



## INTERPRETAÇÃO MATEMÁTICA DA VARIAÇÃO LUMINOSA NO PROCESSO DE SOLDAGEM MIG/MAG PULSADO PARA CLASSIFICAÇÃO DO DESTACAMENTO ATRAVÉS DE UMA REDE NEURAL ARTIFICIAL

### **Henrique Gomes de Moura\***

Aluno de Iniciação Científica – LSM – UFU, Universidade Federal de Uberlândia – FEM.  
Campus Santa Mônica – 38400-902 – Uberlândia – MG. E-mail: [hgmoura@yahoo.com](mailto:hgmoura@yahoo.com).

### **Hélio Cordeiro de Miranda**

Dr. Eng., Professor/pesquisador – ENGESOLDA - UFC, Universidade Federal do Ceará – DEM.  
Campus do Pici – Bloco 714 - 60455-760 – Fortaleza – Ce. E-mail: [hmiranda@ufc.br](mailto:hmiranda@ufc.br).

### **Marcus Antônio Viana Duarte**

Dr. Eng., Professor/pesquisador – LSM – UFU, Universidade Federal de Uberlândia – FEM.  
Campus Santa Mônica – 38400-902 – Uberlândia – MG. E-mail: [mvduarte@mecanica.ufu.br](mailto:mvduarte@mecanica.ufu.br).

### **Valtair Antonio Ferraresi**

Dr. Eng., Prof./pesquisador – LAPROSOLDA – UFU, Universidade Federal de Uberlândia – FEM.  
Campus Santa Mônica – 38400-902 – Uberlândia – MG. E-mail: [valtairf@mecanica.ufu.br](mailto:valtairf@mecanica.ufu.br).

**Resumo.** *O estudo de Redes Neurais exige, para que se atinjam os melhores resultados possíveis durante a fase de criação e/ou treinamento, um tratamento cuidadoso dos dados antes que os mesmos sirvam de entrada para a rede. Esta preparação é feita através de métodos estatísticos que possam interpretar, da forma mais clara e simples, o fenômeno físico analisado. Em função do que foi citado e visando atender as exigências de uma pesquisa no LAPROSOLDA-UFU, este trabalho tem como objetivo estudar a melhor forma de descrever matematicamente a geometria da curva do sinal emitido pelo sensor óptico durante o processo de soldagem. Utilizou-se uma quantidade suficiente de parâmetros estatísticos, tais como média, inclinação e regressão polinomial, de modo que para cada combinação teórica foi criada uma rede. Os resultados do estudo revelaram que boa parte das redes criadas tem a capacidade de “enxergar”, com alta eficácia as diferentes formas do sinal quantificadas pelos parâmetros matemáticos. As redes selecionadas foram empregadas para classificar, com base no sinal do sensor, o tipo de transferência metálica ocorrida durante o processo de soldagem MIG/MAG pulsado. A maioria das classificações foi satisfatória, tanto em relação à eficiência quanto à velocidade de resposta, revelando assim a aplicabilidade da ferramenta no processo de soldagem analisado.*

**Palavras-chaves:** *Redes PNN, Soldagem MIG/MAG pulsada, Transferência Metálica.*

## 1. INTRODUÇÃO

Redes Neurais Artificiais (RNAs) são sistemas paralelos distribuídos, compostos por unidades simples de processamento, ou nodos que computam determinadas funções matemáticas, geralmente

não lineares. O nodo é uma representação matemática simples do neurônio natural que visa reproduzir as funções das redes biológicas, buscando implementar seu comportamento básico e desenvoltura dinâmica. De acordo com as teorias estabelecidas, um neurônio biológico é constituído de três partes: *o corpo da célula, os dendritos e o axônio*. Os *dendritos* têm a função de receber os impulsos nervosos, oriundos de outros nodos, e conduzi-los ao *corpo da célula*, onde serão manipulados através de reações químicas a fim de gerar os impulsos nervosos, que serão conduzidos ao longo da rede para os nodos vizinhos (Braga et al., 1998).

As RNAs possuem, no lugar de *dendritos*, matrizes de *pesos e "bias"*, onde se acumulam várias séries de valores, cuidadosamente determinadas pelo treinamento, que irão pesar cada informação recebida pelo nodo. Essas informações são conduzidas para um *somador* e posteriormente para uma *função de ativação*, que irá processar a saída deste nodo. A Figura 1 representa uma analogia do neurônio biológico e do artificial.




