.

$$0 \leq R(t) \leq D(t); \quad \forall t \quad (5)$$

$$S_{\text{morto}} \leq S(t) \leq S_{\text{max}}; \quad \forall t \quad (6)$$

$$Sp(t) \geq 0; \quad \forall t \quad (7)$$

$$E(t) \geq 0; \quad \forall t \quad (8)$$

Em que S_{max} e S_{morto} são o volume máximo e morto do reservatório, respectivamente. Esse modelo de otimização, formulado como um problema de programação quadrática com restrições lineares, é implementado em Matlab R2012a.

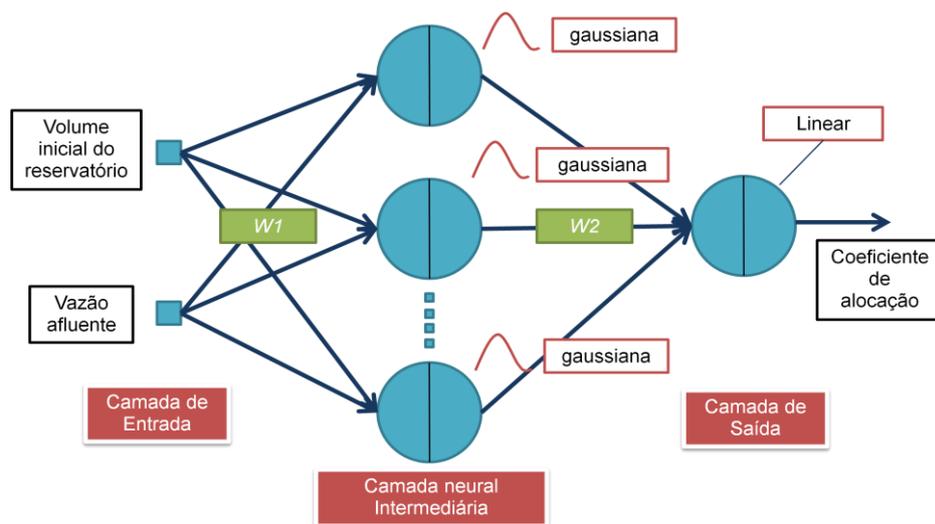
4.3.3 Regras OEI-RBF

O modelo de OEI combinado com RBF consiste das seguintes etapas:

- (1) Gerar M seqüências de N meses de valores de vazões afluentes ao sistema hídrico por meio do MF;
- (2) Para cada seqüência de N meses, encontrar as alocações ótimas de água a partir do modelo de otimização determinístico;
- (3) Usar o conjunto de dados otimizados para desenvolver regras de operação baseadas em RBF.

A arquitetura de uma RBF é formada por uma camada de entrada, uma intermediária e uma de saída como mostrado na (Fig.10). A camada de entrada é composta de dois neurônios, que são o volume inicial do reservatório e a vazão afluente. Na camada intermediária gerou-se um número de neurônios diferentes para cada mês, conforme a calibração. O coeficiente de alocação, que varia de 0% a 100% é o neurônio da camada de saída.

Figura 10 - Configuração típica da RBF



Fonte: Elaborado pelo autor

5 APLICAÇÃO E RESULTADOS

5.1 Regras OEI-RBF

Nesta pesquisa, o sistema hídrico é modelado como um reservatório equivalente, ou seja, o volume é considerado como a soma dos volumes individuais dos reservatórios Coremas – Mãe D'Água. As vazões afluentes ao reservatório equivalente são a soma das vazões de entrada nos dois reservatórios.

Os volumes morto e máximo do reservatório equivalente foram ajustados para 46,80 hm³ e 1.358,70 hm³, respectivamente. O volume inicial foi assumido como sendo igual ao volume máximo. O modelo de OEI foi aplicado para $M = 20$ sequências de $N = 1248$ meses (104 anos) de vazões afluentes ao reservatório, que foram geradas pelo MF. Os primeiros e últimos dois anos de cada sequência foram eliminados para evitar problemas com condições de contorno. Esse processo produziu um total de 24.000 meses (20 sequências de 100 anos) de alocações ótimas.

