

# PROPAGAÇÃO DA INCERTEZA EM REDES NEURAIIS: METODOLOGIA E ESTUDO DE CASO

Christiane S. A. Gusman<sup>1,3</sup>, Eduardo C. Silva<sup>2,3</sup> e Carlos R. Hall Barbosa<sup>3</sup>

<sup>1</sup>ENDESA Brasil - Praça Leoni Ramos, 1, São Domingos – Niterói, RJ, Brasil - 24210-200

<sup>2</sup>Depto Engenharia Elétrica – PUC-Rio – R. Marquês de São Vicente, 225, Gávea - Rio de Janeiro, RJ, Brasil - 22451-900

<sup>3</sup>Programa de Pós-graduação em Metrologia – PUC-Rio – R. Marquês de São Vicente, 225, Gávea - Rio de Janeiro, RJ, Brasil - 22451-900

E-mails: [eng.christianesampaio@gmail.com](mailto:eng.christianesampaio@gmail.com), [edusilva@aluno.puc-rio.br](mailto:edusilva@aluno.puc-rio.br), [hall@ele.puc-rio.br](mailto:hall@ele.puc-rio.br)

**Resumo** – Este trabalho tem como objetivo apresentar uma nova metodologia desenvolvida para analisar a propagação das incertezas de medição das variáveis de entrada em redes neurais artificiais. O método proposto permite que se estime a incerteza de medição das variáveis de saída, contribuindo para a avaliação da confiabilidade de modelagens baseadas em redes neurais. Também apresenta-se um estudo de caso, no qual se avaliou a propagação das incertezas de medição em sete redes neurais destinadas a estimar a concentração dos gases (saídas das redes) dissolvidos no óleo de transformadores de potência, com base nas características físico-químicas do óleo (variáveis de entrada). A metodologia utilizada baseia-se na introdução de perturbações na entrada das redes analisadas e na consequente análise de como estas perturbações afetam a saída das redes. As perturbações introduzidas são as incertezas de medição das variáveis de entrada, as quais foram obtidas a partir dos certificados de calibração dos instrumentos utilizados nas respectivas medições.

**Palavras-chave** – Redes Neurais, Incerteza de Medição, Propagação da Incerteza, Transformadores de Potência, Qualidade Dielétrica.

## 1 Introdução

Os transformadores de potência de grande porte são equipamentos, técnica e economicamente, essenciais em uma planta elétrica de transmissão e distribuição de energia. Assim, esforços vêm sendo empregados para garantir seu bom funcionamento e evitar possíveis falhas que venham a ocorrer devido ao seu ciclo natural de vida ou aos regimes elétricos a que são submetidos. As condições de funcionamento e integridade de um transformador de potência imerso em óleo podem ser estabelecidas a partir da análise do seu óleo isolante. Um conjunto de análises definidas por normas técnicas permite o diagnóstico das condições de falhas do transformador.

O óleo mineral isolante é amplamente usado em equipamentos elétricos assumindo, basicamente, as funções de meio isolante e refrigerante. A primeira função é evitar o aparecimento e garantir a extinção de arcos elétricos, dentre outras falhas. A segunda função é a refrigeração do equipamento, dissipando o calor gerado. A decomposição do óleo mineral isolante submetido a situações de falhas incipientes em transformadores pode produzir os seguintes gases: hidrogênio ( $H_2$ ), metano ( $CH_4$ ), etano ( $C_2H_6$ ), etileno ( $C_2H_4$ ), acetileno ( $C_2H_2$ ), monóxido de carbono ( $CO$ ) e dióxido de carbono ( $CO_2$ ). De acordo com a presença e concentração de cada gás, pode-se inferir quais falhas estão ocorrendo no transformador.

Os métodos mais utilizados de diagnóstico para identificar falhas incipientes em transformadores de potência são a avaliação físico-química (acidez, rigidez dielétrica, teor de água, tensão interfacial, densidade e fator de potência do óleo), que determina o estado do óleo; e as análises cromatográficas, que determinam a presença e concentração de cada gás; ambas auxiliando na análise de possíveis falhas no equipamento.

