

# **Previsão de Vazões utilizando Redes Neurais Artificiais MLP e NSRBN**

**Alan Caio Rodrigues MARQUES<sup>1</sup>, Gelson da Cruz JUNIOR<sup>2</sup>, Cassio Dener Noronha VINHAL<sup>3</sup>**

Escola de Engenharia Elétrica e de Computação

<sup>1</sup>alancaiorm@gmail.com, <sup>2</sup>gcruz@eee.ufg.br, <sup>3</sup>cassio@eee.ufg.br

**Palavras-Chave:** Previsão de Vazões, Redes MLP, Redes NSRBN, Planejamento Hidrotérmico.

## **1 Introdução**

Devido ao aumento da população, crescimento do PIB, o avanço tecnológico, dentre outros fatores, o consumo de energia no Brasil tem crescido de forma acelerada. Para suprir o crescimento sem a instalação de novas usinas; principalmente as hidrelétricas, principal fonte de geração de energia no país, que têm recebido duras críticas devido ao impacto ambiental; deve-se realizar um melhor planejamento energético.

O planejamento da operação de sistemas hidrotérmicos pode ser traduzido como “a determinação de uma estratégia de geração que minimize o custo de operação em cada unidade do sistema durante o horizonte de planejamento”(1).

Entre as diversas variáveis envolvidas no planejamento, algumas apresentam caráter estocástico, sendo as mais representativas as vazões afluentes aos reservatórios das hidrelétricas, sendo estratégico conseguir uma estimativa destas vazões para determinar uma boa estratégia de produção de energia num horizonte futuro. Assim, modelos de previsão de vazões tornam-se essenciais no processo.

Este trabalho sugere a aplicação de métodos baseados em Redes Neurais Artificiais - RNAs para a previsão de vazões afluentes, e compara estes modelos com modelos utilizados pelo setor elétrico brasileiro.

## **2 Material e Métodos**

### **2.1. Metodologia**

O objetivo principal é a previsão de vazões futuras, através de RNAs, mais precisamente, Redes MLP e NSRBN. Para a construção dos modelos, será utilizado o conceito de orientação a objetos, com a implementação das redes em Java. Para a

análise dos resultados serão utilizados dados de postos reais, separando-se períodos específicos para treinamento, validação e teste das redes. Finaliza-se então o trabalho fazendo-se a avaliação dos resultados e analisando as possíveis aplicações do que se obteve.

## 2.2. Fundamentação Teórica

Sendo uma máquina baseada no cérebro humano, as Redes Neurais são compostas de vários neurônios artificiais, o que permite a aprendizagem, função apresentada por seu meio inspirador, o cérebro biológico.

Em (6), uma RNA é descrita, “como um sistema constituído por elementos de processamento interconectados, chamados de neurônios, os quais estão dispostos em camadas e são responsáveis pela não-linearidade e pela memória da rede”. Estes neurônios artificiais, que compõem a rede, são simplificados para sua compreensão na forma matemática.

As redes com aprendizagem supervisionada utilizam o conhecimento prévio do resultado desejado para poder calcular os pesos desejados, ou seja, utilizam conjuntos de entradas e respectivas respostas para estimar os valores de  $w_{ji}$ , através de seu treinamento.

A importância da representação do neurônio está relacionada à aprendizagem da rede, com a aprendizagem será possível prever os valores para as quais a rede está sendo treinada. O treinamento depende da forma utilizada de aprendizagem, podendo ser supervisionado ou não supervisionado. A primeira, através do resultado da entrada e da saída desejada, é possível, utilizando o erro, fazer os valores convergirem de acordo com a mudança dos pesos. Já na rede não-supervisionada, apenas dados de entrada são apresentados, e a semelhança dos dados criam agrupamentos, sendo necessário redundância de dados.

Treinar uma rede neural consiste em ajustar os pesos através de uma regra de aprendizagem até que esta forneça respostas satisfatórias ao problema analisado. No caso, até que um erro, entre a saída encontrada pela rede e a desejada, seja aceitável, ou esgote a quantidade de tentativas sugeridas para essa conversão.

A análise do erro é realizada ao final de um ciclo, sendo o ciclo composto pela passagem de todo o conjunto dos neurônios e suas camadas, apresentando o valor de saída.

Várias redes neurais são desenvolvidas com base nos conceitos apresentados anteriormente, sendo que dessas, a rede Multi Layer Perceptron - MLP e a rede construtiva - NSRBN serão implementadas e utilizadas neste trabalho.