Os dados ótimos de volume inicial, vazão afluente e alocação para os meses de janeiro a dezembro foram agrupados e utilizados para modelagem de 12 RBF, uma para cada mês do ano. As RBFs foram calibradas considerando um desvio padrão da função gaussiana igual a 10 e o número máximo de neurônios iguais a 50. Os valores de correlação linear entre valores calculados e observados no treinamento das RBF para cada mês encontram-se na (Tab.3).

Tabela 3 - Valores de correlações para os modelos RBF

Mês	Correlação
Jan	0,65
Fev	0,57
Mar	0,65
Abr	0,69
Mai	0,70
Jun	0,69
Jul	0,67
Ago	0,67
Set	0,66
Out	0,65
Nov	0,63
Dez	0,61

Fonte: Elaborado pelo autor

Os valores de correlação entre dados calculados e observados, maiores que 0,57, são considerados satisfatórios, tendo em vista o alto grau de complexidade entre as variáveis de calibração.

Segundo Carneiro & Farias (2013), o indicador de vulnerabilidade representa a magnitude das falhas ao atendimento das demandas considerando todo o horizonte de operação N e pode ser definido conforme a Equação (9). Esse índice varia entre 0 e 1 e o menor valor indica o atendimento total a demanda enquanto o maior representa que nada foi alocado. Em outras palavras, quanto mais próximo de zero for esse indicador, menos vulnerável será considerada a regra.

$$\sum_{t=1}^N \frac{[R(t)-D(t)]^2}{D(t)} \quad (9)$$

Para verificar o desempenho do modelo OEI-RBF, novas simulações com 20 anos foram geradas pelo MF e submetidas a testes utilizando as novas regras. O modelo SLOP também foi utilizado para fins de comparação.

Na (Tab.4) encontra-se as comparações entre os índices de vulnerabilidade para os dois modelos considerando as dez novas simulações. Pode-se perceber que em quase todas as simulações o modelo proposto foi melhor do que a política de operação padrão.

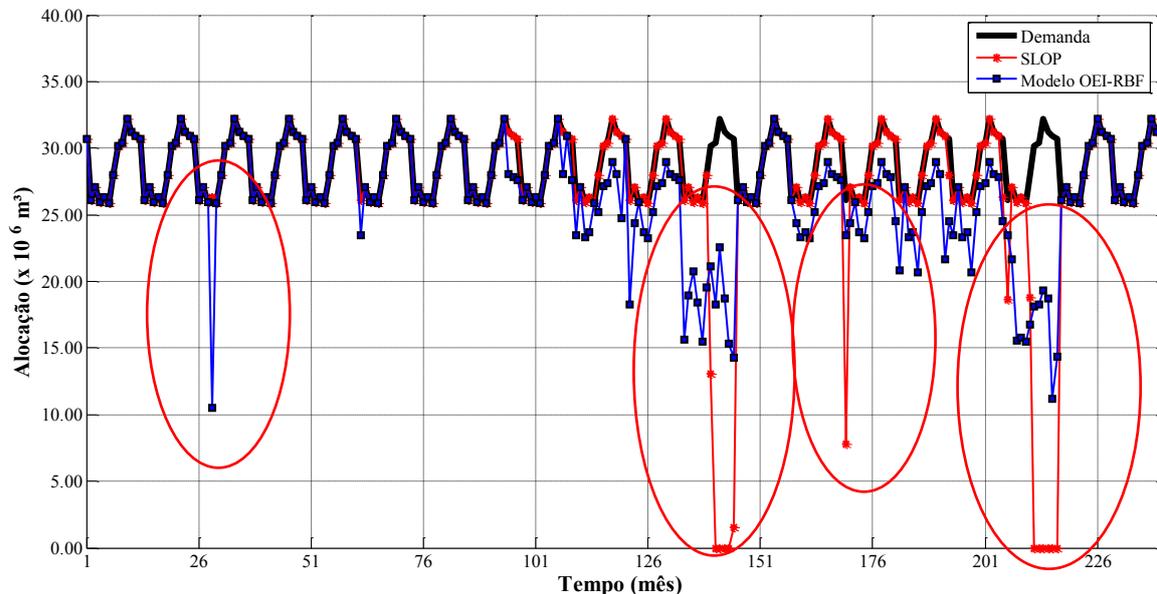
Tabela 4 - Índice de vulnerabilidade para 10 novas simulações de 20 anos considerando todos os modelos