Figura 1 - Representação matemática de um neurônio biológico.

As RNAs possuem a capacidade de aprender por exemplos de interpolações e extrapolações. O aprendizado é um processo pelo qual os parâmetros de uma rede neural são ajustados mediante a uma exposição contínua de estímulos do meio onde a rede está operando. Geralmente é feito de forma supervisionada, onde todos os dados de entrada e saída são fornecidos por um supervisor (professor) externo. Curiosamente, as primeiras redes são de origens empíricas, fato que junto aos diversos tipos de algoritmos de aprendizado e de arquiteturas existentes, torna a escolha da melhor rede neural, que atenda o problema, uma tarefa difícil e meticulosa (Braga et al., 1998).

Recentemente foram pesquisadas novas arquiteturas e teorias para o campo das redes neurais, desta vez com sólidos argumentos matemáticos comprobatórios. As Redes Neurais Probabilísticas (PNN) são fruto desses trabalhos e, em determinadas ocasiões, podem atingir melhores resultados do que as Redes Neurais Convencionais ou Empíricas (The MathWorks Inc., 2001). As mesmas, possuem um número elevado de neurônios, mas podem ser criadas em uma pequena fração do tempo de treinamento das redes convencionais. Tais redes não necessitam de treinamento algum e, de posse de uma rica fonte de experimentos, podem atingir ótimos desempenhos (Masters, 1995). Normalmente, operam de forma bem distinta das redes convencionais e só foram ditas redes neurais devido ao fato de efetuarem, de forma semelhante aos casos anteriores, um processamento em paralelo, da entrada com cada elemento constituinte (neurônios), para uma posterior etapa de competição entre os valores calculados, a fim de encontrar um elemento interno que apresente as maiores semelhanças físicas com o novo indivíduo da população. Uma representação esquemática da rede PNN é mostrada na Figura 2.

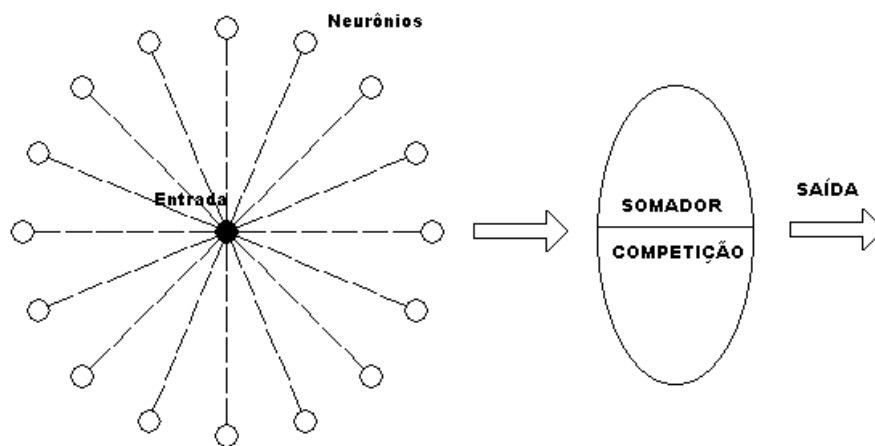


Figura 2 - Rede Neural Probabilística.

As Redes PNN podem ser utilizadas em problemas classificatórios com bastante êxito e de uma forma bem simples. Primeiramente é computada a distância de cada neurônio, da primeira camada com a entrada, para que seja criado um vetor que representa quão próximos estão os indivíduos da população com o indivíduo de entrada. A segunda camada realiza os cálculos estatísticos que resultarão em um vetor de probabilidades e finalmente estes valores são expostos a uma etapa de competição, onde apenas um indivíduo servirá de saída (The MathWorks Inc., 2001).

Com relação ao problema de classificação, destaca-se que o Laboratório para o Desenvolvimento de Processo de Soldagem (Laprosolda) da Universidade Federal de Uberlândia (UFU) desenvolveu uma pesquisa relacionada ao controle do processo MIG/MAG pulsado, na qual se exigia o reconhecimento do perfil do sinal emitido por um sensor óptico (Miranda, 2002). Este sensor tem por finalidade detectar as variações da luminosidade do arco durante a soldagem e a classificação do seu perfil visa a caracterização da condição de transferência metálica. Em virtude desta necessidade, foi proposta a aplicação das redes neurais probabilísticas na classificação do perfil do sinal do sensor de luminosidade, para possibilitar a implementação de um sistema básico de controle do processo MIG/MAG pulsado.