Por outro lado, a estimação dos gases dissolvidos no óleo por meio de atributos físico-químicos elimina a necessidade da realização do ensaio cromatográfico. Como os fenômenos a serem modelados são caracterizados por ruídos, incertezas nas medidas e não-linearidades, métodos baseados em inteligência computacional e, em especial, redes neurais artificiais, podem ser empregados, em conjunto com métodos tradicionais, para se fazer tal estimação de modo satisfatório [1].

Contudo, o emprego tradicional de redes neurais artificiais não considera o efeito das incertezas de medição das variáveis de entrada, que são propagadas para a saída da rede neural e podem afetar seu desempenho, ou explicar em parte os erros residuais observados após o treinamento das redes. Assim, este artigo apresenta os resultados obtidos por simulações computacionais desenvolvidas a fim de avaliar como a incerteza de medição dos parâmetros de entrada se propaga por uma rede neural e, conseqüentemente, como estas incertezas afetam a saída da rede. O trabalho desenvolvido objetiva trazer confiabilidade metrológica aos resultados inferidos por redes neurais. Como estudo de caso, foram avaliados casos reais [1] empregando características físico-químicas como entradas de redes neurais capazes de inferir a concentração dos gases dissolvidos no óleo dos transformadores de potência.

A metodologia adotada nesse trabalho consiste na definição do experimento a ser analisado, nesse caso a análise do óleo do transformador, obtenção dos dados de entrada do experimento com seus respectivos certificados de garantia, análise da incerteza de medição para cada variável de entrada, análise da propagação desta incerteza na rede neural por meio da perturbação das variáveis de entrada (método numérico), desenvolvimento do experimento utilizando o Matlab, comparação entre os resultados apresentados sem perturbação da incerteza de medição [1] e os resultados após a perturbação e conclusão.

Dessa forma, o trabalho aqui apresentado pretende demonstrar a importância de se considerarem as incertezas de medição das variáveis de entrada da rede neural. Assim, foi realizado um estudo de caso de forma a verificar como as incertezas de medição das variáveis de entrada (características físico-químicas) afetam o desempenho de redes neurais previamente desenvolvidas [1]. A norma utilizada durante a análise foi a NIT-DICLA-021 do Inmetro [3], além de conceitos de metrologia, tendo como base as variáveis de entrada não-correlacionadas, conforme os passos descritos na próxima seção.

## 2 Incerteza de Medição

Os valores referentes às medidas experimentais não são exatos, pois existe uma incerteza de medição intrínseca aos instrumentos utilizados para obtenção destes dados. Essa informação é expressa em certificados de calibração dos instrumentos de medição, esses valores de incerteza de medição causam oscilações nos dados medidos. Assim, é importante conhecer a incerteza de medição presente em qualquer medida, elevando a confiabilidade nos resultados obtidos. O valor real do mensurando está compreendido dentro do valor de incerteza, ou seja, na faixa acima ou abaixo do valor medido, sendo assim os dados devem ser tratados antes de iniciar o experimento evitando que a incerteza seja propagada, causando erros nos resultados finais.

A incerteza de medição pode ser observada em qualquer instrumento de medição, sendo esta a característica mais importante para que o mensurando seja determinado de forma segura e em conformidade com as especificações e normas disponíveis. É necessário determinar e evidenciar os erros e incerteza da medição dos instrumentos utilizados nas inspeções e corrigi-los para que sejam mantidos dentro dos limites aceitáveis, obtendo assim um resultado analiticamente coerente.

Esta fase da análise compreende quatro etapas: 1) especificação do mensurando; 2) identificação das fontes de incerteza; 3) quantificação dos valores de incerteza de cada variável de entrada e 4) cálculo da incerteza combinada.

A Figure 1 apresenta alguns exemplos de onde as incertezas de medições são geradas e o quanto podem afetar o mensurando. A partir dessas informações é possível determinar com maior exatidão o valor do mensurando.

