



# **ANÁLISE DE UMA METODOLOGIA PARA CORREÇÃO DO ERRO DE FASE EM PREVISÃO DE VAZÕES**

**Trabalho de Conclusão de Curso**

**Engenharia da Computação**

**Cristiano Reis da Silva Moura**  
**Orientador: Mêuser Jorge Silva Valença**



**Universidade de Pernambuco  
Escola Politécnica de Pernambuco  
Graduação em Engenharia de Computação**

**CRISTIANO REIS DA SILVA MOURA**

**ANÁLISE DE UMA METODOLOGIA  
PARA CORREÇÃO DO ERRO DE FASE  
EM PREVISÃO DE VAZÕES**

Monografia apresentada como requisito parcial para obtenção do diploma de Bacharel em Engenharia de Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

**Recife, junho de 2012.**

## MONOGRAFIA DE FINAL DE CURSO

### Avaliação Final (para o presidente da banca)\*

No dia 19 de 6 de 2012, às 8:00 horas, reuniu-se para deliberar a defesa da monografia de conclusão de curso do discente CRISTIANO REIS DA SILVA MOURA, orientado pelo professor Mêuser Jorge Silva Valença, sob título Análise de uma metodologia para correção de erro de fase em previsão de vazões, a banca composta pelos professores:

**Sérgio Murilo Maciel Fernandes**

**Mêuser Jorge Silva Valença**

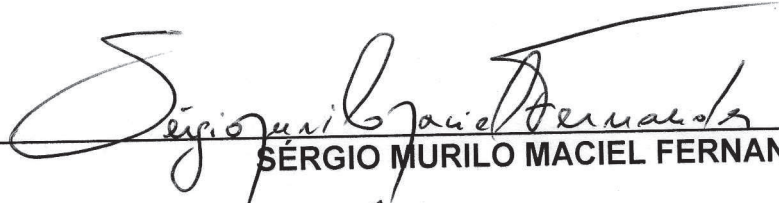
Após a apresentação da monografia e discussão entre os membros da Banca, a mesma foi considerada:


Aprovada       Aprovada com Restrições\*       Reprovada

e foi-lhe atribuída nota: 8,5 ( Oito, cinco )

\*(Obrigatório o preenchimento do campo abaixo com comentários para o autor)

O discente terá 03 dias para entrega da versão final da monografia a contar da data deste documento.

  
\_\_\_\_\_  
**SÉRGIO MURILO MACIEL FERNANDES**

  
\_\_\_\_\_  
**MÊUSER JORGE SILVA VALENÇA**

\_\_\_\_\_

*Dedico este trabalho à minha família e a todos que, de alguma forma, me ajudaram durante esses anos de curso.*

# Agradecimentos

A meus pais, Hugo e Claudia, por nunca deixarem de acreditar em mim, sempre me dando apoio. Obrigado por terem me ajudado a ser quem sou hoje.

Aos meus irmãos, Cássio e Caio, pela compreensão e paciência com o irmão mais velho tendo que pedir silêncio a eles para estudar.

A todos os outros parentes, pelo apoio e força mandados, mesmo que de longe.

A todos os meus amigos – tantos os dentro da Poli quanto os de fora –, pelo apoio e pelos momentos de folga da faculdade, o que foi importantíssimo para não haver a vitória do estresse sobre mim – não cito nomes para não cometer a injustiça de esquecer alguém.

A meu professor orientador Mêuser Valença, não só pela orientação, mas principalmente por ter-me dado bastante estímulo para continuar nessa árdua jornada.

A todos os professores do antigo DSC, atual eComp, que passaram pela minha vida universitária.

Ao pessoal da Subsecretaria de Tecnologia da Informação, no Tribunal Federal Regional da 5ª Região, onde cumpri meu estágio obrigatório, pelo apoio, auxílio e compreensão – principalmente pela compreensão, pois não teria terminado a monografia sem isto.

E a Deus, por ter dado a mim a oportunidade de conviver com tantas pessoas importantes.

# Resumo

O sistema brasileiro de geração de energia elétrica é composto quase totalmente por usinas hidrelétricas (cerca de 90%), além de usinas termelétricas de complementação. Para um melhor aproveitamento da energia elétrica gerada pelas hidrelétricas, evitando ao máximo o uso das termelétricas, as quais são altamente danosas ao ecossistema, devido à necessidade da queima de combustível fóssil, é preciso recorrer a algum método que maximize a produção de eletricidade vinda das hidrelétricas, o que é possível por meio das previsões de vazões fluviais. Redes Neurais Artificiais são bastante úteis para realizar tais previsões, mas não são suficientes para evitar o surgimento do erro de fase. Este trabalho objetiva testar um método que possa minimizar o erro de fase, de modo que a previsão feita seja mais precisa. Os resultados dos experimentos não se mostraram totalmente satisfatórios, comprovando que a correção do erro de fase não é eficaz pelo método apresentado em todas as usinas hidrelétricas.

Palavras-chave: previsão de vazões fluviais, redes neurais artificiais, ELM, usinas hidrelétricas

# Abstract

The electric generate Brazilian system is almost totally constituted by hydroelectric power plants (about 90%), besides thermoelectric complementation. For best hydroelectric power utilization, and, consequently, avoiding almost completely the thermoelectric power use, that is highly hurtful to ecosystem, because fossil fuel burning is needed, it must resort to methods that maximize hydroelectric generated power production, which is possible by means of river flow forecasts. Artificial Neural Networks are very useful to do these forecasts, but they aren't good enough to avoid the model bias appearance. This work aims to test a method which can minimize the model bias, so that the forecast be more accurate. The experiments' results weren't very satisfying, proving the model bias correction isn't effective in every power plant using the method presented here.

Keywords: river flow forecasts, artificial neural networks, ELM, hydroelectric power plants

# Sumário

<b>Capítulo 1 Introdução</b>	<b>1</b>
1.1 Motivação e Problema.....	1
1.2 Objetivos .....	2
1.2.1 Objetivo geral .....	2
1.2.2 Objetivos específicos.....	2
1.3 Estrutura da monografia .....	2
<b>Capítulo 2 Previsão de Vazões no Planejamento Energético</b>	<b>3</b>
2.1 Planejamento energético no Brasil.....	3
2.1.1 Planejamento de médio prazo .....	4
2.1.2 Planejamento de curto prazo.....	4
2.1.3 Planejamento de programação diária.....	4
2.2 Erro de fase.....	4
<b>Capítulo 3 O Uso do Algoritmo <i>Extreme Learning Machine</i> em RNAs</b>	<b>6</b>
3.1 Redes Neurais Artificiais .....	6
3.1.1 Neurônio biológico.....	7
3.1.2 Neurônio artificial.....	8
3.2 <i>Extreme Learning Machine</i> .....	9
3.2.1 Treinamento em ELM.....	11
<b>Capítulo 4 Experimentos Realizados</b>	<b>15</b>
4.1 Bases de dados.....	15
4.2 Preprocessamento dos dados .....	17
4.3 Previsão de vazões diárias utilizando RNA do tipo SLFN .....	18
4.3.1 Correção do erro de fase.....	20
4.4 Resultados.....	22



4.4.1	Métricas de desempenho das previsões .....	22
4.4.2	UHE Furnas .....	24
4.4.3	UHE Salto Santiago.....	25
4.4.4	UHE Três Marias .....	26
4.4.5	UHE Tucuruí .....	27
4.5	Considerações finais sobre os experimentos .....	28
<b>Capítulo 5 Conclusão e Trabalhos Futuros</b>		<b>29</b>
<b>Bibliografia</b>		<b>31</b>

# Índice de Figuras

<b>Figura 1.</b>	Comparação entre vazões ocorridas e previstas.....	5
<b>Figura 2.</b>	O neurônio biológico.....	7
<b>Figura 3.</b>	Modelo matemático de um neurônio artificial .....	8
<b>Figura 4.</b>	Arquitetura neural SLFN.....	10
<b>Figura 5.</b>	Ponto de parada na validação cruzada .....	13
<b>Figura 6.</b>	Usina hidrelétrica de Furnas.....	15
<b>Figura 7.</b>	Usina hidrelétrica de Salto Santiago.....	16
<b>Figura 8.</b>	Usina hidrelétrica de Três Marias .....	16
<b>Figura 9.</b>	Usina hidrelétrica de Tucuruí.....	17
<b>Figura 10.</b>	O NeuroHidro .....	19
<b>Figura 11.</b>	Arquitetura da SLFN utilizada nos experimentos (etapa antes da correção do erro de fase) .....	20