Entretanto, constatou-se através das primeiras redes utilizadas que o tratamento matemático dos dados influenciavam fortemente o desempenho das redes criadas, fato que evidenciou a necessidade de um estudo adequado para estabelecer a melhor forma de descrever matematicamente o perfil do sinal do sensor, ou seja, selecionar quais os parâmetros estatísticos seriam mais adequados para tal finalidade.

Deste modo, o objetivo deste trabalho consiste em estudar a melhor forma de descrever matematicamente a geometria da curva do sinal que é emitido pelo sensor óptico durante o processo de soldagem MIG/MAG pulsado para que, com isso, possa ser realizada a classificação da transferência metálica por meio de RNAs.

## 2. PROCEDIMENTO TEÓRICO

### 2.1. Desenvolvimento do programa “MENEGER”

O manuseio de redes neurais, na maioria dos casos, é uma tarefa estafante e exige uma certa experiência prática no assunto, dada a grande diversidade de teorias anexadas a um ciclo completo de criação, treinamento e validação de redes. Em muitos casos o tempo é um parâmetro limitante, fato que

dificulta o estudo mais detalhado de redes neurais e que resulta normalmente numa desistência por parte do pesquisador e na busca de novas ferramentas para nutrir suas necessidades.

Tendo em vista essas dificuldades, desenvolveu-se um programa capaz de atender, de forma simples e rápida, as maiores exigências de parte das pessoas não habituadas à utilização de redes neurais em seus trabalhos científicos. O programa MENEGER (Administrador de redes neurais artificiais 1.0) foi desenvolvido, através de uma ferramenta comercial, com o intuito de automatizar todo o processo de criação, treinamento e validação de redes neurais artificiais de vários tipos, dentre os quais estão as Redes PNN. A interface do programa foi desenvolvida de forma a tornar sua utilização bastante simples e atrativa, facilitando a vida do usuário ingressante no assunto. O programa está munido de uma série de funções para manipulação e organização dos arquivos de treinamento, validação e teste, sendo que bastará ao usuário entrar com os arquivos de entrada (“*Inputs*”) e saída (“*Targets*”) em formato texto TXT.

As redes já treinadas podem ser validadas, visualizadas, simuladas e inicializadas. O programa faz uso de determinadas funções estatísticas a fim de realizar um tratamento fino dos dados e resultados dos treinamentos e/ou criação de redes. Todos os resultados podem ser visualizados, de forma eficiente, por gráficos e janelas. A Figura 3 ilustra a interface principal do MENEGER.

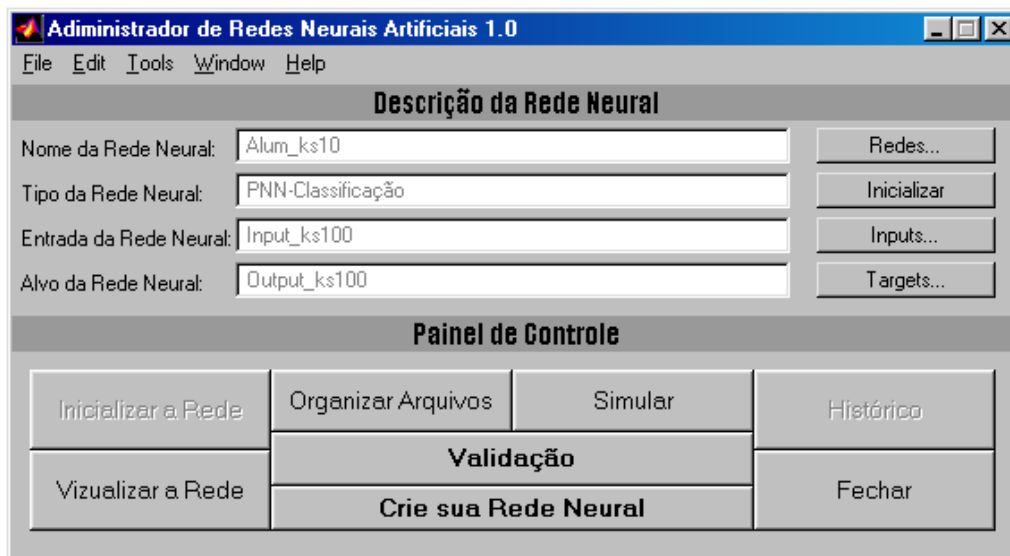


Figura 3 – Imagem da interface principal do Meneger.

