

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS E ALGORITMOS GENÉTICOS AO PLANEJAMENTO DA OPERAÇÃO DE SISTEMAS HIDROTÉRMICOS DE POTÊNCIA E AO MERCADO DE COMERCIALIZAÇÃO DE ENERGIA

ANDERSON PASSOS DE ARAGÃO*, FÁBIO GODOY FERREIRA*, PAULO CESAR MOTA ANSELMO*, PATRÍCIA TEIXEIRA LEITE ASANO*, WELLINGTON TEIXEIRA COIMBRA†, RICARDO DE ANDRADE LIRA RABELO†, RICARDO CANELOI DOS SANTOS*, EDMARCIO ANTONIO BELATI*

**Universidade Federal do ABC - UFABC*
Avenida dos Estados, 5001 - Bangú
Santo André, São Paulo, Brasil

†*Universidade Federal do Piauí - UFPI*
Campus Universitário Ministro Petrônio Portella, s/n - Ininga
Teresina, Piauí, Brasil

Emails: andersonpargao@gmail.com, fabio.godoy@aluno.ufabc.edu.br, paulocesarmaus@gmail.com, patricia.leite@ufabc.edu.br, wellington.coim@gmail.com, ricardoalr@ufpi.edu.br, ricardo.santos@ufabc.edu.br, edmarcio.belati@ufabc.edu.br

Abstract— The Hydrothermal Power System Operation Planning aims to determine the optimum use of hydroelectric and thermoelectric resources available during a planning horizon. In hydrothermal generation systems with hydroelectric generation prevalence, as in the case of the Brazilian system, it is sought to replace thermoelectric generation by hydraulic generation, in order to minimize the operational cost of the system. Therefore, this paper presents a computational model composed of three modules: the first presents the application of Artificial Neural Networks (ANN) to predict the natural flows of hydroelectric plants; in the second module, a Genetic Algorithm (GA1) was implemented to obtain a policy of optimized operation of reservoirs of hydroelectric plants, considering individual hydroelectric plants, using the natural flows data calculated by ANN; The third module corresponds to another Genetic Algorithm (GA2) responsible for reporting, as a basis for the hydraulic generation provided by GA1, a better distribution of the energy generated for the purchase of electricity for the next 14 auctions. In order to verify the feasibility of the proposed model, a system composed of three real hydroelectric plants of the Southeastern Brazilian system was used, the natural flows calculated by RNA were for the period from 2010 to 2015. The proposed methodology aims to demonstrate the viability and applicability of the computational model their effectiveness and the energy gains from their use.

Keywords— Operation Planning of Hydrothermal Power Systems, Optimization, Electric Power Commercialization, Natural Flows, Artificial Neural Networks, Genetic Algorithm.

Resumo— O Planejamento da Operação de Sistemas Hidrotérmicos de Potência tem como objetivo determinar a melhor utilização dos recursos hidroelétricos e termoelétricos disponíveis durante um horizonte de planejamento. Em sistemas de geração hidrotérmicos com prevalência de geração hidrelétrica, como no caso do sistema brasileiro, busca-se substituir a térmica por geração hidráulica, a fim de minimizar o custo operacional do sistema. Portanto, este trabalho apresenta um modelo computacional composto por três módulos: o primeiro apresenta a aplicação de Redes Neurais Artificiais (RNA) para previsão de vazões naturais de usinas hidrelétricas; No segundo módulo, um Algoritmo Genético (AG1) foi implementado para obter uma política de operação otimizada de reservatórios de usinas hidrelétricas, considerando usinas hidrelétricas individuais, utilizando os dados de vazão natural calculados pela RNA; O terceiro módulo corresponde a um outro Algoritmo Genético (AG2) responsável por reportar, como base para a geração hidráulica fornecida pela AG1, uma melhor distribuição da energia gerada para a compra de eletricidade para os próximos 14 leilões. Para verificar a viabilidade do modelo proposto, foi utilizado um sistema composto por três usinas hidrelétricas reais do sistema sudeste brasileiro, as vazões naturais calculadas pela RNA foram para o período de 2010 a 2015. A metodologia proposta visa demonstrar a viabilidade e aplicabilidade do modelo computacional proposto, bem como a sua eficiência e os ganhos energéticos a partir do seu uso.

Palavras-chave— Planejamento da Operação de Sistemas Hidrotérmicos, Otimização, Comercialização de Energia Elétrica, Vazões Naturais, Redes Neurais Artificiais, Algoritmos Genéticos.

1 Introdução

O aumento da demanda por energia elétrica constatado nas última décadas tem impulsionado a busca por diversificação da matriz de energia elétrica por fontes de geração limpas e renováveis (Birol, 2017). Além da necessidade de novas unidades geradoras de energia e do uso eficiente dos recursos energéticos disponíveis no país, faz-se necessário a criação de modelos computacionais capazes de representar cenários operativos cada vez

mais próximos da realidade. Desta forma, é possível realizar um planejamento ótimo da operação buscando a atender as características próprias do sistema em avaliação.

