

# UTILIZAÇÃO DE REDES NEURAIS NA MONITORAÇÃO DA POTÊNCIA DO REATOR IEA-R1

\*Rosa Helena Peccinini Silva Rossi \* e Adalberto José Soares\*

\* Instituto de Pesquisas Energéticas e Nucleares , IPEN – CNEN /SP  
Travessa R nº400, Cidade Universitária, cep-05508-900, tel. 3816-9427, São Paulo, SP, Brasil

## RESUMO

Este trabalho apresenta o resultado de um estudo realizado com Redes Neurais para monitorar a potência gerada no reator de pesquisas IEA -R1, situado no IPEN, em São Paulo. Foram desenvolvidas duas redes, uma do tipo “Multilayer Perceptrons” - MLP e a outra do tipo “Radial Basis Function” - RBF. É apresentado o desempenho de cada rede, e uma comparação entre ambas. Este estudo visa ajudar o operador fornecendo ao mesmo, numa forma de redundância diversional, a informação sobre a potência do reator, de forma a possibilitar a identificação de possíveis falhas no sistema de instrumentação e controle do reator.

**Palavras chave:** redes neurais, reatores de pesquisa, instrumentação e controle de reatores.

## I. INTRODUÇÃO

Após o acidente o acidente ocorrido na central nuclear de Three Mile Island, engenheiros e pesquisadores da área de instrumentação e controle começaram a analisar a praticidade e funcionamento das salas de controle convencionais. Observaram que, as mesmas, apresentavam uma grande quantidade de informações, porém não seletivas. Do ponto de vista operacional, todas as condições anormais tinham a mesma prioridade, ficando a cargo do supervisor a responsabilidade de coordenar as ações conforme a sua experiência, o que, como ficou demonstrado no caso de Three Mile, nem sempre era suficiente para evitar consequências indesejadas para a instalação.

Em vista do resultado dos estudos realizados, várias ferramentas e técnicas de processamento de informação foram desenvolvidas, com o objetivo principal, de priorizar informações a serem disponíveis ao operador, no sentido de facilitar a identificação de falhas e ações a serem tomadas, para mitigar os efeitos da mesma.

A aplicação de Redes Neurais é uma das técnicas que vem sendo pesquisada, com um grande potencial de exploração. É identificada como subespecialidade da Inteligência Artificial, ou como uma classe de modelos matemáticos, sempre visando o estudo de fenômenos complexos.

Este trabalho descreve o resultado de um estudo realizado com dois tipos de redes neurais uma do tipo Multilayer Perceptron (MLP) e outra do tipo Radial Basis Function (RBF), para monitorar a potência do reator de pesquisas IEA-R1, situado no IPEN, em São Paulo. Será apresentado

o desempenho de cada rede, e uma comparação entre ambas.

## II. REDES NEURAIS

A origem da teoria de Redes Neurais remonta aos modelos matemáticos e aos modelos de engenharia, de neurônios biológicos. A rede é um sistema composto por vários neurônios artificiais.

**Modelo Geral de Neurônio.** A Fig. 1 mostra o modelo matemático de um neurônio.




Figura 1. Modelo Matemático de um Neurônio

Neste modelo as entradas formadas por  $U_1, U_2 \dots U_n$ , são combinadas usando uma função  $f$ , que geralmente é a soma das entradas, devidamente ponderadas pelos  $W_1, W_2 \dots W_n$ , para produzir um estado de ativação do neurônio, que através da função  $g$ , chamada “função de transferência do neurônio”, vai gerar o sinal de saída do neurônio, que corresponde à amplitude do pulso de descarga de um neurônio biológico[1]. Um valor auxiliar  $\theta$  é geralmente utilizado para representar a existência de um valor mínimo de excitação do neurônio, e  $W_1, W_2 \dots W_n$  são os pesos de cada sinal de entrada no neurônio analisado. Os pesos representam o padrão de conectividade da rede, ou seja, define como os neurônios estão conectados. As funções de transferência mais utilizadas são do tipo linear, degrau, sigmóide e tangente hiperbólica.

**Características de uma Rede Neural** Uma rede neural é composta por camadas de neurônios que são conectados entre si, conforme ilustrado na Fig. 2.