	SLOP	Modelo OEI-RBF
SIM#1	0,27	0,22
SIM#2	0,07	0,04
SIM#3	0,14	0,10
SIM#4	0,00	0,00
SIM#5	0,06	0,04
SIM#6	0,18	0,15
SIM#7	0,22	0,18
SIM#8	0,03	0,02
SIM#9	0,05	0,04
SIM#10	0,05	0,02

Fonte: Elaborado pelo autor

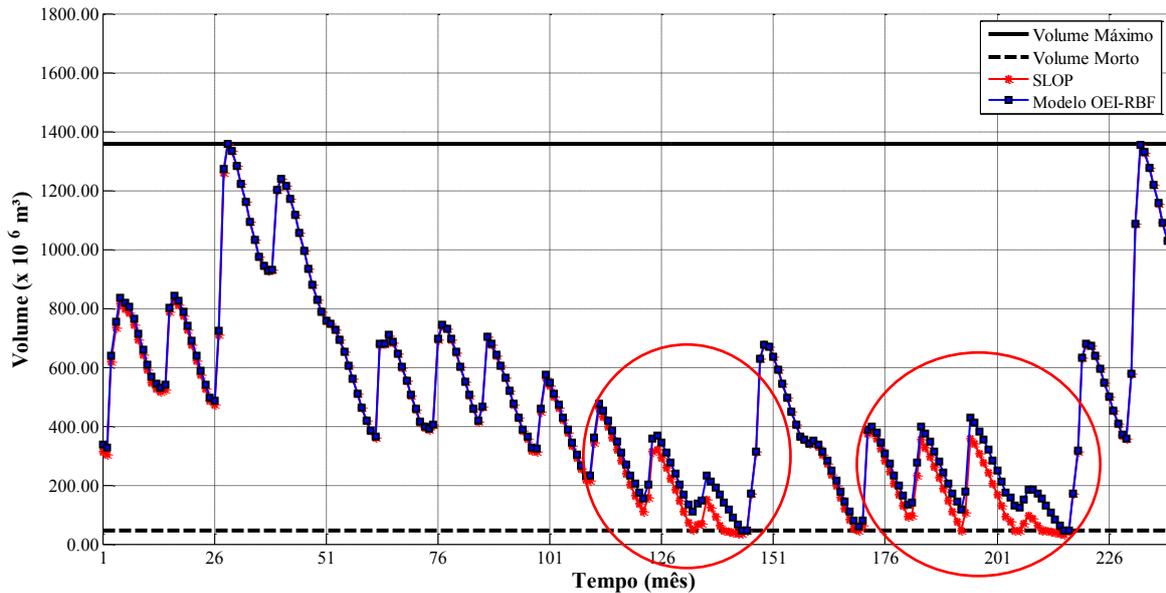
Nas Fig. 11-12 encontram-se gráficos mostrando o comportamento do volume do reservatório e das alocações considerando as operações realizadas pelos modelos OEI-RBF e SLOP na SIM#10, sendo que está foi escolhida de maneira aleatória. Uma observação interessante na (Fig.11) sobre o modelo OEI-RBF foi sua redução de alocação um pouco depois do mês 26, a regra gerada simulou que o mês seguinte haveria estiagem, portanto este reduziu a alocação.

Figura 11 - Volumes do reservatório para operação com todos os modelos



Fonte: Elaborado pelo autor

Figura 12 - Alocações de água para operação do reservatório com todos os modelos



Fonte: Elaborado pelo autor

Comparando o OEI-RBF com o SLOP nas Fig. 11-12, é possível perceber que o racionamento de alocações com o modelo OEI-RBF permite evitar situações extremas de falta de água observadas com o SLOP nos 20 anos de simulação, reduzindo a vulnerabilidade total do sistema, ou seja, o modelo prevê cenários probabilísticos de períodos de estiagem e reduz a alocação de água no sistema para minimizar a vulnerabilidade.