# Índice de Tabelas

<b>Tabela 1.</b>	Amostra de vazões da UHE Furnas.....	17
<b>Tabela 2.</b>	Amostra dos dados da UHE Furnas após o pré-processamento.....	18
<b>Tabela 3.</b>	Amostra dos dados a serem utilizados como entrada na correção (UHE Furnas) .....	21
<b>Tabela 4.</b>	Resultado dos experimentos relativos à UHE Furnas .....	24
<b>Tabela 5.</b>	Intervalos de confiança para as métricas escolhidas em Furnas .....	24
<b>Tabela 6.</b>	Resultado dos experimentos relativos à UHE Salto Santiago .....	25
<b>Tabela 7.</b>	Intervalos de confiança para as métricas escolhidas em Salto Santiago . .....	25
<b>Tabela 8.</b>	Resultado dos experimentos relativos à UHE Três Marias .....	26
<b>Tabela 9.</b>	Intervalos de confiança para as métricas escolhidas em Três Marias..	26
<b>Tabela 10.</b>	Resultado dos experimentos relativos à UHE Tucuruí .....	27
<b>Tabela 11.</b>	Intervalos de confiança para as métricas escolhidas em Tucuruí .....	27

# Tabela de Símbolos e Siglas

CEPEL – Centro de Pesquisas de Energia Elétrica

ELM – *Extreme Learning Machine*

EMA – Erro Médio Absoluto

EPMA – Erro Percentual Médio Absoluto

EQMM – Erro Quadrado Médio Mínimo

MLP – *Multi-layer Perceptron*

NASH – Coeficiente de Nash-Sutcliffe

NSRBN – *Non-linear Sigmoidal Regression Blocks Network*

ONS – Operador Nacional do Setor Elétrico

PMO – Programa Mensal de Operação

REQM – Raiz do Erro Quadrático Médio

RNA – Rede Neural Artificial

SIN – Sistema Integrado Nacional

SLFN – *Single-hidden Layer Feedforward Neural Network*

UHE – Usina Hidrelétrica

# Capítulo 1

## Introdução

Este capítulo mostra uma breve visão do que motivou a escrita desta monografia, além de seus objetivos e como ela se estrutura.

### 1.1 Motivação e Problema

Ao contrário da maioria dos países do mundo, o Brasil tem a maior parte de sua energia elétrica gerada por usinas hidrelétricas, as quais estão distribuídas por 12 bacias hidrográficas espalhadas pelo país. Tais usinas acabam sendo responsáveis por mais de 90% da geração da eletricidade que é consumida no Brasil [4].

Essas usinas têm como “matéria-prima” da eletricidade gerada por elas a vazão dos rios nos quais são construídas. Para um melhor planejamento da produção de energia elétrica (ou para uma melhor elaboração na construção das barragens – “qual a capacidade suportada por estas?”), faz-se necessário elaborar modelos hidrológicos, os quais são utilizados para que se tentem prever as vazões futuras desses rios a partir de complexos cálculos matemáticos, que tem como dados de entrada vazões anteriores já monitoradas e, em alguns casos, medições de precipitações pluviométricas. Tudo isto é preciso por conta da inconstância das vazões fluviais – inconstância esta que acaba dificultando a elaboração do PMO (Programação Mensal de Operação), o qual nada mais é do que um documento que serve de “referência técnica mensal, com revisão semanal, para a as metas de geração de todas as usinas hidrelétricas e termelétricas integrantes do SIN [Sistema Integrado Nacional]” [4].

Uma solução para tal problema é o uso de métodos de previsão de vazão, seja utilizando estatística, seja por meio do uso de outras técnicas, como as Redes Neurais Artificiais. Contudo, muitas vezes esta solução por si só não se mostra adequada por conta do chamado *erro de fase* (em inglês, *bias*): um modelo hidrológico pode superestimar vazões em condições normais, ou subestimar vazões

em períodos de tempestade, por exemplo [11]; tudo isto pode deixar os resultados da previsão bastante imprecisos, tornando de extrema importância, pois, a remoção do erro de fase.

## 1.2 Objetivos

### 1.2.1 Objetivo geral

- Definir se o uso de Redes Neurais Artificiais se mostra benéfico à redução da tendência em modelos de previsão, e o que isso pode melhorar no Setor Elétrico.

### 1.2.2 Objetivos específicos

- Realizar a simulação de uma rede neural que utilize o algoritmo *Extreme Learning Machine* (ELM) [14,15] na previsão de vazão.
- Realizar simulações em pelo menos 4 bases de dados para 7 dias à frente, cada uma representando uma das regiões hidrográficas do Brasil (N, NE, S, SE).
- Testar uma metodologia para correção do erro de fase das previsões realizadas com o algoritmo ELM.

## 1.3 Estrutura da monografia

O Capítulo 2 trata de previsões de vazões, o seu uso no Brasil e o problema do erro de fase. A seguir, o Capítulo 3 mostra os conceitos de Redes Neurais Artificiais, falando tanto de sua unidade fundamental – o neurônio – quanto de conceitos utilizados em redes mais complexas, dando ênfase na SLFN, arquitetura neural utilizada neste trabalho, e em seu algoritmo de treinamento, o ELM. Logo em seguida, são mostrados no Capítulo 4 os experimentos realizados e os resultados obtidos, além da análise de tais resultados. Por fim, o Capítulo 5 analisa o trabalho como um todo, concluindo-o e destacando possíveis trabalhos futuros.

## Capítulo 2

# Previsão de Vazões no Planejamento Energético

O presente capítulo trata brevemente de como é feito o planejamento energético no Brasil, explicando alguns conceitos e modelos utilizados no Sistema Hidrotérmico Interligado Brasileiro (também conhecido como Sistema Integrado Nacional – SIN). Além disso, focaliza a importância da correção do erro de fase.

### 2.1 Planejamento energético no Brasil

Como dito no Capítulo anterior, cerca de 90% da energia elétrica gerada no Brasil vem de usinas hidrelétricas embora existam outros tipos de usinas geradoras de eletricidade, como as termelétricas, que servem para complementação. Como as termelétricas consomem bastante combustível fóssil, o planejamento da geração de energia se faz extremamente importante, de modo que o aproveitamento das usinas hidrelétricas seja maximizado e o uso das usinas de complementação seja o menor possível.

Para isso, o Operador Nacional do Setor Elétrico (ONS) tem o Programa Mensal de Operações (PMO), o qual “se constitui na referência técnica mensal para definição das metas de todas as usinas hidrelétricas, termelétricas e nucleares integrantes do SIN” [8], sendo essas metas estabelecidas através de procedimentos próprios do ONS.

O planejamento da operação, por conta de sua complexidade, é feito atualmente por etapas, sendo auxiliado pela cadeia de modelos desenvolvidos no Centro de Pesquisas de Energia Elétrica (CEPEL) [19]. Cada etapa é auxiliada por modelos designados para um horizonte de planejamento específico, os quais podem ser classificadas como de médio prazo, de curto prazo e de programação diária.

### **2.1.1 Planejamento de médio prazo**

A ideia do planejamento de médio prazo é construir uma política que deverá vir a ser utilizada ao início de cada mês; esta política decide quanto será atendido da demanda de energia do mês seguinte, seja de origem hidráulica, seja vinda de termelétricas. O modelo hidrológico utilizado para este planejamento é o GEVAZP [17, 20]. O horizonte de planejamento pode ser de até 10 anos, mas em geral são considerados apenas os 12 primeiros meses.

### **2.1.2 Planejamento de curto prazo**

Neste planejamento, os blocos de geração hidráulico e térmico definidos pela política de curto prazo são divididos em metas semanais de geração para cada usina do SIN. Para cada semana do mês as afluições são previstas utilizando o modelo hidrológico PREVIVAZM [2]. Para os demais meses do horizonte do ano, utiliza-se o GEVAZP. Pode-se planejar até 1 ano à frente, mas normalmente são considerados apenas 2 meses.