Este planejamento é essencial para que a demanda de energia elétrica seja atendida de forma confiável e com o menor custo. No Brasil a geração de energia elétrica é provida principalmente por usinas hidroelétricas, representando 64,0% e por usinas termoelétricas com 34,4% da parcela da geração de energia elétrica do país, caracteri-

zando assim um sistema hidrotérmico de potência (Empresa de Pesquisa Energética, 2017).

O problema do Planejamento da Operação de Sistemas Hidrotérmicos de Potência (POSHP) visa a construção de uma política operativa de geração das usinas hidroelétricas e termoelétricas do sistema, de modo a atender a demanda e minimizar o custo total da operação em um determinado horizonte de planejamento (de Queiroz, 2016). Logo, o POSHP visa substituir, na medida do possível, a geração de origem complementar (usinas térmicas, déficit e importação de energia, que tem custo de combustível elevado) por geração de origem hidroelétrica, que tem custo de combustível praticamente nulo, buscando minimizar o custo esperado da operação durante o horizonte de planejamento e garantindo suprimento para o próximo período a ser avaliado (Carvalho and Soares, 1987).

O fornecimento confiável e econômico da energia elétrica leva à necessidade de estudos cuidadosos para o funcionamento adequado dos sistemas elétricos de potência, desde a geração até a comercialização. Vale lembrar, que é a dinâmica de funcionamento do sistema que impõem os procedimentos e regularização para a comercialização de energia em todo o sistema.

Entre os vários estudos necessários para o atendimento dos requisitos para a comercialização de energia elétrica pela Câmara de Comercialização de Energia Elétrica (CCEE) pode-se citar a previsibilidade das vazões afluentes naturais que chegam as usinas hidroelétricas e a otimização das fontes de geração em médio prazo (Rabêlo, 2010). Para realizar a cadeia de ações do planejamento, a CCEE necessita dos dados das usinas hidroelétricas como, por exemplo, os dados relativos às máquinas instaladas em cada uma das usinas que compõem o sistema, perdas hidráulicas, engolimento efetivo, potência efetiva, capacidade do reservatório, entre outros.

A grande quantidade de variáveis de cada usina hidroelétrica e termoelétrica, bem como, a quantidade de usinas utilizadas para o atendimento a demanda de energia elétrica, caracterizam o problema como sendo de grande porte. Além das informações construtivas das usinas hidroelétricas, os dados das vazões afluentes naturais que chegam à cada usina são fundamentais para estudos futuros, ou seja, para a criação de cenários operativos futuros. Neste caso, como as afluências futuras são desconhecidas, o problema é de natureza estocástica. Esta incerteza referente às vazões afluentes futuras em conjunto com outras propriedades inerentes à modelagem do problema, como algumas de suas equações e a função objetivo, dados pelos custos dos combustíveis, não linear, das fontes não renováveis, a serem minimizadas fazem com que o problema seja não linear. Por fim, salienta-se que as decisões tomadas

em um intervalo do horizonte de planejamento dependem das decisões que foram tomadas no passado e impactam na evolução das decisões futuras, permitindo classificar o problema como dinâmico (Cicogna, 2004),(Rabêlo, 2010).

Baseado neste contexto, este trabalho propõe um modelo computacional dividido em três módulos aplicado ao POSHP.

O primeiro módulo consiste em uma RNA aplicada a previsão de vazões afluentes naturais das usinas hidroelétricas, levando em consideração os dados reais de vazões afluentes naturais disponibilizados pela Câmara de Comercialização de Energia Elétrica (CCEE) de 1931 até 2009, no arquivo VAZOES.DAT disponibilizado na página da CCEE.

Com as vazões afluentes das usinas hidroelétricas do sistema, foi possível desenvolver o segundo módulo, que corresponde a um Algoritmos Genéticos (AGs) aplicado ao POSHP. O AG implementado tem como objetivo determinar uma política de operação otimizada dos reservatórios das usinas hidroelétricas para um período de planejamento de médio prazo (até 5 anos). Para a construção deste segundo módulo foram utilizados como dados de entrada a vazão afluente natural prevista no módulo 1 e os dados reais das usinas hidroelétricas disponibilizados pela página da CCEE, através do arquivo HIDR.DAT. Efetuada esta etapa e de forma a ilustrar a eficiência do modelo proposto, ele foi avaliado por meio da otimização de um sistema hidroelétrico composto por três usinas reais do sudeste brasileiro, considerando o período de planejamento de 2010 a 2015. A demanda do sistema utilizada foi a potência instalada total das usinas (5152 MW).

O último módulo, com os dados de produção de energia elétrica disponíveis no sistema hidroelétrico encontrada pelo módulo 2, em cada mês, pode-se prever a quantidade de aquisição ou entrega de energia pelo gerador, para evitar que o gerador não tenha energia suficiente para entregar em outro período. No caso dos distribuidores de energia, a demanda a ser contratada deve estar próxima do mercado realizado. Não deverá ocorrer excesso (sobrecontratação) e nem faltar energia para atender todo o mercado (subcontratação) (Dias, 2007).

Este trabalho está organizado da seguinte forma: a Seção 2 apresenta o referencial teórico das técnicas empregadas; a Seção 3 descreve a metodologia proposta, juntamente com os detalhes de cada um dos módulos implementados; a Seção 4 mostra os resultados e as discussões dos resultados encontrados em cada módulo, seguindo pelas conclusões apresentadas na Seção 5.