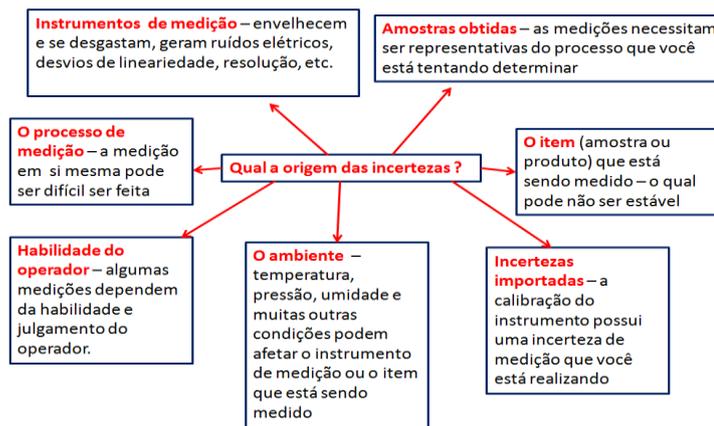


Figura 1 – Fontes de incerteza da Medição

A incerteza do mensurando deve ser determinada a partir do valor médio verdadeiro  $y_{mv}$  da grandeza de saída  $y$ , sendo definido que o valor verdadeiro é  $y_v$ . Sabe-se que em geral o valor verdadeiro é desconhecido (mas a variável é limitada a um intervalo finito) e para que se obtenha o valor médio verdadeiro  $y_{mv}$  são necessárias infinitas medições. Dessa forma, para um conjunto de medidas  $\{y_1, y_2, y_3, \dots, y_n\}$  são utilizados para o cálculo do valor médio verdadeiro de saída, tem-se:

$$y_{mv} = \lim_{N \rightarrow \infty} \frac{\sum_{i=1}^N y_i}{N} \quad (1)$$

A norma do Inmetro NIT-DICLA-021 [3] cita que a incerteza de medição é um parâmetro associado ao resultado de uma medição, que caracteriza a dispersão dos valores que podem ser razoavelmente atribuídos ao mensurando. A incerteza de medição indica diretamente a qualidade da medição sendo importante o conhecimento do seu intervalo de confiança para garantia dos resultados obtidos. Assim, para caracterizar a incerteza de medição é necessário definir dois valores, o intervalo e o nível de confiança ou probabilidade de abrangência, que estabelecerão o quão seguro é o valor verdadeiro nesse intervalo.

No caso de uma rede neural artificial, constrói-se um mapeamento entre as variáveis experimentais de entrada, supostas independentes,  $x_1, \dots, x_n$ , e variável de saída  $y$ , que pode ser representado pela equação (2) a seguir.

$$y = f(x_1, x_2, \dots, x_n) \quad (2)$$

Com base nos conceitos acima citados, a expressão da incerteza padrão combinada  $\mu_c(y)$  para estimativa de saída pode ser definida como:

$$\mu_c^2(y) = \sum_{i=1}^N \mu_i^2(y). \quad (3)$$

$$\mu_i(y) = c_i \mu_{x_i}, \quad (4)$$

onde  $\mu_{x_i}$  é a incerteza de medição da variável  $x_i$  e  $c_i$  é o coeficiente de sensibilidade associado a  $x_i$ .

Por sua vez, o coeficiente de sensibilidade associado à variável de entrada  $x_i$  é definido como a derivada parcial da função de mapeamento  $f$  em relação a  $x_i$ , isto é

$$c_i = \frac{\partial f}{\partial x_i} = \frac{\partial f}{\partial X_i} \Big|_{X_i = x_1 \dots X_N = x_N}. \quad (5)$$

O desenvolvimento deste trabalho conta com resultados obtidos a partir do conceito citado acima para a inserção da incerteza de medição nos dados de entrada (mensurando). Inicialmente foi realizada uma re-análise das redes neurais utilizadas para estimar as concentrações dos gases a partir das características físico-químicas do óleo de transformadores, validando os resultados obtidos. Após essa fase preliminar foram realizados novos testes, nos quais as redes foram perturbadas com os valores de incerteza de medição obtidos em certificados de calibração dos instrumentos utilizados para a obtenção dos dados de entrada. Essa perturbação se deu de forma gradual, com cada variável recebendo uma perturbação ora positiva, ora negativa, permitindo calcular numericamente os coeficientes de sensibilidade, e posteriormente a propagação das incertezas de medição das variáveis de entrada.