### **2.1.3 Planejamento de programação diária**

Na programação diária, a hidrologia é feita através da previsão de vazões diárias para um horizonte de 7 a 14 dias. O modelo hidrológico usado é o PREVIVAZH, que considera tanto fatores externos (chuvas, por exemplo) quanto internos (vazões anteriores) [3].

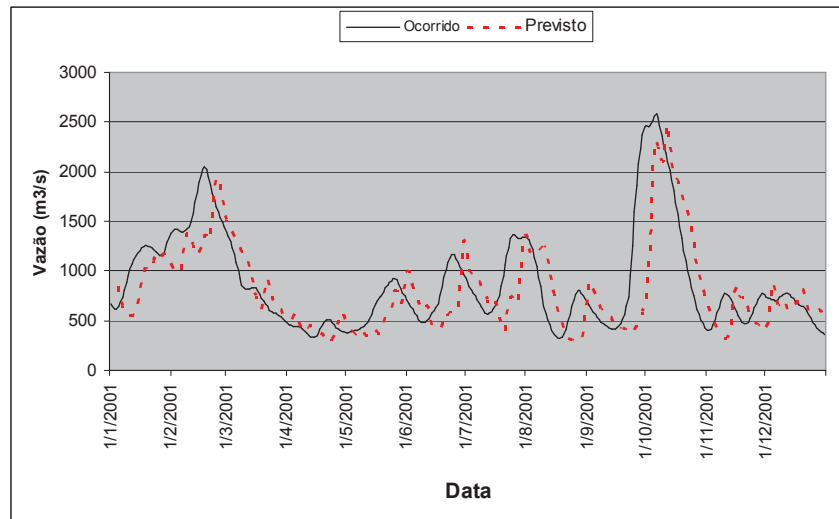
## **2.2 Erro de fase**

A previsão de vazões fluviais se mostra extremamente importante, mas há um fator que afeta sua qualidade: o erro de fase. Por causa de um erro de fase gerado por um modelo hidrológico qualquer, máximos locais de vazão podem ser subestimados, e mínimos locais podem ser superestimados; além disto, as previsões podem apresentar atraso em relação ao tempo, como pode ser visto na Figura 1.

O erro de fase tem como causa principal o uso de valores de vazão passados como entrada para o modelo utilizado na previsão. Tais valores tendem a dominar as entradas de tal forma “que os valores previstos sofrem forte influência dos valores



mais recentes a tal ponto destas serem responsáveis pelas previsões defasadas” [27].



**Figura 1.** Comparação entre vazões ocorridas e previstas [27]

É importante evitar o erro de fase na previsão, pois tal erro tende a se propagar por todo o conjunto de dados e afetar a qualidade do modelo de previsão. Algumas técnicas para diminuir o erro, ou até mesmo eliminá-lo, têm sido estudadas [11] e se mostrado eficientes, podendo ser utilizadas.

# Capítulo 3

## O Uso do Algoritmo *Extreme Learning Machine* em RNAs

Este capítulo trata inicialmente de como funcionam as Redes Neurais Artificiais. Em seguida, é explicado o funcionamento do algoritmo ELM.

### 3.1 Redes Neurais Artificiais

O uso de Redes Neurais Artificiais (RNAs) – também conhecidas simplesmente como Redes Neurais – é uma técnica que usa modelos desenvolvidos nos últimos anos e têm como metáfora o funcionamento do cérebro humano com suas redes neurais biológicas. Também se pode definir uma RNA 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” [25].


A utilização dessa técnica se mostra bastante interessante por ela ter como principais características [26]:

- Não-linearidade: permite a resolução de problemas que não são linearmente separáveis;
- Adaptatividade: pode reaprender de forma a se adequar a um novo conjunto de exemplos;
- Aprendizagem: extrai o conhecimento por meio de exemplos;
- Modelagem de sistemas complexos: pode trabalhar com uma grande quantidade e diversidade de dados;
- Processamento paralelo: recebe várias informações e testa todas as possibilidades ao mesmo tempo;

- Tolerância a falhas: mesmo que alguns neurônios sejam perdidos, a rede continua tendo um desempenho satisfatório; e
- Capacidade de generalização: ao receber um novo conjunto de exemplos, fornece uma resposta satisfatória.

### 3.1.1 Neurônio biológico

O neurônio biológico é a unidade mais básica do sistema nervoso humano. Ele é composto, como pode ser visto na Figura 2, por um corpo celular do qual saem ramificações denominadas dendritos e um prolongamento chamado de axônio, cujos terminais são denominados telodendros.



**Figura 2.** O neurônio biológico (fonte: <http://www.sogab.com.br/anatomia/sistemanervosojonas.htm>)

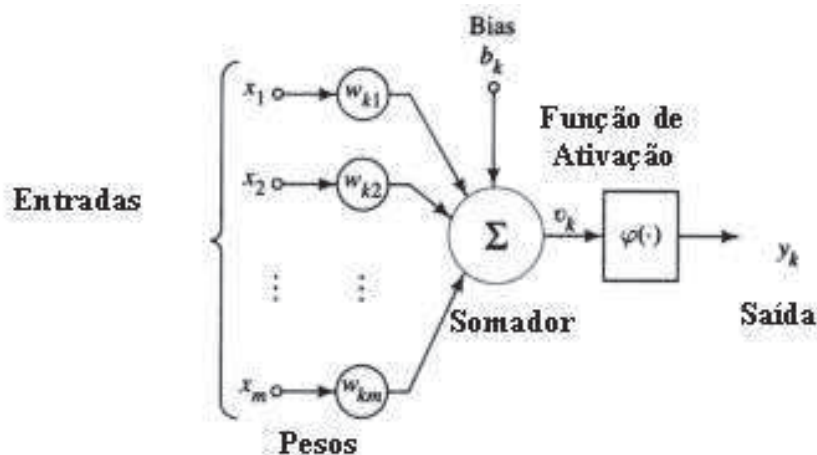
A transmissão de um impulso nervoso de um neurônio para outro se dá através das conexões sinápticas existentes entre os dendritos de um neurônio e os telodendros da célula nervosa seguinte.

O funcionamento de um neurônio se baseia na “Lei do Tudo ou Nada”, a qual está relacionada com a intensidade do estímulo a partir do qual um neurônio dispara ou não o impulso nervoso. Caso o estímulo seja muito pequeno, sua intensidade acaba por ser inferior ao limiar excitatório da célula nervosa, fazendo com que não aconteça nenhum impulso nervoso; porém, caso o limiar excitatório seja ultrapassado pela intensidade do estímulo, há a ocorrência do impulso nervoso, o qual será o mesmo, independentemente de quão intenso foi o tal estímulo.

### 3.1.2 Neurônio artificial

A primeira vez em que foi proposto um modelo matemático que representasse um neurônio biológico ocorreu em 1943 [21]. Tal modelo, proposto por McCulloch e Pitts, busca representar de maneira bastante simples, o neurônio biológico; esse neurônio artificial é formado por um conjunto de entradas (representando os dendritos), uma unidade de processamento (a qual é análoga ao corpo celular) e uma ou mais saídas (correspondentes aos telodendros do axônio) [1].

Para simular o funcionamento do neurônio biológico, o neurônio artificial utiliza uma regra de propagação e uma função de ativação; a emissão de um sinal por este neurônio baseia-se em um limiar análogo a Lei do Tudo ou Nada [24].