2 Referencial Teórico

2.1 Redes Neurais Artificiais e Algoritmos Genéticos

As Redes Neurais Artificiais (RNAs) foram concebidas com base no sistema nervoso humano, e são implementadas de maneira a imitar as características de plasticidade e renovação do cérebro humano que são a base do aprendizado por experiência (Haykin et al., 2009). A RNA implementada neste trabalho é do tipo *Multi-Layer Perceptron* (MLP) com entradas atrasadas no tempo. Esta arquitetura utiliza como algoritmo de treinamento o *Backpropagation*.

Os Algoritmos Genéticos (AGs) são algoritmos de busca e otimização inspirados na Teoria da Seleção Natural das Espécies proposta por Charles Darwin. Seu funcionamento é baseado na inspiração biológica a qual pressupõe que em uma determinada população os indivíduos com melhores características genéticas possuem maiores chances de sobrevivência e de gerarem novos indivíduos cada vez mais aptos. Os AGs enfatizam a troca de material genético dos candidatos mais promissores para a solução do problema, ou seja, a combinação dos indivíduos mais aptos da população. Os operadores genéticos são aproximações computacionais de fenômenos observados na natureza, como a mutação genética e a reprodução sexuada denominada de crossover (Goldberg and Holland, 1988).

3 Metodologia

Este trabalho aplicou Redes Neurais Artificiais e Algoritmos Genéticos para a otimização de fontes de geração de energia elétrica e para definir as informações necessárias para que essa energia pudesse ser comercializada através de leilões, bem como, para a definição dos montantes de energia a serem leiloados para a contratação das empresas distribuidoras. A Figura 1, a seguir apresenta como o modelo computacional está estruturado.

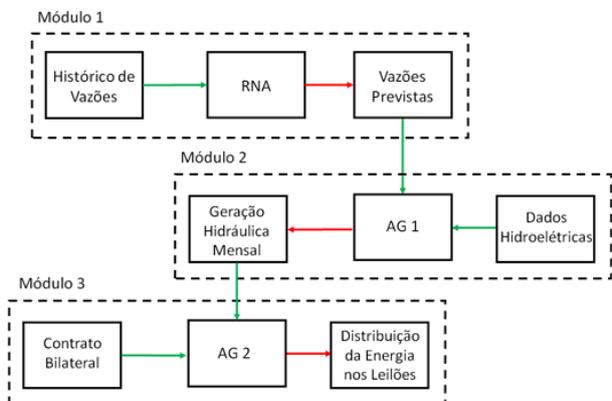


Figura 1: Modelo Computacional proposto. As setas verdes indicam dados de entrada do módulo e as setas vermelhas indicam a saída do módulo.

Na Figura 1 são apresentados os três módulos, os dados de entrada, os dados de saída e a comunicação entre eles. Para melhor entendimento da metodologia proposta e desenvolvida, cada um dos módulos serão detalhados a seguir.

3.1 Módulo 1 - Rede Neural Artificial

Aplicou-se uma RNA *feedforward* com entradas atrasadas no tempo para realizar o estudo da previsão de séries temporais de vazões. Para escolha da arquitetura da RNA como número de camadas e número de neurônios, partiu-se de premissas encontradas na literatura.

(Cybenko, 1989) demonstrou que uma RNA com três camadas é suficiente para aproximar qualquer função, isto é, elas são aproximadores universais de funções, logo limitou-se o número de camadas a três.

O número de neurônios foi definido com base no horizonte de previsão de vazões. Neste trabalho, buscou-se realizar a previsão de vazões 5 anos à frente, com discretização mensal. Portanto, optou-se por utilizar os 12 meses imediatamente anteriores ao período a ser previsto como dados de entrada, o que justifica o uso de 12 neurônios na camada de entrada. O número de neurônios na camada intermediária foi definido de modo a evitar o *overfitting*, que ocorre quando a rede neural "memoriza" o comportamento da série estudada o que compromete a sua capacidade de gerar novos resultados. De acordo com (Haykin et al., 2009), (Silva et al., 2010), (Cybenko, 1989), se o número de neurônios na camada de entrada é igual a N , então o número de neurônios na camada intermediária não deve ser superior a $2N + 1$ para que a rede generalize e não memorize.

A metodologia da RNA com atraso no tempo exige que os dados de entrada sejam manipulados de modo que seja possível estabelecer algo que se pareça com uma "janela deslizante". Isto funciona da seguinte maneira: os dados de entrada devem ser utilizados para gerar uma saída (um mês a frente, seguindo a ideia de simular um modelo auto-regressivo), sendo que nos passos seguintes, a nova saída deve ser incluída no conjunto de dados de entrada, enquanto que um dos dados utilizados no passo anterior deve ser descartado, de modo a manter o tamanho do vetor de entrada sempre igual a 12. Este processo é repetido até que se obtenha os 60 valores correspondentes ao horizonte de previsão desejado.