Observando-se as Figuras 11-12 e a Tab. 4, em que todos os valores do critério de vulnerabilidade adotado foram menores no modelo OEI-RBF, percebe-se que o modelo proposto é superior a regra operacional SLOP.

6 CONSIDERAÇÕES FINAIS

O objetivo desse estudo foi a formulação e aplicação de regras operacionais mensais para os reservatórios Coremas – Mãe D'Água, localizado no semiárido paraibano. O procedimento consistiu em gerar regras operacionais por meio de otimização estocástica implícita e redes neurais de função de base radial.

As regras geradas foram aplicadas para operar o sistema considerando cenários sintéticos de vazões mensais. No modelo OEI-RBF, observou-se uma menor vulnerabilidade quando comparado com a política de operação padrão.

Seria interessante que em trabalhos futuros a ferramenta RBF fosse explorada para aprimorar esse tipo de modelagem e aplicada em outras áreas dos recursos hídricos, como por exemplo, considerar a otimização dos usos múltiplos e condições variáveis de demanda.

REFERÊNCIAS BIBLIOGRÁFICAS

ADELOYE A. J.; RUSTUM, R.; KARIYAMA, D. **Kohonen self-organizing map estimator for the reference crop evapotranspiration**. *Water Resources Research*, v. 47, n. 8, pp. 1–19, 2011.

Agência Nacional de Águas. **Resolução n.º 687, de 03 de dezembro de 2004**. Dispõe sobre o Marco Regulatório para a gestão do Sistema Curema-Açu e estabelece parâmetros e condições para a emissão de outorga preventiva e de direito de uso de recursos hídricos e declaração de uso insignificante. [S.I.]: ANA, 2004.

AKTER, T., and S. P. SIMONOVIC: **Modelling uncertainties in short-term reservoir operation using fuzzy sets and a genetic algorithm**, *Hydrological Sciences Journal des Sciences Hydrologiques*, 49(6), 2004.

BARROS, M. T. L., F. T-C. TSAI, S. YANG, J. E. G. Lopes and W. W-G. Yeh: **Optimization of large-scale hydropower system operations**, *Journal of Water Resources Planning and Management*, ASCE, 129(3), pp. 178-188, 2003.

BELLMAN, R.: *Dynamic Programming*, Princeton University Press, Princeton, USA, 1957.

BRAVO, J. M.; COLLISCHONN, W.; PILAR, J. V. **Otimização da Operação de Reservatórios: Estado-da-Arte**. In: Anais do XVI Simpósio Brasileiro de Recursos Hídricos. João Pessoa, 2005, CD-ROM.

CAMPOS, N.; STUDARD, T. **Gestão das águas: princípios e práticas. 2.ª Edição**, Porto Alegre – RS: ABRH, 2003.

CARNEIRO, T. C.; FARIAS, C. A. S. (2013) **Otimização Estocástica Implícita e Redes Neurais Artificiais para Auxílio na Operação Mensal dos Reservatórios Coremas - Mãe d'Água**. *Revista Brasileira de Recursos Hídricos*.

CASTRO, M. C.F. (2001) **Predição Não – Linear de Séries Temporais Usando Redes Neurais RBF por Decomposição em componentes Principais**. *Tese de Doutorado do curso de Pós-graduação em Engenharia Elétrica apresentada na UNICAMP, faculdade de Engenharia Elétrica e de Computação, Campinas-SP, 2001.*

CELESTE, A. B. **Optimal Real-time Operation of a Multipurpose Water Resource System Using Genetic Algorithms**. 2002. M.Sc. Dissertation, 147 p., Ehime University, Matsuyama, Ehime, Japan, 2002.

CELESTE, A. B.;BILLIB, M. **Improving Implicit Stochastic Reservoir Optimization Models with Long-Term Mean Inflow Forecast**. *Water Resources Management*, v. 26, pp. 2443-2451, 2012.