**Figura 3.** Modelo matemático de um neurônio artificial (fonte: [http://www.gsigma.ufsc.br/~popov/aulas/rna/neuronio\\_artificial/index.html](http://www.gsigma.ufsc.br/~popov/aulas/rna/neuronio_artificial/index.html))

A figura anterior mostra que as entradas do neurônio artificial ( $x_0, x_1, x_2, \dots, x_n$ ) são formadas por números. Cada entrada é multiplicada por um peso, o qual representa o nível de relevância da entrada para o neurônio (nota-se que o valor de  $x_0$  é predefinido; quando  $x_0$  é multiplicado por seu respectivo peso, tem-se o valor do limiar excitatório [25]). Os produtos gerados são somados ( $net$ ), e o resultado desta soma é usado como parâmetro pela função de ativação  $f(net)$ , a qual retorna o valor da saída do neurônio ( $y$ ). As equações abaixo representam, respectivamente, o valor de  $net$ , a função de ativação usada na arquitetura neural *Perceptron* (rede que lida apenas com saídas discretas – 0 ou 1), e a usada na arquitetura *Adaline* (rede que permite respostas contínuas) [24].

$$net_i = \sum_{i=0}^n x_i w_i \quad (3.1)$$

$$y_i = f(net_i) = \begin{cases} 1, & \text{se } net_i \geq 0 \\ 0, & \text{se } net_i < 0 \end{cases} \quad (3.2)$$

$$y_i = f(net_i) = \frac{1}{1+e^{-net_i}} \quad (3.3)$$

Assim como o sistema nervoso biológico, uma RNA é formada por vários neurônios, sendo os pesos ajustados com o tempo (ou não), de acordo com o algoritmo presente na arquitetura neural da RNA em questão. Há inúmeras arquiteturas neurais diferentes, como as anteriormente citadas *Perceptron* e *Adaline*, além de várias outras, como a MLP (sigla para *Multi-layer Perceptron* – em português, “Perceptron com múltiplas camadas”) [24], a NSRBN (sigla para *Non-linear Sigmoidal Regression Blocks Network* – em português, “rede com blocos de regressão sigmóides não-lineares”) [28], e a Kohonen [16].


## 3.2 Extreme Learning Machine

Muitos algoritmos de treinamento presentes em RNAs baseiam-se no método do gradiente descendente, no qual “o ajuste dos pesos deve ser proporcional ao sentido contrário da função erro com relação aos pesos” [24]. Apesar de estes algoritmos terem sido bastante utilizados, eles são, em geral, lentos, além de convergirem facilmente para mínimos locais. O treinamento iterativo da rede faz com

que tal rede demore mais tempo para ser treinada; além disso, algoritmos tradicionais de treinamento, como é o caso do *backpropagation*, fazem com que todos os parâmetros da rede sejam atualizados durante todos os passos da sua aprendizagem.

Para que esses problemas fossem diminuídos, foi criado o algoritmo *Extreme Learning Machine* (em português, “Máquina de Aprendizado Extremo”). Tal algoritmo tem como objetivo prover um melhor desempenho de generalização num tempo de aprendizagem extremamente rápido [14].

O ELM é aplicado em redes cujas estruturas se assemelhem a uma MLP, contanto que só haja uma camada escondida; a esta estrutura de RNA se dá o nome de SLFN (sigla para *Single-hidden Layer Feedforward Neural Network* – em português, “rede neural *feedforward*<sup>1</sup> com camada escondida única”). Dessa forma, a rede tem 3 camadas de neurônios: a camada de entrada, a camada escondida e a camada de saída. A atribuição dos pesos de entrada e do limiar da camada escondida é feita de maneira aleatória (e tais valores não mudam durante a fase de treinamento), enquanto os pesos de saída são determinados analiticamente [15] e o algoritmo de aprendizagem é baseado em operações matriciais.



**Figura 4.** Arquitetura neural SLFN (fonte:

<http://jis.eurasipjournals.com/content/2009/1/901381/figure/F4>)

---

<sup>1</sup> Uma rede neural *feedforward* é uma RNA na qual as conexões entre os neurônios são unidirecionais e não formam um ciclo direto.

### 3.2.1 Treinamento em ELM

Dadas  $n$  amostras de treinamento  $(x_i, d_i)$ , onde  $x_i = [x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}] \in \mathbb{R}^n$  e  $d_i = [d_{i1}, d_{i2}, d_{i3}, \dots, d_{in}] \in \mathbb{R}^n$ , uma RNA com uma camada escondida e os  $N$  neurônios na camada escondida podem ser representados da seguinte forma:

$$\sum_{i=1}^{\tilde{N}} \beta_i g_i(x_j) = \sum_{i=1}^{\tilde{N}} \beta_i g(w_i x_j + b_i) = y_j ,$$

onde:

- $j = 1, 2, \dots, N$ ;
- $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$  é o vetor de peso que conecta os neurônios de entrada com o  $i$ -ésimo neurônio escondido;
- $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{in}]^T$  é o vetor de peso que conecta o  $i$ -ésimo neurônio escondido com os neurônios de saída;
- $b_i$  é o limiar do  $i$ -ésimo neurônio escondido;
- $g(x)$  é a função sigmoide,  $g(x) = \frac{1}{1+e^{-x}}$ ;
- $y_j$  é a saída calculada da rede, e
- $w_i x_j$  é o produto interno entre os vetores  $w_i$  e  $x_j$ .

Para que as saídas da rede ( $y_j$ ) tenham uma relação de igualdade com os resultados esperados ( $t_j$ ), é preciso que existam  $\beta_i$ ,  $w_i$  e  $b_i$  de modo que a equação seja escrita dessa forma:

$$\sum_{i=1}^{\tilde{N}} \beta_i g_i(x_j) = \sum_{i=1}^{\tilde{N}} \beta_i g(w_i x_j + b_i) = t_j .$$

Enquanto nos algoritmos tradicionais a otimização da diferença entre a saída calculada e a desejada é feita otimizando os pesos de entrada, os pesos de saída e os limiares, o ELM faz a otimização de maneira bastante diferente. Em primeiro lugar, as escolhas dos pesos de entrada e dos limiares são feitas arbitrariamente e

tais valores permanecem inalterados, ao contrário do que acontecia, por exemplo, no *backpropagation*, no qual os valores eram ajustados a cada iteração do algoritmo.

Feita a atribuição, o algoritmo de treinamento calcula, por meio do método dos quadrados mínimos, a solução  $B$  do sistema linear  $H\beta=T$  (este sistema representando as duas últimas equações citadas), sendo:

$$H = \begin{bmatrix} g(w_1x_1 + b_1) & \cdots & g(w_{\tilde{N}}x_1 + b_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ g(w_1x_N + b_1) & \cdots & g(w_{\tilde{N}}x_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}}, \quad (3.6)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m}, \quad (3.7)$$

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m}. \quad (3.8)$$

A solução de norma mais baixa para o sistema linear em questão, pelo método dos quadrados mínimos, é dada por:

$$B = H^+T, \quad (3.9)$$

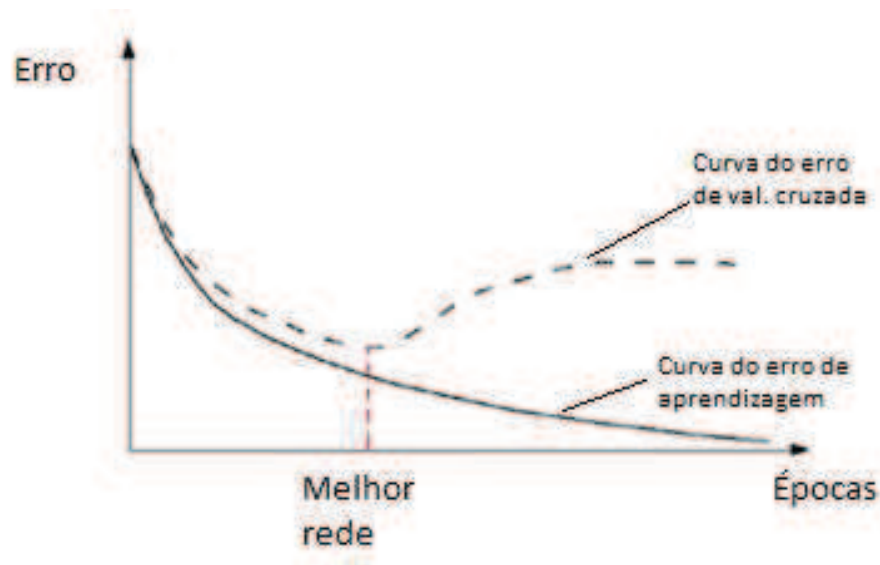
onde  $H^+$  é a matriz inversa generalizada de Moore-Penrose [22] da matriz  $H$ . Com isso, o ELM é capaz de lidar analiticamente com o processo de treinamento como se resolvesse um sistema não-linear. Ao solucionar o sistema, os pesos da saída são determinados através do cálculo da matriz inversa generalizada da matriz de saída da camada escondida.