Tipos de Camadas. Existem basicamente três tipos de camadas, a saber, entrada, intermediária e saída. A camada de entrada, é constituída por neurônios de entrada que recebem excitação do mundo exterior. No ser humano correspondem aos órgãos dos sentidos. Geralmente uma rede neural apresenta apenas uma camada de entrada, com uma quantidade de neurônios igual ao número de sinais que “entram” na rede. Neste caso, cada neurônio apresenta apenas um sinal de entrada. A camada intermediária, também conhecida como “Camada Oculta” ou “Hidden”, representa o conjunto de neurônios onde os vários sinais de entrada são processados. Numa rede genérica podemos ter mais de uma camada intermediária, porém na maior parte dos casos práticos se utiliza apenas uma. A camada de saída é constituída por neurônios que geram os sinais de resposta da rede à excitação das entradas. Estas respostas são usadas para gerar os sinais de resposta do sistema. Num ser humano, eles correspondem aos neurônios que excitam os músculos .

Padrão de Conectividade. O padrão de conectividade define como os neurônios estão conectados entre si, e em geral é representado pela matriz de conectividade  $W$  ou matriz de pesos. A matriz de pesos é ajustada durante a fase de aprendizado da rede.

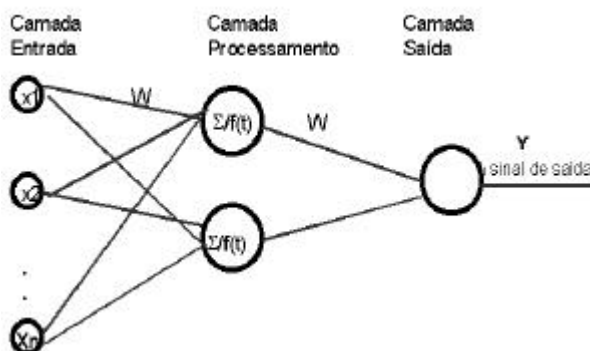


Figura 2. Estrutura Clássica das Redes Neurais do Tipo MLP e RBF, onde  $X$  é entrada,  $W$  são os pesos e  $Y$  a saída.

**Multilayer Perceptron (MLP).** O ciclo de uma rede neural, conforme aquela ilustrada na Fig. 2, é constituído de duas fases distintas, a fase de treinamento e a fase de aplicação. Na fase de treinamento a rede é alimentada com valores pré-selecionados que resultem em respostas conhecidas (resposta real), e a matriz de conectividade é ajustada de forma que a resposta da rede seja igual à resposta real. O algoritmo de treinamento da rede é baseado na minimização do erro quadrático, entre a resposta da rede e a resposta real. A minimização do erro quadrático é feita utilizando-se a técnica do gradiente decrescente da função de erro, cujas variáveis são os pesos da rede. Na fase de aplicação os pesos são fixos, sendo seus valores aqueles ajustados na fase de treinamento. Este tipo de rede tem sido bastante utilizado em modelos e sistemas de identificação não lineares [2]. Para o treinamento deste tipo de rede são necessárias muitas épocas, sendo que cada época corresponde a um ciclo completo de leitura de todas as entradas selecionadas para a fase de treinamento, e aplicação do algoritmo de treinamento para que a resposta da rede seja igual à resposta real . O algoritmo de treinamento é um processo iterativo, conhecido como “retropropagation”, é aplicado para se corrigir todos os “pesos” da rede até se atingir um erro, entre a resposta da rede e a resposta real, considerado satisfatório (mínimo); ou até que se atinja um número limite de iterações previamente estabelecido.

Funções de Transferência. Neste trabalho foram utilizados dois tipos de função transferência para a rede do tipo MLP. Para os neurônios da camada de entrada foi utilizada a função linear, representada pela Eq. (1), e nas camadas oculta e de saída foi utilizada a função tipo sigmoideal representada na Eq. (2). Em ambas equações,  $X$  representa o valor de entrada na função de transferência e  $Y$  o valor de saída.

$$Y = X \quad (1)$$

$$Y = 1 / (1 + \exp(-X)) \quad (2)$$

**Radial Basis Function (RBF).** A rede RBF é parecida com a MLP, apresentando também três camadas conforme a Fig. 2. A diferença básica entre elas está na camada oculta, onde os neurônios apresentam uma resposta localizada, que é radialmente simétrica em relação a um centro. Desta forma são formadas regiões de campos receptivos, e a camada de saída efetua uma combinação linear da resposta destas regiões. Neste caso a função transferência utilizada é do tipo Gaussiana Eq. (3), onde  $C$  é o centro da função, ou Centróide e  $X$  é a variável de entrada.[3] e [4]

$$H(X) = \exp(-(X - C)^2 / (0,75)^2) \quad (3)$$

Funções de Transferência. No caso da rede do tipo RBF, na primeira camada foi utilizada uma função linear identidade, definida na Eq. (1), na camada oculta foi utilizada uma função gaussiana, conforme Eq.(3), e na camada de saída uma função do tipo sigmóide, conforme Eq. (2).