### 3 Propagação da Incerteza de Medição em Redes Neurais

Este estudo foi desenvolvido a partir de um conjunto de dados obtidos em [1], e teve o objetivo de demonstrar a importância de considerar a incerteza de medição dos dados de entrada contribuindo para a obtenção de resultados mais confiáveis. A análise foi realizada por meio de uma perturbação sistemática das variáveis de entrada. Os dados de entrada são obtidos com base em análises realizadas em laboratórios acreditados, estando assim a incerteza da medição disponível nos certificados de calibração dos equipamentos correspondentes. De posse dessas informações é possível analisar as redes treinadas a partir da perturbação de cada variável de entrada, bem como determinar a propagação da incerteza de medição pela rede.

Dada uma rede neural adequadamente treinada, a metodologia aqui apresentada para análise da propagação da incerteza das variáveis de entrada nesta rede neural se inicia com a obtenção das incertezas de cada uma de suas variáveis de entrada, por meio dos certificados de calibração das mesmas. De posse dos valores de incerteza das variáveis de entrada da rede, deve-se examinar como a resposta da rede (saída) é alterada em função de perturbações em cada uma das variáveis de entrada. Por sua vez, dada uma entrada  $x_i$ , as perturbações consistem em se fazer

$$x_i' = x_i \pm \mu_{x_i} \quad (6)$$

onde  $\mu_{x_i}$  é a incerteza da variável  $x_i$ , e observar como a saída da rede  $y$  é afetada em função das perturbações  $\mu_{x_i}$  em cada variável de entrada  $x$ :

$$\mu_{y_{x_i}} = y(x_i') - y(x_i) \quad (7)$$

- $\mu_{y_{x_i}}$  representa a variação da saída da rede devido a perturbação nas variáveis de entrada;
- $y(x_i')$  representa a saída da rede para a entrada  $x_i'$  e
- $y(x_i)$  representa a saída da rede para a entrada  $x_i$ .

Repetindo-se este procedimento para as  $n$  variáveis de entrada, obtêm-se os valores de variação da saída  $\mu_{y_{x_i}}$  associados a cada uma delas. Consequentemente, os coeficientes de sensibilidade  $c_i$  podem ser calculados por:

$$c_i = \frac{\mu_{y_{x_i}}}{\mu_{x_i}} \quad (8)$$

Por sua vez, pode-se definir a incerteza combinada  $\mu_c$ , da propagação da incerteza das variáveis de entrada na saída, aplicando-se(3).

### 4 Redes Neurais para Estimção da Concentração de Gases

O estudo de caso apresentado nesta seção tem como objetivo demonstrar a importância de se considerar a incerteza de medição dos dados de entrada de redes neurais por meio de um exemplo real. Neste intuito, empregou-se a análise descrita na seção 3 a uma rede neural desenvolvida para modelar a concentração dos gases dissolvidos no óleo de transformadores de potência (saída) em função de grandezas físico-química (entradas). Conforme citado em [1], foram definidas as características físico-químicas que influenciam na qualidade do óleo isolante. O vetor de entrada a ser aplicado às redes neurais é constituído pelos seguintes elementos: acidez, rigidez dielétrica, teor de água, tensão interfacial, densidade e fator de potência do óleo. As variáveis de saída são obtidas da decomposição do óleo mineral isolante de um transformador de potência em operação, submetido a situações de falhas incipientes, surgindo os seguintes gases a serem considerados: hidrogênio ( $H_2$ ), metano ( $CH_4$ ), etano ( $C_2H_6$ ), etileno ( $C_2H_4$ ), acetileno ( $C_2H_2$ ), monóxido de carbono (CO) e dióxido de carbono ( $CO_2$ ). Conforme descrito na literatura, pode-se inferir a ocorrência de falhas incipientes em transformadores a partir da análise dos valores das concentrações desses gases dissolvidos no óleo dos mesmos. [5, 6, 7]. As variáveis de entrada e suas respectivas incertezas de

medição são indicadas na Tabela 1, além dos valores mínimos e máximos que compõem o conjunto de 251 dados, tendo sido também calculados a média e o desvio padrão das variáveis de entrada.