## 2.2.Criação e validação da rede PNN

Os arquivos de entrada (“*Input*”) e de saída (“*Target*”) para criação e validação da rede foram gerados a partir de um banco de dados construído através de sinais oriundos de ensaios com processo MIG/MAG pulsado. As soldagens em alumínio foram executadas automaticamente na posição plana, com diferentes parâmetros de pulsação para possibilitar a ocorrência das três condições de transferência metálica neste processo: menos de Uma Gota Por Pulso (- UGPP), Uma Gota Por Pulso (UGPP) e mais de Uma Gota Por Pulso (+ UGPP). O sensor óptico foi posicionado na tocha de soldagem de modo que gerasse um sinal de tensão, proporcional à variação luminosa do arco, para ser relacionado com o tipo de transferência metálica.

Para facilitar a classificação do tipo de transferência metálica e possibilitar a implementação adequada do futuro sistema de controle, os perfis dos sinais do sensor óptico foram divididos em sete padrões, conforme pode ser visto na Fig. 4.




Figura 4 – Padrões da transferência metálica.

Padrão 1: – UGPP com baixíssimo tempo de pulso;

Padrão 2: UGPP com tempo de pulso muito baixo (próximo a UGPP);

Padrão 3: UGPP na região próxima a – UGPP;

Padrão 4: UGPP na região central;

Padrão 5: UGPP na região próxima a + UGPP;

Padrão 6: + UGPP com tempo de pulso não muito elevado (próximo a UGPP);

Padrão 7: + UGPP com tempo de pulso muito elevado.

Com os sinais emitidos pelo sensor englobando os sete padrões para diferentes condições de soldagem (um mesmo padrão foi obtido em vários ensaios), dividiu-se os arquivos gerados de acordo com o tipo de transferência metálica e a seguir, para cada padrão, executou-se um programa para selecionar aleatoriamente as fases de pulso (vários arquivos para um mesmo padrão) e desta forma criar o banco de dados. Ressalta-se que o banco de dados contém erros inerentes ao processo, pois a seleção foi aleatória e o grupo de arquivo relacionados a um determinado padrão de destacamento não é 100 % puro (contém outros padrões), pois a própria transferência metálica do processo não é uniforme.

Para cada padrão de destacamento, foram selecionados 600 fases de pulso, o que totaliza 4200 fases de pulso no banco de dados criado (7 padrões). Empregaram-se 70 fases de pulsos (10 para cada padrão) para criação das redes e o montante total (4200) para testar e validar as mesmas. Como dito anteriormente, o tipo de rede escolhida foi a “Probabilistic Neural Network” (PNN), com interface em um programa comercialmente disponível.

Para que a análise do padrão de destacamento seja efetiva para o trabalho em desenvolvimento, é necessário que a classificação do tipo de transferência metálica não dependa do tempo de duração e da amplitude dos pulsos do sinal do sensor óptico, pois mesmo com ajustes diferentes para estes parâmetros, é possível (e comum) a ocorrência de padrões de destacamentos iguais. Deste modo, antes de ser utilizado para criação e validação da rede, o banco de dados foi submetido a um tratamento matemático para representar qualitativamente a forma geométrica de cada pulso. Para diminuir o processamento computacional, cada pulso foi dividido em um número “x” de partes, independente do tempo de duração dos mesmos. Isto fez com que o tempo de pulsação fosse normalizado e com isso diminuísse sua influência sobre a análise do padrão de destacamento. Em cada parte deste sinal, calculou-se índices estatísticos nos quais se acreditava que representariam a forma geométrica do sinal.