**Aprendizado da Rede.** Assim como no caso da rede do tipo MLP, a rede RBF é treinada até obter saídas aproximadas das desejadas. Neste tipo de arquitetura, onde os centros são fixos, o ajuste do peso ocorre apenas entre a camada oculta e a camada de saída, não sendo utilizado o método de “backpropagation” para se ajustar os pesos da informação que entra nos neurônios da camada intermediária. Neste caso a correção dos pesos é feita através do método simples dos mínimos quadrados, o que simplifica em muito a fase de treinamento da rede. O número de épocas de treinamento é 1000, inferior ao da MLP.

### III. EXPERIMENTO

**Dados para Treinamento das Redes Neurais.** Para este trabalho foram colhidos dados do reator nuclear IEA -R1, reator de pesquisas do tipo piscina aberta, situado no IPEN em São Paulo. Para alimentação da rede foram considerados três parâmetros de entrada, a saber: a temperatura da água antes de entrar no núcleo do reator (T3), a temperatura da água após passar pelo núcleo do reator (T4), e a atividade do nitrogênio 16 (N16). Como parâmetro de saída, foi estabelecido que a rede deve fornecer a potência do reator, baseado na informação dos 3 parâmetros selecionados, que, como sabemos, mudam de acordo com a potência do reator. Os valores do % de potência escalar foram coletados para servirem de padrão durante a fase de treinamento da rede. Foram consideradas 45 medidas que foram distribuídas em dois grupos. O primeiro grupo foi utilizado para treinamento das redes neurais e o outro grupo para teste das mesmas. Em todos os casos as entradas foram normalizadas entre os valores 0 e 1. A tabela 1 mostra um conjunto típico de valores fornecidos para treinamento das redes.

TABELA 1 – Valores típicos utilizados na fase de treinamento das redes.

Potência (MW)	T3 (°C)	T4 (°C)	N16 (%)
1,80	27,52	29,81	21,5
1,90	27,60	29,93	22,5
2,00	27,53	30,05	24,0

**Desenvolvimento das Redes Neurais.** Foram desenvolvidas duas redes em linguagem C++, uma do tipo MLP e outra do tipo RBF, ambas com 3 camadas, e com o objetivo de determinar o percentual da potência do reator a partir dos valores fornecidos pelos instrumentos responsáveis pelas medidas de T3, T4 e N16.

**Número de Camadas.** Para os dois tipos de redes estudadas foram utilizadas três (3) camadas, sendo uma de entrada, uma intermediária (oculta) e uma de saída. Durante o desenvolvimento das redes, chegou-se à conclusão que, para este caso específico, o aumento no número de camadas intermediárias não melhoram o desempenho das redes. Na primeira camada, a de entrada, foram estabelecidos três

neurônios, representando T3, T4 e N16. Para a camada intermediária foram estudados dois casos considerados relevantes, sendo o primeiro com três (3) neurônios e o segundo com dois (2). Para a camada de saída foi estabelecido apenas um neurônio, cuja saída é a potência do reator, prevista pela rede.

Para o caso da rede do tipo RBF, os centróides foram calculados conforme a Base de Dados e o número de neurônios da Camada Oculta, conforme tabelas 2 e 3.

TABELA 2 – Centróides (normalizados) para a Rede do tipo RBF com 2 neurônios na camada oculta

	T3	T4	N16
Neurônio 1	0,9953	0,9962	0,9951
Neurônio 2	0,997	0,9918	0,9145

TABELA 3 – Centróides (normalizados) para a Rede do tipo RBF com 3 neurônios na camada oculta

	T3	T4	N16
Neurônio 1	0,9956	0,9889	0,8959
Neurônio 2	0,9952	0,9961	0,9165
Neurônio 3	0,9987	0,9953	0,9380

### IV. RESULTADOS E COMPARAÇÕES

As tabelas 4 e 5 mostram o resultado obtido quando se utilizam dois neurônios na camada oculta. Nelas podemos observar que a rede neural do tipo MLP- Multi Layer Perceptron apresentou excelentes resultados, com um erro médio da ordem de 0,43% em todo conjunto de dados, e um erro médio de 0,40% para os dados utilizados na fase de aplicação. Uma performance muito superior à da rede do tipo RBF Radial Basis Function, que apresentou um erro médio da ordem de 26% em todo conjunto de dados e um erro médio de 24% para os dados utilizados na fase de aplicação.