**Tabela 1** – Variáveis de entrada disponíveis para as redes neurais, juntamente com suas unidades de medida e incertezas de medição

Variáveis de Entrada	Incerteza (U)	Unidade de Medição	Valor Máximo	Valor Mínimo	Valor Médio	Desvio Padrão
Rigidez Dielétrica	0,58	(Kv/0,1)	92,3	15,5	69,056	20,1138
Fator de Potência	1%	%	26,56	0,144	2,3791	3,0695
Tensão Interfacial	0,2	dynas/cm	75,3	19,3	36,1737	7,6115
Densidade	0,0003	(g/cm <sup>3</sup> )	0,8996	0,8652	0,8803	0,009
Teor de água	0,1	(µg H <sub>2</sub> O)	82,9	4,4	20,070	11,439
Acidez	0,00366	(mgKOH/g)	0,6	0,005	0,0398	0,0493

Cada rede neural possui apenas um neurônio de saída, correspondendo à concentração de um gás. Os valores identificados na análise físico-química são considerados as variáveis de entrada, porém nem todos contribuíram para análise e caracterização das falhas. Sendo assim é necessário identificar quais são as variáveis mais significativas para que o diagnóstico de falhas incipientes em transformadores fosse obtido. Para realizar esta tarefa foi utilizado um algoritmo conhecido por busca exaustiva que seleciona os atributos de melhor potencial de predição relacionado a um sistema adaptativo de inferência *neuro-fuzzy* (ANFIS - Adaptive Neuro-Fuzzy Inference Systems). Este sistema de inferência usa a série de dados de entrada e saída para construir um sistema nebuloso, onde as funções de pertinência são ajustadas por um algoritmo *back-propagation* ou este combinado com método dos mínimos quadrados, permitindo que o sistema aprenda os próprios dados de modelagem.

As redes neurais empregadas são do tipo Multi-Layer Perceptron com treinamento pelo algoritmo de Levenberg-Marquardt, tendo sido implementadas em Matlab [2]. As funções de ativação são do tipo tangente hiperbólica. A análise de propagação de incerteza foi avaliada para as sete redes desenvolvidas em [1], uma para cada tipo de gás. Todas as redes avaliadas possuem três entradas, uma camada escondida e uma saída.

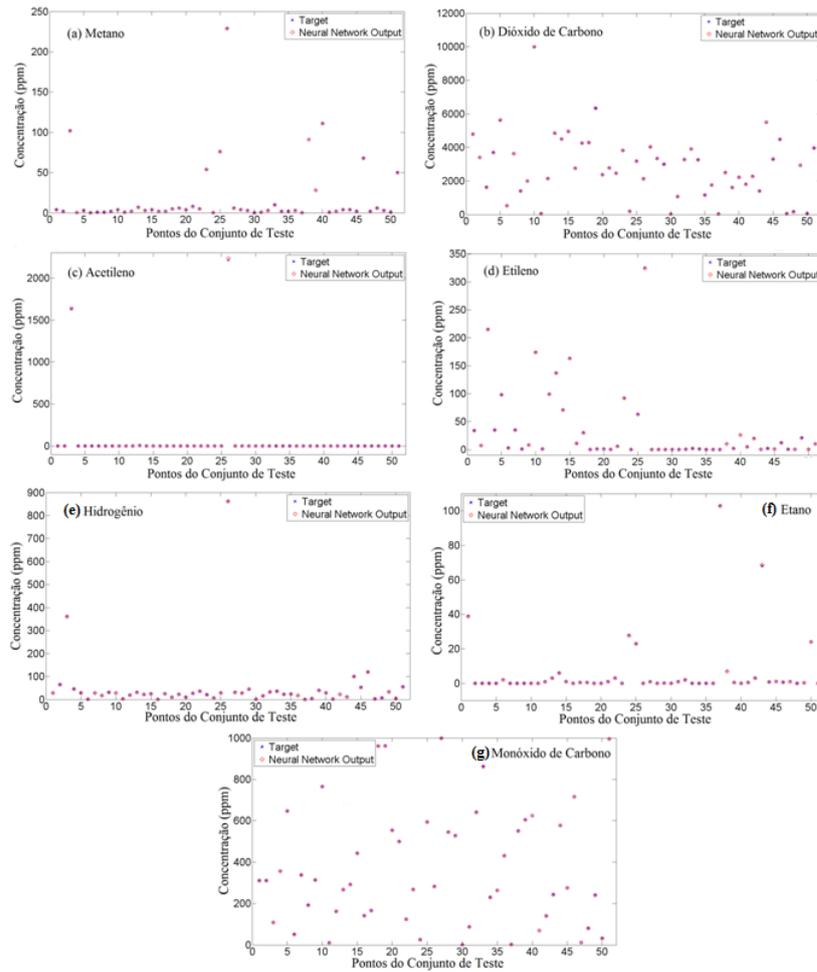
Vale ressaltar a importância do processo de normalização dos dados redimensionando o domínio das entradas da rede para os limites que garantam a convergência. Este processo de normalização dos dados se dá de forma a obter média igual a 0 e desvio padrão igual a 1. Além disso, os 251 padrões de entrada foram divididos conforme o seguinte critério: 140 utilizados no treinamento, 60 validação e 51 para testes. As Figuras 2 e 3 apresentam gráficos comparativos, para dados do conjunto de teste, entre as saídas de cada uma das sete redes desenvolvidas e seus respectivos valores desejados. A Figura 2(a) retrata a rede desenvolvida para estimar a concentração de metano, 2(b) dióxido de carbono, 2(c) acetileno, 2(d) etileno; por sua vez, a 2(e) retrata a rede desenvolvida para estimar a concentração de hidrogênio, (f) etano e (g) monóxido de carbono.