O que foi descrito no parágrafo anterior é a grande diferença entre uma RNA convencional e uma RNA com atraso no tempo. O algoritmo de treinamento utilizado foi o *Backpropagation*, que já foi exaustivamente descrito na literatura (Ballini, 2000), (Chakraborty et al., 2000). As taxas de aprendizagem e o termo momentum foram constantemente alteradas até que bons resultados

fossem obtidos. A qualidade dos resultados foi avaliada pelo critério de parada utilizado durante a fase de treinamento. Ao final de cada etapa do treinamento, era calculado um valor para o erro quadrático médio (eqm) (Silva et al., 2010). Assim, quando o eqm fosse inferior a $5 \cdot 10^{-6}$ o treinamento era encerrado, e os pesos sinápticos ajustados até aquele momento utilizados para gerar uma nova série de vazões.

3.2 Módulo 2 - Algoritmo Genético 1 (AG1)

Após obter as vazões afluentes naturais das usinas através do módulo 1, o módulo 2 será o responsável por determinar a operação ótima dos reservatórios das usinas hidroelétricas do sistema. A política operativa resultante estabelece que ao final do período de planejamento o volume final do reservatório de cada usina hidroelétrica do sistema esteja com seu valor máximo, portanto com sua energia armazenada máxima, de tal forma a minimizar o custo da operação do sistema ao longo do período de planejamento. O AG1 aplicado ao POSHP foi modelado da seguinte forma:

- **Codificação Genética:** utilizou-se como representação do cromossomo uma matriz bidimensional de dimensão 3×60 . As linhas representam a quantidade de usinas hidroelétricas do sistema hidroelétrico utilizado neste trabalho. Já as colunas representam a quantidade de intervalos do horizonte de planejamento de cinco anos (2010 a 2015), com discretização mensal. Sendo assim, cada gene do cromossomo representa o volume final da usina i , em um determinado intervalo do horizonte t . Os volumes das usinas foram normalizados entre 0 e 1, de modo que fiquem na mesma escala;
- **Tamanho da População:** conforme aponta (Leite et al., 2002), (Asano et al., n.d.), (Junior et al., n.d.), AGs com uma população de 24 indivíduos produzem resultados satisfatórios quando aplicados ao POSHP. Portanto, este trabalho considerou uma população de 24 indivíduos;
- **Avaliação:** como a otimização do POSHP visa a minimização do custo da operação do sistema hidrotérmico. Portanto, a Equação (1) foi utilizada como função de avaliação dos indivíduos da população.

$$C = r \cdot \sum_{t=1}^N \frac{[CT(t)]^2}{[t+1]^{\frac{1}{12}}} \quad (1)$$

Onde r corresponde ao fator de conversão monetária igual a 0,21 R\$/MW, i o período de planejamento atual e N o número de períodos do horizonte de planejamento. A demanda D do mercado de energia deve ser atendida

pela geração hidráulica GH e pela complementação térmica do sistema CT . Portanto CT pode ser representada por meio das seguintes equações:

$$CT(t) = D(t) - GH(t), \text{ se } D(t) \geq GH(t) \quad (2)$$

$$CT(t) = 0, \text{ se } D(t) \leq GH(t) \quad (3)$$

A geração hidráulica de cada usina é calculada com base nas características construtivas da usina, nos dados de vazão aflente natural fornecidos pelo módulo 1 e nos volumes que são otimizados pelo AG1. A geração hidráulica do sistema (GH) representa a soma da geração hidráulica das usinas hidroelétricas do sistema;

- **Método de Seleção:** a seleção dos indivíduos foi realizada utilizando o Método do Torneio;
- **Operador de Crossover:** utilizou-se o Crossover Uniforme para a recombinação dos pais com probabilidade de 90%;
- **Operador de de Mutação:** empregou-se a Mutação *Creep* com probabilidade de 1%;
- **Critério de Parada:** o critério de parada estabelecido foi o número máximo de gerações alcançadas pelo algoritmo, definido em 1 milhão.

Definidas as características do AG1, a próxima subseção irá descrever o AG2 aplicado ao mercado de comercialização de energia.

3.3 Módulo 3 - Algoritmo Genético 2 (AG2)

Com a disponibilização da geração hidroelétrica e garantindo que o gerador terá energia para entregar a longo prazo e com custo bastante uniforme sem pico momentâneos, o módulo AG2 tem como objetivo a geração de um vetor com uma solução para a compra de energia elétrica para os anos seguintes. Como otimização futura a utilização do Preço de Liquidação das Diferenças (PLD) e dados mais atualizados dos contratos existentes seriam necessários. A modelagem para este módulo foi definida da seguinte forma:

- **Codificação Genética:** utilizado um vetor com 14 posições, representando em cada posição a quantidade de energia a ser comprada no período do planejamento em que ocorreria um leilão. A Figura 2 exemplifica a codificação utilizada pelo AG2;

A primeira linha representa o ano de realização do leilão, a segunda linha o ano da entrega da energia, a terceira linha o tipo de leilão e a última o valor em média em MW a ser contratado.