### 2.2.1 Redes MLP

De acordo com Frank Rosenblatt (4), o modelo mais simples de Rede Neural, em que várias unidades de processamento estão conectadas unicamente a uma unidade de saída, através dos pesos sinápticos é a rede Perceptron. A utilização de várias camadas torna a rede mais complexa, só que também permite uma abordagem mais ampla. Vários trabalhos desenvolvidos fazem comparações entre implementações de redes MLP e modelos clássicos (6).

### 2.2.2 Redes NSRBN

Outro objetivo a ser alcançado neste trabalho é a implementação um modelo alternativo de redes neurais, através do uso de um algoritmo de abordagem construtiva, de tal forma que os usuários possam utilizar o modelo sem ter que se preocupar com a definição da arquitetura da rede neural, o que nem sempre é uma tarefa fácil. Estas redes são chamadas de redes com blocos de regressões sigmóides não-lineares (NSRBN) (2,3,5), as quais podem ser vistas como um aproximador universal de função e de arquitetura.

As redes NSRBN são eficientes, uma vez que elas utilizam blocos de sigmóides não-lineares como função de ativação. Este fato é contrário às redes neurais de alta ordem que tomam como base polinômios multivariados e apresentam uma explosão no número de parâmetros livres necessários para aproximar uma dada função.

A arquitetura de uma rede neural, de acordo com a possibilidade de mudanças no seu tamanho durante o processo de treinamento, pode ser classificada em estática ou dinâmica. Uma rede é dita de arquitetura estática quando o número de camadas e unidades de processamento permanecem constante desde a concepção da rede até a finalização do seu treinamento. Por outro lado, uma rede

de arquitetura dinâmica tem como característica principal um processo de mudanças no tamanho durante o treinamento.

Nessa nova classe de redes proposta, um algoritmo construtivo será utilizado para incrementar a estrutura da rede, partindo-se de uma pequena estrutura, até que se atinja uma estrutura de tamanho ótimo, segundo critérios estatísticos de seleção adequados.

A proposta do modelo NSRBN é de se construir a rede por blocos de polinômios homogêneos, utilizando uma função de ativação adequada (tangente hiperbólica, por exemplo), para os neurônios escondidos. Quanto aos neurônios de saída, estes têm uma ativação mais complexa, uma vez que realizam uma regressão logística não-linear com relação à saída dos neurônios escondidos.

### **3 Resultados e Discussão**

Até o presente momento, foi desenvolvido apenas o algoritmo MLP e, com a realização dos testes preliminares, foi possível observar sua eficiência. Em (6), uma comparação com vários modelos é realizada para o posto de Furnas, e mostra-se que, para o modelo PREVAZ, utilizado atualmente para a previsão realizada pelo ONS, para um período de 12 passos à frente, o erro percentual médio está em 30,19% e tem seu maior erro em 100,45%. Nos testes realizados pelo modelo MLP desenvolvido nesta pesquisa, o erro percentual médio ficou em 22,95%, com o maior erro de 61%, para o mesmo posto.

### **4 Conclusões**

É possível verificar, dessa forma, que o modelo proposto de rede neural, devido a sua característica de não-linearidade, apresenta melhor comportamento na previsão do que o modelo estatístico. Baseado nessa premissa, a utilização de redes neurais mostra-se viável, porém o trabalho ainda compreende a implementação dos outros modelos, em especial a rede NSRBN.

### **5 Referências Bibliográficas**

- [1] JÚNIOR, G. da C. Modelo Equivalente Não Linear para o Planejamento da Operação a Longo Prazo de Sistemas de Energia Elétrica. Campinas (SP): Universidade Estadual de Campinas, 1998.

- [2] VALENÇA, M. Aplicando Redes Neurais: um guia completo. 2a ed.. ed. Olinda, Pernambuco: Editora Livro Rápido, 2005.
- [3] VALENÇA, M. Fundamentos das Redes Neurais: exemplos em Java. Olinda, Pernambuco: Editora Livro Rápido, 2010
- [4] ROSENBLAT, F. Perceptron simulation experiments. Kolkata, India: Proceedings of the Inst. of radio Eng, 1960.
- [5] VALENÇA, M. Análise e Projeto de Redes Neurais com Abordagem Construtiva para Modelagem de Sistemas. Universidade Federal de Pernambuco: Tese de Doutorado em Ciência da Computação, Departamento de Informática, 1999
- [6] BALLINI, R. Análise e Previsão de Vazões Utilizando Modelos de Séries Temporais, Redes Neurais e Redes Neurais Nebulosas. Universidade Estadual de Campinas: Tese de Doutorado em Engenharia Elétrica, Faculdade de Engenharia Elétrica e de Computação, 2000.