Para que uma RNA funcione de maneira satisfatória, é preciso que haja uma condição de parada. A finalidade da condição de parada é fazer a rede neural parar de ajustar os pesos no momento adequado, de forma que não haja um superajustamento dos pesos, o que causaria uma memorização por parte dessa rede neural, ao invés de um aprendizado.



O critério de parada utilizado no *Extreme Learning Machine* é a validação cruzada [15]. Este critério divide o conjunto de padrões em três partes: a primeira corresponde ao treinamento, a segunda à validação e a terceira aos testes, sendo esta última parte a única a não sofrer normalização dos dados (o conceito de normalização será explicado no Capítulo 4). O conjunto de treinamento é aquele no qual os pesos da rede são corrigidos de acordo com o algoritmo de treinamento – no caso, o ELM. Depois de cada iteração, a rede treinada é testada com o conjunto de validação cruzada. Dessa forma, enquanto houver queda no erro de validação cruzada, a rede continua sendo generalizada.

A partir do momento no qual houver seguidos aumentos no erro de validação cruzada, ao mesmo tempo em que houver um decréscimo no erro de treinamento, sinaliza-se uma possível memorização dos padrões de treinamento por parte da rede neural. É nesse momento que deve haver uma interrupção no treinamento. Com isso, têm-se os pesos ótimos da RNA, os quais serão usados para testá-la, por meio do conjunto de testes.



**Figura 5.** Ponto de parada na validação cruzada

Há vários trabalhos mencionando melhorias para o algoritmo ELM, como o *Fully Complex Extreme Learning Machine* [18] e o *Convex Incremental Extreme*

*Learning Machine* [13]; porém, foi decidido que no presente trabalho seria utilizado o algoritmo original, explicado neste capítulo.

# Capítulo 4

## Experimentos Realizados

Este capítulo tratará dos experimentos realizados com as bases de dados selecionadas, além dos resultados obtidos e da análise destes por meio de testes estatísticos.

### 4.1 Bases de dados

Para a realização dos experimentos, foram selecionadas quatro usinas hidrelétricas brasileiras, cada uma referente à sua respectiva região (a ONS trabalha com somente quatro regiões):

- UHE Furnas (Região Sudeste): está localizada no curso médio do rio Grande, no trecho denominado "Corredeiras das Furnas", entre os municípios de São José da Barra e São João Batista do Glória, em Minas Gerais. [7]



**Figura 6.** Usina hidrelétrica de Furnas (fonte: g1.com.br)

- UHE Salto Santiago (Região Sul): fica no Rio Iguaçu, no município de Saudade do Iguaçu, Paraná. [23]



**Figura 7.** Usina hidrelétrica de Salto Santiago (fonte: g1.com.br)

- UHE Três Marias (Região Nordeste): localizada no Rio São Francisco, no Município de Três Marias, Minas Gerais. [5]



**Figura 8.** Usina hidrelétrica de Três Marias (fonte: agenciaminas.mg.gov.br)

- UHE Tucuruí (Região Norte): localiza-se no Rio Tocantins, no município de Tucuruí, Pará. [6]



**Figura 9.** Usina hidrelétrica de Tucuruí (fonte: [sosriodosbrasil.blogspot.com](http://sosriodosbrasil.blogspot.com))

Foram coletadas para o experimento as bases de dados com as vazões diárias de cada uma destas quatro usinas, no período de 1º de Janeiro de 1980 até o dia 31 de Dezembro de 2007.

**Tabela 1.** Amostra de vazões da UHE Furnas.

<b>Data</b>	<b>Vazão (m<sup>3</sup>/s)</b>
1/jan/1980	2301
2/jan/1980	2127
...	...
30/dez/2007	959
31/dez/2007	870

## 4.2 Preprocessamento dos dados

Antes de serem submetidas aos experimentos com RNA, as bases foram preprocessadas, de forma a garantir o funcionamento dos procedimentos a serem realizados.

O primeiro passo é transformar a tabela original, com somente uma coluna de dados numéricos (pode-se dizer que a coluna de datas serve como uma ordenação dos dados), e transformá-la numa tabela com 21 colunas numéricas.

**Tabela 2.** Amostra dos dados da UHE Furnas após o pré-processamento.

n=1	n=2	n=3	n=4	...	n=19	n=20	n=21
2301	2127	2092	2121	...	3078	3224	3324
2127	2092	2121	2053	...	3224	3324	3411
2092	2121	2053	1879	...	3324	3411	3472
2121	2053	1879	1618	...	3411	3472	3580
2053	1879	1618	1383	...	3472	3580	3707
1879	1618	1383	1280	...	3580	3707	3718

Como pode ser observado na tabela acima, os dados que estão na 2ª linha em uma coluna passam para a 1ª linha na coluna seguinte, os que estão na 3ª linha passam para a 2ª da outra coluna, e assim sucessivamente. Isso garante que as vazões de 21 dias seguidos estejam ordenados horizontalmente na tabela de dados, o que será de extrema importância na execução da RNA.

Outra etapa bastante importante de pré-processamento é a normalização dos dados, não apenas por fazer com que todas as variáveis recebam a mesma atenção da rede neural, mas também por as variáveis precisarem ter seus valores proporcionais aos limites da função de ativação utilizada nas camadas de saída da rede [25]. Porém, a ferramenta responsável pela utilização da RNA normaliza os dados automaticamente; dessa forma, não foi necessário se preocupar em normalizar as vazões antes de executar o programa (nem em desfazer a normalização na saída).

### 4.3 Previsão de vazões diárias utilizando RNA do tipo SLFN

Para a previsão de vazões com RNA, foi utilizado o software NeuroHidro. A versão utilizada para os experimentos utiliza o algoritmo ELM no treinamento da rede neural.

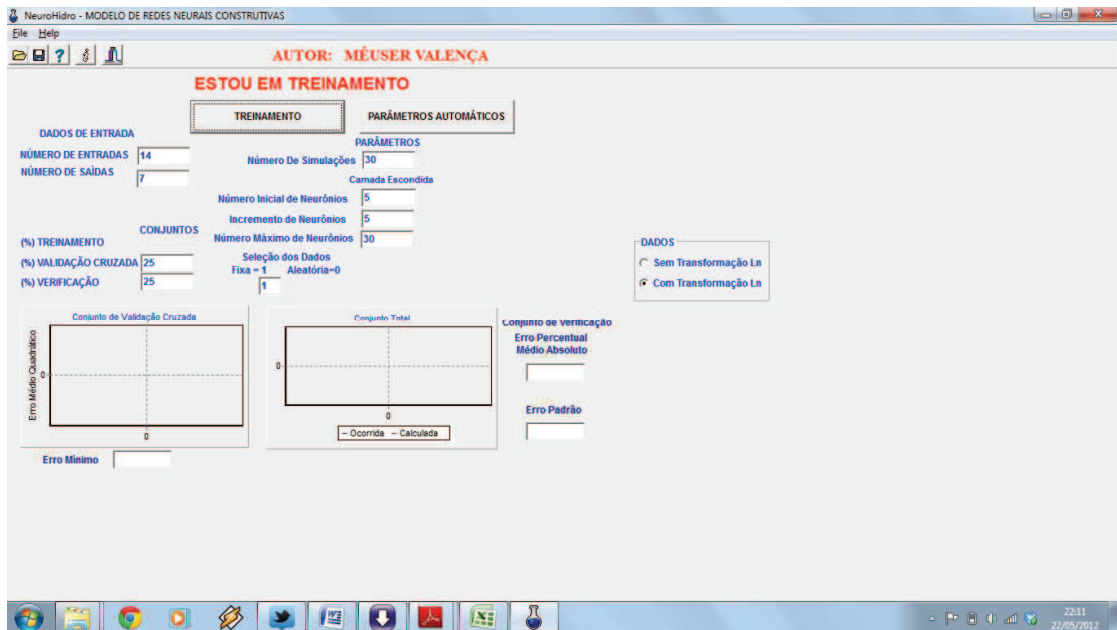
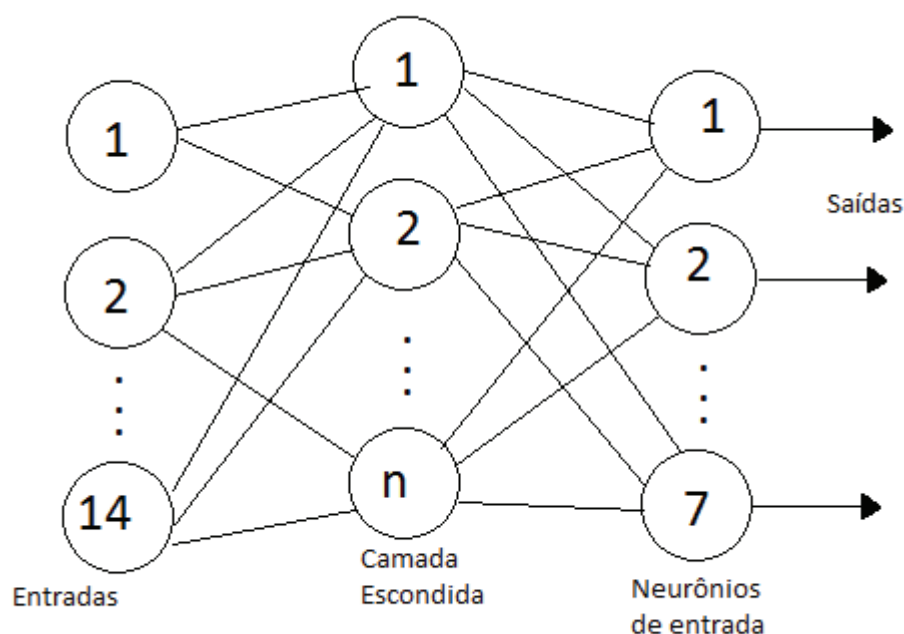