| | | | | | | | | | | | | | |
|-------|------|------|-------|-------|------|------|------|------|--------|--------|--------|--------|--------|
| 2011 | 2011 | 2012 | 2013 | 2011 | 2012 | 2013 | 2014 | 2015 | 2011 | 2012 | 2013 | 2014 | 2015 |
| 2016 | 2016 | 2017 | 2018 | 2016 | 2017 | 2018 | 2019 | 2020 | 2016 | 2017 | 2018 | 2019 | 2020 |
| A-5 | A-3 | A-3 | A-3 | A-1 | A-1 | A-1 | A-1 | A-1 | Ajuste | Ajuste | Ajuste | Ajuste | Ajuste |
| 12.27 | 1.52 | 4.92 | 11.28 | 28.05 | 5.88 | 0.10 | 7.18 | 9.92 | 17.73 | 29.18 | 12.82 | 20.56 | 8.90 |

Figura 2: Codificação Genética utilizada pelo módulo 3 (AG2).

- **Tamanho da População:** 24 indivíduos, também seguindo conforme proposto por (Leite et al., 2002), (Asano et al., n.d.), (Junior et al., n.d.);
- **Avaliação:** utilizada como função objetivo a função de risco atendendo os limites de 4% máximo de repasse do cliente final;
- **Método de Seleção:** foi utilizado o Método da Roleta;
- **Crossover:** foi utilizado o Crossover Uniforme com taxa de 80,77%;
- **Mutação:** utilizou-se a Mutação Creep com taxa de 7%;
- **Critério de Parada:** Adotou-se como critério de parada o número máximo de gerações definido em 250000.

4 Resultados e Discussões

4.1 Condições de Operação

Os dados utilizados pela RNA foram coletados a partir do arquivo do deck de preços do sistema NEWAVE disponíveis no site da CCEE. Os dados foram extraídos do arquivo VAZOES.DAT, e armazenados em um banco de dados utilizando o sistema gerenciador de banco de dados MySQL. Logo a manipulação de dados foi facilitada pelo uso de expressões SQL. Finalmente, ficou definido que o treinamento da RNA seria realizado utilizando os dados dos anos de 1931 a 2009, enquanto que os dados do período 2010 a 2015 foram utilizados para teste.

Adotou-se o horizonte de planejamento de cinco anos, com discretização mensal para os módulos 1 e 2. Para o módulo 3 adotou-se a discretização anual, já que os tipos de leilão A-5, A-3, A-1 e Ajuste são referentes ao ano de disponibilização de energia (Ano A) menos a quantidade de anos em que o leilão será realizado. O mercado de energia elétrica foi mantido constante e igual a capacidade instalada do sistema hidroelétrico (5152 MW). O volume inicial utilizado no módulo 2 foi considerado como sendo igual ao volume máximo operativo de cada usina.

4.2 Resultados do Módulo 1 (RNA)

Ao encerrar o treinamento da RNA, os pesos ajustados naquela etapa foram utilizados para calcular o valor das vazões afluentes naturais para os próximos 5 anos a partir de 12 meses imediatamente anteriores, que neste caso eram correspondentes às vazões observadas no ano de 2009. Tais resultados podem ser melhor analisados a partir das Figuras 3, 4 e 5, que comparam os valores da série de vazões efetivamente observada e os valores da série de vazões calculadas pela RNA para o horizonte 2010 à 2015 para as usinas de Emborcação, Itumbiara e São Simão, respectivamente.

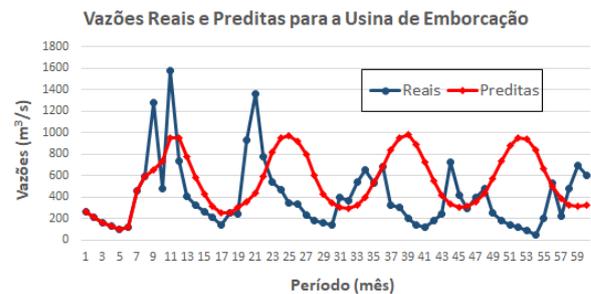


Figura 3: Comparativo entre as vazões reais e previstas pelo módulo 1 para a usina de Emborcação.

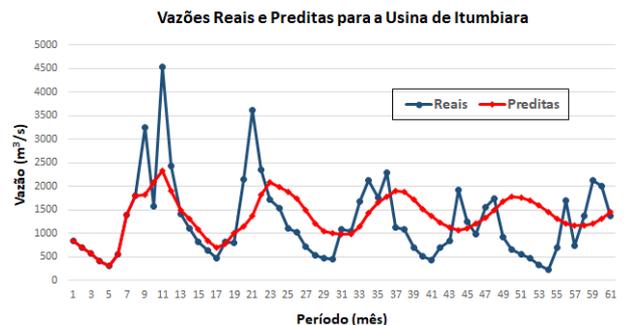


Figura 4: Comparativo entre as vazões reais e previstas pelo módulo 1 para a usina de Itumbiara.