Os índices calculados em cada trecho foram: média dividida pelo valor máximo do pulso, inclinação, desvio padrão, variância, “kurtosis” e “skewness”. Foi realizado ainda uma regressão polinomial nos trechos dos pulsos. A exceção desta regressão, os índices foram agrupados dois a dois

para melhor representação, o que resultou nas seguintes combinações para este trabalho: *Regressão Polinomial Múltipla (rpm)*, *Média e Inclinação (mi)*, *Média e Desvio Padrão (md)*, *Média e Variância (mv)*, *Média e “Kurtosis” (mk)*, *Média e “Skewness” (ms)*, *Inclinação e “Skewness” (is)*, *Inclinação e Variância (iv)*, *Inclinação e Kurtosis (ik)*, *Inclinação e Desvio Padrão (id)* e *“Kurtosis e Skewness” (ks)*. As duas primeiras colunas da Tab. 1 mostram a disposição dos parâmetros utilizados e seu número de divisões de cada pulso.

### 3. RESULTADOS E DISCUSSÃO

A Tabela 1 ilustra os valores do aproveitamento global, para cada rede neural treinada, quando submetida a uma situação real de trabalho, ou seja, trata-se de uma validação em um plano mais amplo. Nesta tabela, é importante destacar os seguintes aspectos:

- ◆ número de entradas para cada pulso analisado: 15 entradas para Regressão polinomial e 10 entradas para as demais;
- ◆ análise de erro encontrado em cada classe: deve-se considerar que os sinais originais apresentavam maiores erros para as classes 4 e 5 (menores para as classes 1, 2 e 7);

Tabela 1 – Aproveitamento global para cada rede treinada.

Redes	Divisões	Erro encontrado para cada Padrão (em 600 fases de pulsos)							Aproveitamento Global (%)
		1	2	3	4	5	6	7	
“Regressão Polinomial”	15	0	7	38	82	23	54	6	95,0
“Média e Inclinação”	10	0	2	18	107	105	60	0	93,0
“Inclinação e Skewness”	10	0	55	89	53	89	84	1	91,2
“Inclinação e Desvio”	10	0	2	27	71	93	201	1	90,6
“Inclinação e Kurtosis”	10	0	78	16	38	250	115	18	87,7
“Média e Desvio”	10	2	6	123	315	145	123	17	82,6
“Inclinação e Variância”	10	0	46	23	135	120	352	58	82,5
“Média e Variância”	10	1	5	105	238	139	242	54	81,3
“Kurtosis e Skewness”	10	0	70	252	109	121	303	28	79,0
“Média e Skewness”	10	22	61	542	113	167	439	19	69,7
“Média e Kurtosis”	10	0	79	195	157	323	527	80	67,6

Os quatro melhores resultados foram para as redes “Regressão polinomial”, “Média e Inclinação”, “Inclinação e Skewness” e “Inclinação e Desvio”, todas com índice de acerto superior a 90 %. As classes com maior facilidade de identificação foram: a 1, a 7, a 2, a 3 e a 6. As classes 4 e 5 apresentaram maiores problemas de identificação, conforme dito anteriormente, mas isto não significa obrigatoriamente que a rede teve maiores dificuldades para a classificação deste grupo, pois durante a fase de sua criação, os conjuntos de dados destas classes (4 e 5) já apresentavam erros inerentes do próprio sinal gerado pelo sensor. Na realidade, a transferência metálica para estas classes muda esporadicamente durante a soldagem, fazendo com que o sinal não seja totalmente regular, assemelhando-se algumas vezes com outros padrões. Em outras palavras, pode ser que a rede esteja



Tabela 3 – Aproveitamento individual para a rede “Inclinação e Desvio”.

Padrão atribuído	Padrão classificado						
	1	2	3	4	5	6	7
Padrão 1	<b>100,0</b>	-	-	-	-	-	-
Padrão 2	-	<b>99,6</b>	0,4	-	-	-	-
Padrão 3	-	-	<b>94,6</b>	5,3	-	-	-
Padrão 4	-	-	-	<b>88,3</b>	11,7	-	-
Padrão 5	-	-	-	3,0	<b>84,7</b>	12,3	-
Padrão 6	-	-	-	3,3	29,3	<b>67,3</b>	-
Padrão 7	-	-	-	-	-	-	<b>100,0</b>

Tabela 4 – Aproveitamento individual para a rede “Regressão Polinomial”.