TABELA 4 – Valores típicos da fase de aplicação, obtidos com dois neurônios na camada oculta

Potência Real	Valor previsto pela rede do tipo MLP	Valor previsto pela rede do tipo RBF
0,375	0,372	0,453521
0,355	0,356	0,453521
0,34	0,34	0,453521

TABELA 5. Comparações Entre as Redes MLP e RBF com 2 Neurônios na Camada Oculta

Tipo da Rede:	MLP	RBF
Número de neurônios na Camada Oculta:	2	2
Número de épocas:	10000	1000
Erro médio obtido na fase de treinamento da rede:	0,002344	0,433521
Erro médio entre a resposta da rede e a resposta real (utilizando todos os dados disponíveis)	0,43	25,96
Erro médio entre a resposta da rede e a resposta real (utilizando os dados da fase de teste)	0,40	24,28

As tabelas 6 e 7 mostram o resultado obtido quando se utilizam três neurônios na camada oculta. Nelas podemos observar que, assim como no caso de dois neurônios, a rede neural do tipo MLP- Multi Layer Perceptron apresentou um resultado muito melhor do que a rede do tipo RBF, já que o erro médio é da ordem de 0,49% em todo conjunto de dados, e de 0,47% para os dados da fase de aplicação. Uma performance muito superior à da rede do tipo RBF Radial Basis Function que apresentou um erro médio da ordem de 21% em todo conjunto de dados e um erro médio da ordem de 19% para os dados da fase de aplicação.

TABELA 6 – Valores típicos da fase de aplicação, obtidos com três neurônios na camada oculta

Potência Real	Valor previsto pela rede do tipo MLP	Valor previsto pela rede do tipo RBF
0,375	0,372	0,435164
0,355	0,356	0,435164
0,34	0,341	0,435164

TABELA 7. Resultados e Comparações Entre as Redes Neurais com 3 Neurônios na Camada Oculta

Tipo da Rede:	MLP	RBF
Número de neurônios na Camada Oculta:	3	3
Número de épocas:	10000	1000
Erro médio obtido na fase de treinamento da rede:	0,002316	0,431844
Erro médio entre a resposta da rede e a resposta real (utilizando todos os dados disponíveis)	0,49	21,05
Erro médio entre a resposta da rede e a resposta real (utilizando os dados da fase de teste)	0,47	19,25

## V. AGRADECIMENTOS

Agradeço ao CNPQ pela Bolsa de Estudos, cujos recursos possibilitaram o desenvolvimento do meu trabalho.

## VI. REFERÊNCIAS

- [1] Barreto, Jorge Muniz, **Redes Neurais Fundamentos e Aplicações**, II SBAI-Segundo Simpósio Brasileiro de Automação Inteligente, Curitiba, Setembro 1995
- [2] Kovács, Zsolt L., **Redes Neurais Artificiais: Fundamentos e Aplicações**, 2. Ed. – Edição Acadêmica, São Paulo, 1996
- [3] Cabral Jr., E.F., **Redes Neurais Artificiais**. Ed. Autor. 324p., 1999
- [4] Timoszczuk, P.A. & Cabral Jr., E. **RBF Neural Networks and MTI for text Independent Speaker Identification**
- [5] Tsoi, A.C. 1989. **Multilayer perceptron trained using radial basis functions**. *Electronic Letters* 25(9)

## ABSTRACT

This work presents the results of a program that makes use of neural network concepts, developed to monitor the nuclear power of IEAR1 research reactor. Two networks were tested, one using Multilayer Perceptrons (MLP) and the other using Radial Basis Function (RBF). The results obtained with the two networks are presented and compared. The objective of the developed program is to create a diversional form to present the information regarding the reactor power to the operator, in order to help identify possible failures in the instrumentation and control system of the reactor.