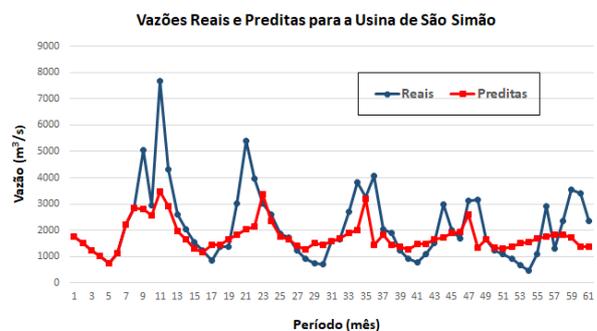


Figura 5: Comparativo entre as vazões reais e previstas pelo módulo 1 para a usina de São Simão.

Para as figuras acima foi calculada a métrica erro percentual médio (EPM) para cada uma. O

resultados, respeitando a ordem de disposição das figuras, foram 49.94; 31.96 e 26.29.

Pela análise das figuras, ainda é possível notar que os 12 primeiros valores previstos pela RNA possuíam melhor precisão do que os valores a partir do 13º mês, isto é, quanto mais distante no horizonte de previsão, menor era a precisão. Apesar disso, para a usina de São Simão é possível notar que o último ponto da série fora previsto com alta precisão. Na verdade, os resultados para São Simão foram excelentes quando comparados aos demais, tanto que é nítido como a RNA foi capaz de capturar a estocasticidade daquela série, principalmente, porque a RNA conseguiu capturar diversos detalhes do comportamento da série histórica, o que reforça o que já fora mostrado por (Cybenko, 1989).

Não obstante, é muito importante destacar que para os três casos (Emborcação, Itumbiara e São Simão), a mesma estrutura de RNA fora utilizada assim como o mesmo algoritmo de treinamento, sendo que apenas as taxas de aprendizado e termo momentum foram variadas. Além disso, os dados de treinamento para todos os casos foram extraídos do mesmo período (1931 a 2009), que a princípio não é uma ótima estratégia já que tais períodos deveriam ser selecionados de acordo com as características de cada aproveitamento. No entanto, focando no fato de que o conjunto de treinamento era distinto do conjunto posteriormente utilizado para testar a RNA, é claro perceber que não houve o problema de *overfitting*, que ocorreria caso a curva de resultados fosse exatamente igual à curva de dados observados. Somando todos estes fatos, é seguro afirmar que o algoritmo utilizado possui boa generalização, já que foi capaz de produzir resultados para três casos distintos.

4.3 Resultados do Módulo 2 (AG1)

Os estudos de caso realizados com mais de uma usina hidroelétrica em cascata evidenciam a alteração do comportamento dos reservatórios, em função do seu posicionamento relativo na cascata, devido a operação das outras usinas (Carvalho and Soares, 1987), (Cicogna, 2004).

A trajetória de volume resultante da otimização por meio do AG1, para três usinas hidroelétricas e considerando-se o período de 2010 a 2015, está apresentada na Figura 6. Através dos resultados obtidos pode-se notar a variação do volume dos reservatórios em função da posição da usina na cascata, principalmente nos três primeiros anos da otimização.

A usina de Emborcação, mais a montante na cascata, é responsável pela regulação das vazões afluentes, visando amenizar a sazonalidade das vazões e impedir vertimentos. Já a usina de Itumbiara, localizada no meio da cascata, possui oscilações mais amenas no volume do seu reservatório

do que a usina de Emborcação, entretanto apresenta oscilações mais severas quando comparada a usina de São Simão. A usina de São Simão é operada com seu reservatório no volume máximo durante quase todos os intervalos do período de planejamento. Esse fato se dá pois, a energia armazenada no sistema é valorizada pela produtividade das usinas mais a jusante. Assim, São Simão é operada com sua produtividade máxima, haja vista, que ela opera na maioria do período de planejamento a fio d'água com seu volume máximo. Tal fato corrobora com os resultados encontrados pelos autores (Rabêlo, 2010), (Antunes et al., 2014), (Rosenthal, 1981).

Nos dois últimos anos percebe-se que há um menor deplecionamento das usinas de Emborcação e Itumbiara. Este comportamento se dá devido às vazões afluentes naturais para todas as usinas do sistema serem baixas durante os 24 últimos meses. De modo que no final do período de planejamento os volumes operativos dos reservatórios estejam em seu volume máximo e a baixa condição hidrológica das vazões afluentes que chegam ao reservatório das usinas, nota-se um deplecionamento muito mais suave do que o que foi constatado nos três primeiros anos da otimização.

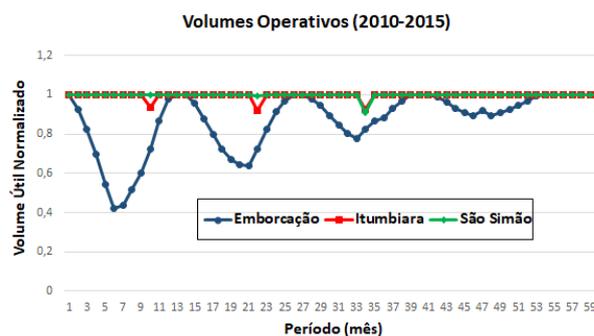


Figura 6: Trajetória do Volume das usinas hidroelétricas para o período de 2010-2015.