Padrão atribuído	Padrão classificado						
	1	2	3	4	5	6	7
Padrão 1	<b>100,0</b>	-	-	-	-	-	-
Padrão 2	-	<b>98,6</b>	0,4	-	-	-	1,0
Padrão 3	-	3,6	<b>94,0</b>	2,4	-	-	-
Padrão 4	-	-	5,4	<b>86,6</b>	8,0	-	-
Padrão 5	-	-	-	2,3	<b>97,0</b>	0,7	-
Padrão 6	-	-	3,4	-	6,0	<b>90,0</b>	0,6
Padrão 7	-	-	-	-	-	0,7	<b>99,3</b>

Tabela 5 – Aproveitamento individual para a rede “Inclinação e Skewness”.

Padrão atribuído	Padrão classificado						
	1	2	3	4	5	6	7
Padrão 1	<b>100,0</b>	-	-	-	-	-	-
Padrão 2	-	<b>93,0</b>	6,7	0,3	-	-	-
Padrão 3	-	10,0	<b>85,3</b>	4,0	-	0,7	-
Padrão 4	0,7	-	-	<b>89,7</b>	2,0	7,3	0,3
Padrão 5	-	-	-	5,0	<b>86,3</b>	8,0	0,7
Padrão 6	-	-	-	1,3	14,0	<b>84,0</b>	0,7
Padrão 7	-	-	-	-	-	-	<b>100,0</b>

De acordo com a natureza dos dados, espera-se que os erros encontrados aumentem do Padrão 1 para o Padrão 3 e diminuam gradativamente deste ponto até o Padrão 7, ou seja, o erro aumenta das extremidades para o centro. Como foi dito, os Padrões 4 e 5 são semelhantes e se confundem com outros padrões, o que possibilita uma maior margem de erro relacionado à forma do sinal. Além disso,



na criação dos bancos de dados experimentais, foram considerados os erros inerentes à transferência com padrão do tipo: 3, 4, 5 e 6.

Observando as Tabelas 2-5, pôde-se verificar que a rede “Média e Inclinação” atingiu os melhores resultados, visto que a mesma classificou corretamente as extremidades e conseguiu discernir com maior eficiência os Padrões 4, 5 e 6 e ainda apresentar baixa dispersão nos resultados. Ressalta-se novamente que existe uma parcela de erros inerentes tanto ao processo de soldagem quanto à natureza geométrica dos sinais, de forma que podem ser imaginados não só como erros propriamente ditos e sim como uma regra, adotada pela rede, de correta classificação, tendo em vista que existem pulsos estranhos inseridos em cada pacote de dados. Para ser mais objetivo, pode-se concluir que os erros apresentados reforçam o fato das redes terem realmente “aprendido” a reconhecer os padrões, uma vez que os bancos de dados não são verdadeiramente puros.

Ao analisar a rede “Inclinação e Desvio” (Tab. 3), pôde-se constatar uma menor eficiência quando comparada à rede “Média e Inclinação” (Tab. 2). No entanto, é possível que este fato esteja relacionado a maior falha de classificação encontrada nos indivíduos do Tipo 6. Destaca-se ainda, que além do erro local para cada padrão, deve-se considerar a dispersão nos resultados de classificação. A rede “Regressão Polinomial” (Tab. 4) mesmo tendo excelente desempenho, apresentou uma dispersão elevada, classificando por exemplo, Padrões 2 como sendo 7 e Padrões 6 como 3. Nesta situação, pode-se afirmar que o erro é da rede e não do banco de dados. Considerou-se, portanto, que a “Regressão Polinomial” foi inferior às redes “Média e Inclinação” e “Inclinação e Desvio”(Tabs. 2 e 3).

A rede “Inclinação e Skewness”(Tab. 5), apesar de bom desempenho nas extremidades (1, 2 e 7), classificou com margem de erro elevada os padrões centrais (4, 5 e 6) e com elevada dispersão, de modo que foi considerada com pior desempenho dentre as quatro analisadas.

No geral, de acordo com as tabelas mostradas acima, foi possível diferenciar qualitativamente o potencial de classificação para os padrões de transferência analisados. Identificaram-se também as falhas apresentadas pelas redes ao classificarem cada população (pulsos), quantificando inclusive a gravidade dessas falhas (erro absoluto e de dispersão).