Figura 10. O NeuroHidro

Foi estabelecido que:

- A rede utilizada tem, para todas as bases de dados, 14 entradas e 7 saídas – daí as 21 colunas de dados no pré-processamento (ou seja, são feitas previsões de vazões em um horizonte de curto prazo de 7 dias à frente).
- 50% dos dados utilizados são para o treinamento da rede, 25% para a validação cruzada e os 25% restantes para a verificação.
- O número de neurônios na camada escondida da rede varia entre 5 e 30, estando estes valores inclusos, com um incremento de 5 neurônios.
- Para cada número de neurônios na camada escondida, são feitas 30 simulações.



**Figura 11.** Arquitetura da SLFN utilizada nos experimentos (etapa antes da correção do erro de fase).

Depois de feitas as simulações, o NeuroHidro gerou não só as saídas da rede – ou seja, as vazões calculadas –, como também gerou algumas taxas de erro que servem de parâmetro não só para a avaliação do desempenho da previsão, como também durante a realização dos testes estatísticos.

#### 4.3.1 Correção do erro de fase

Como dito nos Capítulos 1 e 2 deste trabalho, o erro de fase é bastante decorrente ao se fazer previsão de vazões. Um fator determinante para isso acontecer é a utilização de valores passados de vazões como entradas no método utilizado – neste caso, especificamente, o uso de RNA: mesmo esta técnica apresentando uma boa aproximação do hidrograma, geralmente ocorrem erros de defasagem temporal na previsão [27].

Neste estudo, a técnica de correção será análoga à utilizada em [27], onde as saídas da primeira rede neural – isto é, as vazões previstas – serviram como “entrada para os demais módulos que ficaram responsáveis pela ação de correção.



Os módulos de correção têm como entradas valores defasados das séries temporais geradas durante o treinamento em função das previsões realizadas” [27].

**Tabela 3.** Amostra dos dados a serem utilizados como entrada na correção (UHE Furnas)

Defasagem de D1 (d1)	Defasagem de V1 (D1)	Vazão calculada 1 (V1)	Defasagem de D2 (d2)	Defasagem de V2 (D2)	Vazão calculada 2 (V2)	...
		3194,962			3234,766	...
	45,4843	3240,447		-56,3996	3178,366	...
196,0612	-241,546	2998,901	-267,232	-323,632	2854,734	...
749,8116	-508,266	2490,635	-241,054	-564,686	2290,049	...

Como pode ser visto na tabela, os valores nas colunas referentes às primeiras defasagens (D1, D2, etc.) são calculados subtraindo a vazão anterior da atual. O cálculo das segundas defasagens (d1, d2, etc.) é feito de maneira análoga a esta. As duas primeiras linhas não são usadas.

Como a rede neural gerou 7 saídas (vazões previstas) e a preparação dos dados para a correção acrescentou mais 14 valores (duas defasagens para cada vazão prevista), este conjunto de 21 valores passa a ser o conjunto de entradas da nova rede neural. Esta rede neural também será do tipo SLFN, utilizando novamente o algoritmo ELM para o treinamento da rede. O número de saídas da rede será o mesmo que o da anterior (sete), e as saídas desejadas continuam sendo as mesmas sete da rede anterior.

O número de neurônios na camada escondida será o que obteve o menor erro quadrático médio mínimo (EQMM) do conjunto de validação cruzada durante as simulações de previsão. O EQMM é obtido utilizando a seguinte fórmula:

$$EQMM = E(QP|QO_1, QO_2, \dots, QO_N) \quad (4.1)$$

onde:

- $QP$  é a vazão calculada na previsão;
- $QO$  é a vazão que se deseja prever;
- $N$  é o número de dados.

No caso do experimento realizado, todas as previsões tiveram menor erro médio mínimo quadrático com 30 neurônios na camada escondida. O número de simulações realizadas em cada base de dados será 30.

## 4.4 Resultados

Findos os experimentos, é preciso analisar os resultados estatisticamente. A mera comparação entre erros sem o uso de testes estatísticos pode gerar erro de interpretação dos resultados, pois é possível que os resultados melhores ou piores de um determinado experimento possam, na verdade, ter acontecido por acaso – os pesos gerados na segunda RNA podem ter influenciado na geração de resultados melhores (ou piores) que os obtidos na primeira RNA. No caso deste trabalho, o que se quer saber é se houve diferença significativa entre as previsões feitas antes e depois da correção do erro de fase.

O teste realizado para verificar a eficácia da correção foi o T de Student, com nível de significância de 5%. Nesse teste, consideram-se a hipótese nula ( $H_0$ ) e a alternativa ( $H_1$ ); a hipótese nula é  $\mu_1 = \mu_2$ , enquanto a alternativa é  $\mu_1 \neq \mu_2$  – para este trabalho, a hipótese nula é que não há diferença entre a previsão feita sem a correção do erro de fase e a previsão com o erro de fase corrigido, enquanto a hipótese alternativa afirma que há diferença significativa nos resultados dessas previsões.

### 4.4.1 Métricas de desempenho das previsões

Para realizar tais testes, serão utilizadas as seguintes métricas:

- Número de simulações realizadas
- Raiz do erro quadrático médio (REQM): mede as diferenças entre valores previstos por um modelo e os valores realmente observados;

quanto maior o valor, pior a previsão realizada pelo método utilizado. Esta métrica penaliza erros maiores.

- Fórmula para calcular o REQM:

$$REQM = \sqrt{\frac{\sum_{i=1}^N (QP_i - QO_i)^2}{N}} \quad (4.2)$$

- Erro percentual médio absoluto (EPMA): o erro médio absoluto (EMA) é uma taxa que mede o quanto as previsões de vazões se desviam em relação aos valores observados; quanto menor o seu valor, melhores são as previsões [10]. O EPMA é simplesmente o EMA expresso em porcentagem. Este erro penaliza erros medianos.

- Fórmula para calcular o EPMA:

$$EPMA = \frac{1}{N} \sum_{i=1}^N |QP_i - QO_i| \times 100\% \quad (4.3)$$

- Coeficiente de eficiência de Nash-Sutcliffe (NASH): mede a eficiência de realizar previsões mais acertadas nas cheias (momentos onde as vazões são mais elevadas); quanto maior o valor de NASH, melhor a previsão [10]. O NASH penaliza erros menores.

- Fórmula para calcular o NASH:

$$NASH = 1 - \frac{\sum_{i=1}^N (QP_i - QO_i)^2}{\sum_{i=1}^N (QO_i - \bar{QO})^2} \quad (4.4)$$

Nas fórmulas acima,  $QP$ ,  $QO$  e  $N$  se referem às mesmas entradas citadas na equação 4.1.