CELESTE, A. B. et al. **Derivation of reservoir operating rules by implicit stochastic optimization**. *Annual Journal of Hydraulic Engineering – JSCE* 49(2), 2005. p. 1111–1116.

CELESTE, A. B., K. et al. **Stochastic generation of inflow scenarios to be used by optimal reservoir operation models**. *Annual Journal of Hydraulic Engineering, JSCE*, 48(1), 2004. p. 451-456.

CELESTE, A. B.; CURI, W. F.; CURI, R. C. Análise de métodos para geração sintética de vazões em rios intermitentes. In: **Anais do XVII Simpósio Brasileiro de Recursos Hídricos**, 2007, São Paulo. p. 1-18.

CHANDRAMOULI, V. and P. DEKA: **Neural network based decision support model for optimal reservoir operation**, *Water Resources Management*, 19, pp. 447-464, 2005.

CHU, W. S. and W. W.-G. YEH: **A nonlinear programming algorithm for real-time hourly reservoir operations**, *Water Resources Research*, 14(5), pp. 1048-1063, 1978.

CRAWLEY, P. D. and G. C. DANDY: **Optimal operation of multiple-reservoir system**, *Journal of Water Resources Planning and Management*, ASCE, 119(1), pp. 1-17, 1993.

DURANYILDIZ, I. and M. BAYAZIT: **Optimal operation of reservoir systems in critical periods**, *Water Resources Management*, 2, pp. 141-148, 1988.

DRAPER, A. J.: **Implicit Stochastic Optimization with Limited Foresight for Reservoir Systems**, Ph.D. Dissertation, 164 p., University of California, Davis, 2001.

EMCH, P. and W. W-G YEH: **Management model for conjunctive use of coastal surface water and ground water**, *Journal of Water Resources Planning and Management*, ASCE, 124(3), pp. 129-139, 1998.

FARIAS, C. A. S., A. B. CELESTE, Y. SAKATA, A. KADOTA and K. SUZUKI: **Use of Monte Carlo optimization and artificial neural networks for deriving reservoir operating rules**, *Annual Journal of Hydraulic Engineering, JSCE*, 50(1), pp. 25-30, 2006.

FARIAS, C. A. S.: **Derivation of hedging rules and forecasts by artificial neural networks for optimal real-time management of an integrated water resources system**, Ph.D. Thesis, Ehime University, Matsuyama, Japan, 2009.

FONTANE, D., T. GATES and E. MONCADA: **Planning reservoir operations with imprecise objectives**, *Journal of Water Resources Planning and Management*, ASCE, 123(3), pp. 154–162, 1997.

GOLDBERG, D. E.: **Genetic Algorithm in Search, Optimization and Machine Learning**, Addison Wesley, Reading, USA, 1989.

HIEW, K., J. LABADIE and J. SCOTT: **Optimal operational analysis of the Colorado-Big Thompson project**, in *Computerized Decision Support Systems for Water Managers*, edited by J. Labadie *et al.*, ASCE, pp. 632–646, Reston, USA,

1989.

HOUCK, M. H.: **Real-time daily reservoir operation by mathematical programming**, *Water Resources Research*, 18(5), pp. 1345-1351, 1982.

JACOBSON, D. and D. MAYNE: **Differential Dynamic Programming**, Elsevier, New York, USA, 1970.

KARAMOUZ, M., M. H. Houck and J. W. DELLEUR: **Optimization and simulation of multiple reservoir systems**, *Journal of Water Resource Planning and Management*, ASCE, 118(1), pp. 78–81, 1992.

KUMAR, D. N. and M. J. REDDY: **Ant colony optimization for multi-purpose reservoir operation**, *Water Resources Management*, 20, pp. 879-898, 2006.

LABADIE, J. W.: **Optimal operation of multireservoir systems: state-of-the-art-review**, *Journal of Water Resource Planning and Management*, ASCE, 130(2), pp. 93–111, 2004.

LIMA, C. A. G.: **Análise e sugestões para diretrizes de uso das disponibilidades hídricas superficiais da bacia hidrográfica do rio Piancó, situada no estado da Paraíba**. Ph.D. Thesis, Universidade Federal de Campina Grande, Campina Grande, Brasil, 2004.