#### **4. CONCLUSÕES**

No geral, pelo menos quatro redes apresentaram bom desempenho e bom tempo de resposta para classificação do tipo de sinal do sensor óptico. Dentre estas, a rede “Média e Inclinação” superou as demais e foi selecionada para ser utilizada na implementação de um programa de controle da transferência metálica no MIG/MAG pulsado. As conclusões particulares são:

- ◆ a inclinação é um índice fundamental para representação da forma geométrica do sinal do sensor óptico, mas deve ser utilizada com outro índice de média ou de dispersão para atingir uma eficiência desejada;
- ◆ a regressão polinomial apesar do excelente desempenho, não foi considerada a mais adequada porque apresentou maior dispersão que as redes “Média e Inclinação” e “Inclinação e Desvio”, além de exigir também maior processamento computacional (15 divisões para cada pulso contra 10 para as demais redes);
- ◆ os erros obtidos pelas redes na classificação de cada padrão devem ser interpretados como erros máximos que podem ser atingidos e não erros reais.

#### **5. AGRADECIMENTOS**

Os autores agradecem ao LAPROSOLDA – UFU, ao LSM-UFU, à White Martins, à CAPES, ao CNPq pelo apoio laboratorial e suporte financeiro.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

Braga, A. P.; Carvalho, A. P. L. F.; Ludermir, T. B., 1998, “Fundamentos de Redes Neurais Artificiais”, 11<sup>a</sup> Escola de Computação - UFRJ, Rio de Janeiro, julho, pp. 246.

Masters, T., 1995, “Advanced Algorithms for Neural Networks: a C++ sourcebook”, John Wiley & Sons Inc., USA, pp. 431.

Miranda, H.C., 2002, “Verificação da possibilidade de identificação da transferência metálica no processo MIG/MAG Pulsado através de um sensor óptico”, II Congresso Nacional de Engenharia Mecânica, (II CONEM), João Pessoa – PB, Agosto, pp.

The MathWorks Inc., 2001, “Neural Network Toolbox User`s Guide”, Radial Basis Networks, pp.7:02 - 7:18.

## MATHEMATICAL INTERPRETATION OF THE LUMINOUS VARIATION IN THE PULSED GMAW WELDING FOR DETACHMENT CLASSIFICATION WITH AN ARTIFICIAL NEURAL NETWORK

### **Henrique Gomes de Moura\***

Aluno de Iniciação Científica – LSM – UFU, Uberlândia Federal University- FEM.  
Campus Santa Mônica – 38400-902 – Uberlândia – MG. E-mail: [hgmoura@yahoo.com](mailto:hgmoura@yahoo.com).

### **Hélio Cordeiro de Miranda**

Dr. Eng., Teacher/researcher - ENGESOLDA - UFC, Ceará Federal University- DEM.  
Campus do Pici – Bloco 714 - 60455-760 – Fortaleza – Ce. E-mail: [hmiranda@ufc.br](mailto:hmiranda@ufc.br).

### **Marcus Antônio Viana Duarte**

Dr. Eng., Teacher/researcher – LSM – UFU, Uberlândia Federal University- FEM.  
Campus Santa Mônica – 38400-902 – Uberlândia – MG. E-mail: [mveduarte@mecanica.ufu.br](mailto:mveduarte@mecanica.ufu.br).

### **Valtair Antonio Ferraresi**

Dr. Eng., Teacher/researcher - LAPROSOLDA - UFU, Uberlândia Federal University- FEM.  
Campus Santa Mônica – 38400-902 – Uberlândia - MG. E-mail: [valtairf@mecanica.ufu.br](mailto:valtairf@mecanica.ufu.br).

***Abstracts.** The study of Neural Network demands a careful treatment concerning the data base to attain the best results during the creation and training phase. This treatment is carried out with several statistical methods that can easily describe the physical phenomenon analyzed. This work focus on the study of the best way to describe mathematically the signal geometric shape that is produced by optical sensor during the welding process. In this way, enough quantity of statistical parameters, like mean, inclination and polynomial regression, was used in each network. Some networks have taken to the final stage to classify the type of metal transfer in the welding process. The majority of the results was satisfactory for both answer velocity and efficiency.*

**Keywords:** Probabilistic Neural Network, Metal transfer, Pulsed GMAW welding.