#### 4.4.2 UHE Furnas

A base de dados correspondente às vazões da usina de Furnas foram submetidas às simulações no NeuroHidro. Os resultados podem ser vistos na tabela a seguir:

**Tabela 4.** Resultado dos experimentos relativos à UHE Furnas

<b>MÉTRICAS</b>	<b>antes da correção</b>	<b>após a correção</b>
nº de simulações	30	30
média das REQM	309,5604	353,5953
desvio-padrão das REQM	5,5938	1,9263
média dos EPMA	24,35	24,13
desvio-padrão dos EPMA	1,4939	0,2452
média dos NASH	0,76	0,69
desvio-padrão dos NASH	0,0087	0,0034

A tabela a seguir mostra os intervalos de confiança calculados para cada uma das métricas de acordo com o teste T de Student:

**Tabela 5.** Intervalos de confiança para as métricas escolhidas em Furnas

<b>MÉTRICAS</b>	<b>Intervalo de Confiança</b>
REQM	$-46,19 < (\mu_1 - \mu_2) < -41,87$
EPMA	$-0,33 < (\mu_1 - \mu_2) < 0,77$
NASH	$0,06 < (\mu_1 - \mu_2) < 0,07$

Considerando que  $H_0: \mu_1 = \mu_2$  e  $H_1: \mu_1 \neq \mu_2$ , e os intervalos mostrados na tabela anterior, chega-se à conclusão de que, para a REQM e o NASH, houve diferença significativa nos resultados das previsões antes e depois de aplicar a correção do erro de fase, o que não ocorreu para o EPMA. Porém, como, de acordo com as duas métricas que mostraram diferença significativa entre os resultados, percebe-se que os erros das previsões aumentaram ao ser feita a correção do erro

de fase, pode-se dizer que houve piora e, em Furnas, não é recomendável utilizar o método estudado.

#### 4.4.3 UHE Salto Santiago

A base de dados correspondente às vazões da usina de Salto Santiago foram submetidas às simulações no NeuroHidro. Os resultados podem ser vistos na tabela abaixo:

**Tabela 6.** Resultado dos experimentos relativos à UHE Salto Santiago

<b>MÉTRICAS</b>	<b>antes da correção</b>	<b>após a correção</b>
nº de simulações	30	30
média das REQM	481,3962	471,9648
desvio-padrão das REQM	4,8848	0,3849
média dos EPMA	33,95	32,09
desvio-padrão dos EPMA	1,1862	0,484
média dos NASH	0,66	0,67
desvio-padrão dos NASH	0,0069	0,0005

A tabela a seguir mostra os intervalos de confiança calculados para cada uma das métricas de acordo com o teste T de Student:

**Tabela 7.** Intervalos de confiança para as métricas escolhidas em Salto Santiago

<b>MÉTRICAS</b>	<b>Intervalo de Confiança</b>
REQM	$7,64 < (\mu_1 - \mu_2) < 11,22$
EPMA	$1,39 < (\mu_1 - \mu_2) < 2,32$
NASH	$-0,012 < (\mu_1 - \mu_2) < -0,007$

Considerando que  $H_0: \mu_1 = \mu_2$  e  $H_1: \mu_1 \neq \mu_2$ , e os intervalos mostrados na tabela anterior, chega-se à conclusão de que, para a REQM, o EPMA e o NASH, houve diferença significativa nos resultados das previsões antes e depois de aplicar a correção do erro de fase. Como as 3 métricas mostraram diferença significativa, e

os resultados das previsões mostraram que os seus erros diminuíram ao ser feita a correção do erro de fase, pode-se dizer que houve melhora e, em Salto Santiago, é recomendável a utilização do método utilizado.

#### 4.4.4 UHE Três Marias

A base de dados correspondente às vazões da usina de Três Marias foram submetidas às simulações no NeuroHidro. Os resultados podem ser vistos na seguinte tabela:

**Tabela 8.** Resultado dos experimentos relativos à UHE Três Marias

<b>MÉTRICAS</b>	<b>antes da correção</b>	<b>após a correção</b>
nº de simulações	30	30
média das REQM	340,0415	346,8052
desvio-padrão das REQM	5,8006	1,5346
média dos EPMA	27,62	25,18
desvio-padrão dos EPMA	1,3913	0,3439
média dos NASH	0,75	0,74
desvio-padrão dos NASH	0,0086	0,0023

A tabela a seguir mostra os intervalos de confiança calculados para cada uma das métricas de acordo com o teste T de Student:

**Tabela 9.** Intervalos de confiança para as métricas escolhidas em Três Marias

<b>MÉTRICAS</b>	<b>Intervalo de Confiança</b>
REQM	$-8,95 < (\mu_1 - \mu_2) < -4,57$
EPMA	$1,91 < (\mu_1 - \mu_2) < 2,96$
NASH	$0,006 < (\mu_1 - \mu_2) < 0,013$

Considerando que  $H_0: \mu_1 = \mu_2$  e  $H_1: \mu_1 \neq \mu_2$ , e os intervalos mostrados na tabela anterior, chega-se à conclusão de que, para a REQM, o EPMA e o NASH, houve diferença significativa nos resultados das previsões antes e depois de aplicar

a correção do erro de fase. Como as 3 métricas mostraram diferença significativa, e os resultados mostraram em duas das três métricas que os erros das previsões aumentaram ao ser feita a correção do erro de fase, pode-se dizer que houve piora e que, em Três Marias, não é recomendável utilizar o método estudado.

#### 4.4.5 UHE Tucuruí

A base de dados correspondente às vazões de Tucuruí foram submetidas às simulações no NeuroHidro. Os resultados podem ser vistos na tabela abaixo:

**Tabela 10.** Resultado dos experimentos relativos à UHE Tucuruí

<b>MÉTRICAS</b>	<b>antes da correção</b>	<b>após a correção</b>
nº de simulações	30	30
média das REQM	1393,8988	1606,196
desvio-padrão das REQM	119,4293	14,6485
média dos EPMA	9,53	13,59
desvio-padrão dos EPMA	0,915	0,4535
média dos NASH	0,98	0,97
desvio-padrão dos NASH	0,0035	0,0005

A tabela a seguir mostra os intervalos de confiança calculados para cada uma das métricas de acordo com o teste T de Student:

**Tabela 11.** Intervalos de confiança para as métricas escolhidas em Tucuruí

<b>MÉTRICAS</b>	<b>Intervalo de Confiança</b>
REQM	$-256,96 < (\mu_1 - \mu_2) < -168,32$
EPMA	$-4,43 < (\mu_1 - \mu_2) < -3,68$
NASH	$0,008 < (\mu_1 - \mu_2) < 0,011$

Considerando que  $H_0: \mu_1 = \mu_2$  e  $H_1: \mu_1 \neq \mu_2$ , e os intervalos mostrados na tabela anterior, chega-se à conclusão de que para a REQM, o EPMA e o NASH, houve diferença significativa nos resultados das previsões antes e depois de aplicar

a correção do erro de fase. Como as 3 métricas mostraram diferença significativa, e os resultados mostraram que em todas as métricas os erros das previsões aumentaram ao ser feita a correção do erro de fase, pode-se dizer que houve piora e, em Tucuruí, não é recomendável utilizar tal método.

## **4.5 Considerações finais sobre os experimentos**

Como observado neste capítulo, os testes estatísticos realizados comprovaram que a correção de erro de fase na previsão de vazões, utilizando-se da metodologia empregada, não se mostrou eficaz nas usinas analisadas, com exceção da Usina Hidrelétrica de Salto Santiago.



# Capítulo 5

## Conclusão e Trabalhos Futuros

Este trabalho teve como objetivo principal analisar a viabilidade de utilizar um método para correção do erro de fase em previsão de vazões diárias, além da importância de dar a devida atenção a tal erro, o qual pode se mostrar extremamente prejudicial ao PMO caso não seja devidamente tratado. Mostrou-se aqui que o uso do método corretivo não foi bem-sucedido em todos os casos, (em alguns casos, chegando a piorar o resultado das previsões realizadas).