LOUCKS, D. P., J. R. STEDINGER and D. A. HAITH: **Water Resources Systems Planning and Analysis**, Prentice Hall, Englewood Cliffs, USA, 1981.

MARTIN, Q. W.: **Optimal daily operation of surface-water system**, *Journal of Water Resources Planning and Management*, ASCE, 113(4), pp. 453-470, 1987.

MURRAY, D. and S. YAKOWITZ: **Constrained differential dynamic programming and its application to multi-reservoir control**, *Water Resources Research*, 15(5), pp. 1017–1027, 1979.

NANDALAL, K. D. W. and J. J. BOGARDI: **Dynamic Programming Based Operation of Reservoirs: Applicability and Limits**, Cambridge University Press, United Kingdom, 2007.

NEEDHAM, J., D. WATKINS, J. LUND and K. NANDA: **Linear programming for flood control in the Iowa and Des Moines rivers**, *Journal of Water Resources Planning and Management*, ASCE, 126(3), pp. 118–127, 2000.

NEELAKANTAN, T. R. and N. V. PUNDARIKANTHAN: **Hedging rule optimization for water supply reservoir system**, *Water Resources Management*, 13, pp. 409-426, 1999.

OLIVEIRA, R. and D. P. LOUCKS: **Operating rules for multireservoir systems**, *Water Resources Research*, 33(4), pp. 839-852, 1997.

PULITO-VELÁZQUEZ, M.; ANDREU J.; SAHUQUILLO; A.: **Economic optimization of conjunctive use of surface water and groundwater at the basin scale**. *Journal of Water Resources Planning and Management*, ASCE, v. 132(6), pp. 454-467, 2006.

RAMAN, H. and V. CHANDRAMOULI: **Deriving a general operation policy for reservoirs using neural network**, *Journal of Water Resources Planning and Management*, ASCE, 122(5), pp. 342-347, 1996.

SHRESTHA, B., L. DUCKSTEIN and E. STAKHIV: **Fuzzy rule-based modeling of reservoir operation**, *Journal of Water Resources Planning and Management*, ASCE, 122(4), pp. 262-269, 1996.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.: **Redes neurais artificiais para engenharia e ciências aplicadas**. Artliber, São Paulo, 399 p, 2010.

SILVA, M, A, S. **Mapas Auto-organizáveis na análise Exploratória de dados**

Geoespaciais Multivariados, *Dissertação de mestrado do curso de Pós-graduação em Computação aplicada apresentada ao INPE, São Jose dos Campos-SP, 2005.*

Scientec, Associação para Desenvolvimento da Ciência e Tecnologia. (1997). **Plano Diretor de Recursos Hídricos da Paraíba: Bacias do Piancó e do Alto Piranhas**, SEPLAN, Brasil.

SVANIDZE, G. G. **Mathematical Modeling of Hydrologic Series** (for Hydroelectric and Water Resources Computations). Water Resources Publications, Fort Collins, Colorado, 1980.

TEGAVARAPU, R. S. V. and S. P. SIMONOVIC: **Short-term operation model for coupled hydropower reservoir**, *Journal of Water Resources Planning and Management*, ASCE, 126(2), pp. 98-106, 2000.

TEJADA-GUIBERT, J., J. STEDINGER and K. STASCHUS: **Optimization of the value of CVP's hydropower production**, *Journal of Water Resources Planning and Management*, ASCE, 116(1), pp. 52–70, 1990.

Tu, M.-Y., N.-S. Hsu, F. T.-C. Tsai and W. W.-G. Yeh: **Optimization of hedging rules for reservoir operations**, *Journal of Water Resources Planning and Management*, ASCE, 134(1), pp. 3–13, 2008.

WILLIS, R., B. A. FINNEY and W.-S. CHU: **Monte Carlo optimization for reservoir operation**, *Water Resources Research*, 20(9), pp. 1177-1182, 1984.

YOUNG, G. K., Jr.: **Finding reservoir operating rules**, *Journal of the Hydraulic Division*, ASCE, 93(HY6), pp. 297-321, 1967.