O deplecionamento mais acentuado para Emborcação e mais suave em Itumbiara, visto que a usina de Emborcação consegue regularizar parte da vazão afluente ao reservatório de Itumbiara, se dá devido ao efeito cota. Este efeito prioriza o enchimento imediato dos reservatórios, de forma que eles possam ser operados com produtividade máxima durante os intervalos restantes do horizonte de planejamento. Assim, verifica-se que o deplecionamento nos reservatórios mais a montante só é realizado para evitar vertimentos e regularizar as vazões afluentes, e que no final do período cheio, este reservatório recupera o seu nível máximo de armazenamento (Rabêlo et al., 2012).

4.4 Resultados do Módulo 3 (AG2)

De posse dos valores do módulo 2, nesta etapa foram simulados todos os leilões possíveis para se-

rem entregues até o ano de 2020.

O representante poderá comprar em:

- **1 (um) leilão de energia A-5:** em 2011 para ser entregue em 2016;
- **3 (três) leilões A-3:** nos anos de 2011, 2012, 2013 sendo que essa energia será entregue em 2016, 2017 e 2018 respectivamente;
- **Efetuar a compra em 5 (cinco) leilões de energia A - 1:** nos anos de 2011, 2012, 2013, 2014 e 2015 sendo que essa energia será entregue em 2016, 2017, 2018, 2019 e 2020 respectivamente;
- **Efetuar a compra em 5 (cinco) leilões de ajuste:** nos anos de 2011, 2012, 2013, 2014 e 2015 sendo que essa energia será entregue em 2016, 2017, 2018, 2019 e 2020 respectivamente.

Nesta simulação foram retornados os seguintes valores: 12.27; 1.52; 4.92; 11.28; 28.05; 5.88; 0.10; 7.18; 9.92; 17.73; 29.18; 12.82; 20.56; 8.90;

Com esses valores o gráfico de retorno para os leilões é demonstrado na Fig. 8.

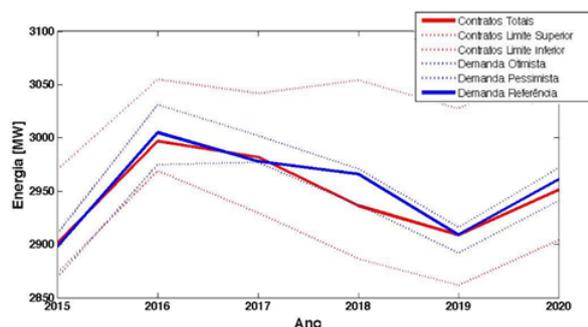


Figura 7: Resultado obtido para a compra em 14 leilões para os anos de 2010 a 2015.

Os valores a serem contratados caso ocorram cenários de sobre ou subcontratação são respectivamente 18.206 MW médios e 17.424 MW médios, correspondendo a 103,00% e 98,57% da Demanda do Cenário de Referência com valor de 17.676 MW médios. Como os valores de subcontratação e sobrecontratação estão com valores igual ou inferior a 3% não há riscos para a distribuidora pois até esse limite podem ser repassados a tarifa final. Isso foi possível devido a utilização de um número de 14 leilões em um período de 5 anos, pois com a presença de um número alto de leilões tendem a diminuir os riscos de subcontratação e sobrecontratação.

5 Conclusões

Este trabalho apresentou um modelo computacional aplicado na previsão de vazões afluentes naturais, na otimização do planejamento da operação

de sistemas hidrotérmicos de potência e na comercialização da energia produzida pelo sistema hidrotérmico. O sistema desenvolvido emprega duas técnicas de inteligência computacional, redes neurais artificiais e algoritmos genéticos, dividido por três módulos. No primeiro módulo, foi desenvolvido uma RNA para a previsão de vazões afluentes naturais. O módulo 2 aplicou um algoritmo genético (AG1) para, de posse das vazões afluentes naturais, determinar uma política de operação dos reservatórios das usinas hidroelétricas de modo a minimizar o custo operacional do sistema. O AG1 produz como resultado, a geração hidráulica do sistema para o horizonte de planejamento. Por fim o módulo 3 emprega um outro algoritmo genético (AG2) para que, de posse da geração hidráulica calculada no módulo 2, seja distribuída as cotas de energia que devem ser disponibilizadas entre os leilões para uma compra mais eficiente e com o menor risco possível.

Com relação ao módulo 1, a RNA utilizada para realizar a previsão de vazões apresentou boa capacidade de generalização, já que a mesma arquitetura de RNA foi capaz de prever as vazões afluentes naturais para três usinas hidroelétricas, que possuem regimes de vazão distintos ao longo do período estudado. O caso da usina de São Simão merece um destaque maior, já que a RNA foi capaz de capturar diversos detalhes da curva de séries de vazões, o que ocorreu com menor precisão para os casos das outras duas usinas hidroelétricas. Por fim, também notou-se que os 12 primeiros valores previstos pela RNA possuíam uma precisão maior quando comparados aos valores que iam além desse período, evidenciando que a incerteza aumenta quando se tenta realizar estimativas de longo prazo.