Foram utilizadas 4 bases de dados referentes a usinas hidrelétricas espalhadas pelo território brasileiro: Furnas, Salto Santiago, Três Marias e Tucuruí. Para a realização das previsões e das correções, foram utilizadas simulações de redes neurais do tipo SFLN, as quais utilizavam o algoritmo *Extreme Learning Machine* para o ajuste dos seus pesos durante a fase de treinamento da rede. Para a fase da previsão antes da correção, foram utilizadas 14 entradas (correspondentes a vazões de 14 dias passados) e 7 saídas (correspondentes a vazões de 7 dias à frente). Já para a fase de correção, foram utilizadas como entradas as 7 saídas da previsão anterior, juntamente com duas “declividades” para cada uma dessas sete saídas, totalizando 21 entradas na nova SFLN, cujo número de saídas permanece sendo 7 (o mesmo horizonte utilizado antes).

Os testes estatísticos aos quais os resultados dos experimentos realizados foram submetidos mostraram que praticamente todas as métricas para a avaliação do desempenho das previsões feitas tiveram uma diferença estatisticamente significativa, mostrando, pois, que em apenas uma das quatro usinas analisadas (Salto Santiago) é interessante a realização da correção do erro de fase utilizando o método testado.

Uma grande dificuldade enfrentada durante a realização deste trabalho foi a compreensão do algoritmo de treinamento de RNA utilizado nos experimentos – o ELM, uma vez que este algoritmo envolve conhecimentos de álgebra matricial avançada, com a qual estudantes de Computação em geral não costumam se deparar, a não ser que estejam envolvidos em atividades de pesquisa científica.

Como trabalho futuro, pode-se verificar se os aperfeiçoamentos feitos no algoritmo ELM se mostram mais eficazes na correção de erro de fase do que o algoritmo original. Outra sugestão é a verificação de outra metodologia de correção para ser aplicada juntamente ao algoritmo ELM, de forma que se analise se este algoritmo se mostra eficaz em correções de defasagem.

# Bibliografia

- [1] BRAGA, A. P.; CARVALHO, A. P. L., Fº; LUDERMIR, T. B. **Redes Neurais Artificiais: teoria e aplicações**, 2.ed. Rio de Janeiro: LTC, 2007. 260 p.
- [2] COSTA, F. da S. et al. **Modelagem estocástica de previsão de vazões mensais: Previvazm**. Artigo apresentado no XV Simpósio Brasileiro de Recursos Hídricos. Curitiba, 2003.
- [3] COSTA, F. S.; DAMÁZIO, J. M.; CARVALHO, A. L. **Modelo estocástico de previsão de vazões diárias: Previvazh**. Artigo apresentado no Seminário Internacional Sobre Hidrologia Operativa. Concordia, Argentina, 2000.
- [4] COSTA, F. S.; MACEIRA, M. E. P.; DAMÁZIO, J. M. Modelos de previsão hidrológica aplicados ao planejamento da operação do sistema elétrico brasileiro. **Revista Brasileira de Recursos Hídricos**, v. 12, p. 21-30, 2007.
- [5] ENERCONSULT S. A. **Usina Hidrelétrica Três Marias (CEMIG)**. [http://www.enerconsult.com.br/pt/servicos/ProjectPage.asp?s=0000%0233%CURM\\_BOX&p=/pt/servicos/ProjectPage.asp&i=141&tsc=14&ith=](http://www.enerconsult.com.br/pt/servicos/ProjectPage.asp?s=0000%0233%CURM_BOX&p=/pt/servicos/ProjectPage.asp&i=141&tsc=14&ith=). Último acesso em 22 mai. 2012.
- [6] ELETROBRÁS Eletronorte. <http://www.eln.gov.br/>. Último acesso em 22 mai. 2012.
- [7] ELETROBRÁS Furnas. <http://www.furnas.com.br/>. Último acesso em 22 mai. 2012.
- [8] FADIGA, F. M., Jr. et al. Modelos de previsão de vazões para a Bacia Incremental à UHE Itaipu. **Revista Brasileira de Recursos Hídricos**, v. 13, n. 2, p. 65-75, 2008.
- [9] GOMES, L. F. C.; MONTENEGRO, S. M. G. L.; VALENÇA, M. J. S. Modelo baseado na técnica de Redes Neurais para previsão de vazões na bacia do Rio São Francisco. **Revista Brasileira de Recursos Hídricos**, v. 15, p. 5-15, 2010.

- [10] GUILHON, L. G. F.; ROCHA, V. F.; MOREIRA, J. C. Comparação de métodos de previsão de vazões naturais afluentes a aproveitamentos hidroelétricos. **Revista Brasileira de Recursos Hídricos**, v. 12, n. 3, p. 13, 20, 2007.
- [11] HASHINO, T.; BRADLEY, A. A.; SCHWARTZ, S. S. Evaluation of bias-correction methods for ensemble streamflow volume forecasts. **Hydrology and Earth System Sciences**, v. 11, p. 939-950, 2007.
- [12] HUANG, G.-B.; BABRI, H. A. Upper bound on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation functions. **Proceedings of the IEEE Transactions on Neural Networks**, v. 9, n. 1, p. 224-229, 1998.
- [13] HUANG, G.-B.; CHEN, L. Convex Incremental Extreme Learning Machine. **Neurocomputing**, v. 70, p. 3056-3072, 2007.
- [14] HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. **Extreme Learning Machine: a new learning scheme of feedforward neural networks**. Artigo apresentado na International Joint Conference on Neural Networks (IJCNN2004), Budapeste, Hungria, 25–29 jul. 2004.
- [15] HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme Learning Machine: theory and applications. **Neurocomputing**, v. 70, p. 489-501, 2006.
- [16] KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, v. 43, p. 59-69, 1982
- [17] JARDIM, D. L. D. D.; MACEIRA, M. E. P; FALCÃO, D. M. Stochastic Streamflow Model for Hydroelectric Systems Using Clustering Techniques. **Proceedings of the IEEE Porto Power Tech Conference**, v. 3. Porto, 2001.
- [18] LI, M.-B. Fully Complex Extreme Learning Machine. **Neurocomputing**, v. 68, p. 306-314, 2005.
- [19] MACEIRA, M. E. P. et al. Chain of Optimization Models for Setting the Energy Dispatch and Spot Price in the Brazilian System. **Proceedings of the XIV Power Systems Computation Conference**. Sevilha, 2002.
- [20] MACEIRA, M. E. P.; MERCIO, C. M. V. B. Stochastic Streamflow Model for Hydroelectric Systems. **Proceedings of the V International Conference**

- PMAPS – Probabilistic Methods Applied to Power Systems.** Vancouver, 1997.
- [21] MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943
- [22] RAO, C. R.; MITRA, S. K. **Generalized Inverse of Matrices and Its Applications.** Nova York: Wiley, 1972. 256 p.
- [23] TRACTABEL Energia. **UHE Salto Santiago.** In: <http://www.tractebelenergia.com.br/asp/system/viewPage.asp?P=827&VID=default&SID=136992235186395&S=0&C=27353>. Último acesso em 22 mai. 2012.
- [24] VALENÇA, M. J. S. **Aplicando Redes Neurais: um guia completo.** Olinda: Livro Rápido, 2005. 284 p.
- [25] VALENÇA, M. J. S. **Fundamentos das Redes Neurais: exemplos em Java.** 2.ed. Olinda: Livro Rápido, 2007. 384 p.
- [26] VALENÇA, M. J. S. **Preveno com redes neurais: o estado da arte.** Artigo apresentado no XVI Simpósio Brasileiro de Recursos Hídricos, João Pessoa-PB, 2005.
- [27] VALENÇA, M. J. S.; LUDERMIR, T. B. **Uma metodologia para correção do erro de defasagem durante o processo de previsão com redes neurais.** Artigo apresentado no XVIII Simpósio Brasileiro de Recursos Hídricos, Campo Grande, 2009.
- [28] VALENÇA, M. J. S.; LUDERMIR, T. B.; GUILHON, L. G. **Previsão de vazões de longo prazo utilizando redes neurais.** Artigo apresentado no XVI Seminário Nacional de Produção e Transmissão de Energia Elétrica, São José dos Campos, 2001.