O AG1 implementado no módulo 2 mostraram resultados consistentes com a experiência operacional dos sistemas hidrotérmicos encontrada na literatura e mostraram a aplicabilidade do modelo proposto considerando um sistema hidroelétrico composto por 3 usinas hidroelétricas em cascata reais do Brasil. Ressalta-se ainda que os resultados evidenciaram a coerência das soluções obtidas pelo AG1, mostrando que a abordagem proposta buscou maximizar os benefícios hidroelétricos, quando possível, do sistema hidrotérmico de geração, considerando usinas individualizadas.

Por fim, o módulo 3 (AG2) mostrou que as simulações criadas e distribuídas em 14 leilões para compra de energia elétrica pelas distribuidoras de energia, com a utilização de um algoritmo genético, se obtém um retorno que permite diminuir os erros ao longo do tempo através de compras sem previsão e uso de dados pluviométricos que interferem no mercado. Outro fato observado é que o simulador sempre dará preferência a compra de energia nos leilões A - 5 sobre o leilão A - 3 já que seu preço é inferior, o que é vantajoso para a empresa e para

o país, uma vez que a viabilização do leilão A-5 sinaliza o desenvolvimento do país e a necessidade de aumentar a geração.

Agradecimentos

Os autores agradecem o apoio e o incentivo do CNPq, Chamada Universal 2016, processo 432423/2016-8.

Referências

- Antunes, F., de Alencar, T. R., Leite, P. T., Vitorri, K., Rabelo, R. d. A. L. and Toufen, D. L. (2014). Techniques of the optimization based in artificial intelligence applied to hydrothermal power systems operation planning, *IEEE Latin America Transactions* **12**(8): 1615–1624.
- Asano, P. T. L., de Alencar, T. R. and Carneiro, A. A. d. F. M. (n.d.). Ferramenta computacional baseada em algoritmos genéticos aplicada ao planejamento da operação de sistemas hidrotérmicos.
- Ballini, R. (2000). Análise e previsão de vazoes utilizando modelos de séries temporais, redes neurais artificiais e redes neurais nebulosas, *Análise e Previsão de Vazões Utilizando Modelos de Séries Temporais, Redes Neurais Artificiais e Redes Neurais Nebulosas*.
- Birol, F. (2017). Key world energy statistics.
- Carvalho, M. and Soares, S. (1987). An efficient hydrothermal scheduling algorithm, *IEEE Transactions on Power Systems* **2**(3): 537–542.
- Chakraborty, B., Kaustubha, R., Hegde, A., Pereira, A., Done, W., Kirilin, R., Moghadamjoo, A., Georgakis, A., Kotropoulos, C. and Xafopoulos, P. (2000). Bishop, cm, neural networks for pattern recognition, oxford university press, new york, 1995. carreira-perpiñán m., mode-finding for mixtures of gaussian distributions, *ieee transaction on pattern analysis and machine intelligence*, vol. 22, no. 11, november 2000, 1318-1323., *IEEE transaction on Pattern Analysis and Machine Intelligence* **22**(11): 1318–1323.
- Cicogna, M. A. (2004). Sistema de suporte à decisão para o planejamento e a programação da operação de sistemas de energia elétrica.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function, *Mathematics of control, signals and systems* **2**(4): 303–314.
- de Queiroz, A. R. (2016). Stochastic hydrothermal scheduling optimization: An overview, *Renewable and Sustainable Energy Reviews* **62**: 382–395.
- Dias, I. V. (2007). Estratégias de gestão de compra de energia elétrica para distribuidoras no brasil.
- Empresa de Pesquisa Energética, E. (2017). Balanço energético nacional: Relatório síntese, ano base 2016, *Retrieved December 7*: 2017.
- Goldberg, D. E. and Holland, J. H. (1988). Genetic algorithms and machine learning, *Machine learning* **3**(2): 95–99.
- Haykin, S. S., Haykin, S. S., Haykin, S. S. and Haykin, S. S. (2009). *Neural networks and learning machines*, Vol. 3, Pearson Upper Saddle River, NJ, USA:.
- Junior, J. G., de Alencar, T. R., Junior, R. F. O., Asano, P. T. L. and Vitorri, K. (n.d.). Sistema de suporte à decisão utilizando algoritmos genéticos voltado para sistemas hidrotérmicos.
- Leite, P. T., Carneiro, A. A. F. M. and Carvalho, A. (2002). Energetic operation planning using genetic algorithms, *IEEE Transactions on Power Systems* **17**(1): 173–179.
- Rabêlo, R. A., Fernandes, R. A. and Silva, I. N. (2012). Operational planning of hydrothermal systems based on a fuzzy-pso approach, *Evolutionary Computation (CEC), 2012 IEEE Congress on, IEEE*, pp. 1–8.
- Rabêlo, R. d. A. L. (2010). *Componentes de software no planejamento da operação energética de sistemas hidrotérmicos*, PhD thesis, Universidade de São Paulo.
- Rosenthal, R. E. (1981). A nonlinear network flow algorithm for maximization of benefits in a hydroelectric power system, *Operations research* **29**(4): 763–786.
- Silva, I. d., Spatti, D. H. and Flauzino, R. A. (2010). Redes neurais artificiais para engenharia e ciências aplicadas, *São Paulo: Artliber* pp. 33–111.