A Tabela 2 apresenta a análise do conjunto de variáveis de saída utilizadas no experimento [1], explicitando seus respectivos valores mínimos, máximos, médios e desvios padrão. Esta Tabela, também, apresenta as respectivas quantidades de neurônios na camada escondida, para cada uma das redes desenvolvidas.

**Tabela 2** – Composição do Conjunto de Variáveis de Saída Disponíveis

Variáveis de Saída	Unidade Medida	Quant. Neurônios Camada Escondida	Valor Mínimo	Valor Máximo	Valor Médio	Desvio Padrão
H <sub>2</sub> (Hidrogênio)	ppm	25	0	1533	49,18	158,52
CH <sub>4</sub> (Metano)		5	0	243	16,22	37,55
CO (Monóxido carbono)		15	0,3	1325	308,47	254,39
CO <sub>2</sub> (Dióxido carbono)		25	24	9973	2880,96	2182,22
C <sub>2</sub> H <sub>4</sub> (Etileno)		25	0	325	31,245	51,80
C <sub>2</sub> H <sub>6</sub> (Etano)		15	0	382	16,09	53,80
C <sub>2</sub> H <sub>2</sub> (Acetileno)		5	0	2215	32,70	229,84

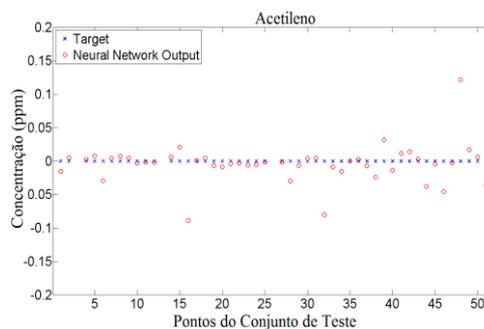
A Figura 2 apresenta gráficos comparativos, para dados do conjunto de teste, entre as saídas de cada uma das sete redes desenvolvidas e seus respectivos valores desejados.



**Figura 2** – Comparação entre as saídas das redes neurais, utilizadas para modelar a concentração dos gases, e seus respectivos *targets*. (a) Metano, (b) Dióxido de Carbono, (c) Acetileno, (d) Etileno, (e) Hidrogênio, (f) Etano, (g) Monóxido de Carbono.

Observando-se a Figura 2, verifica-se que todas as sete redes desenvolvidas modelam satisfatoriamente bem as concentrações gasosas, visto que as saídas das redes são muito próximas de seus respectivos valores-alvo. Também, nota-se que os padrões de saída das redes utilizadas para modelar as concentrações de dióxido de carbono e monóxido de carbono são os mais homogêneos distribuídos. Por outro lado, os padrões de saída da rede utilizada para modelar o acetileno apresentam grande concentração em torno de 0 ppm. Destaca-se que redes neurais treinadas com padrões mal distribuídos pelo espaço amostral tendem a apresentar dificuldades de generalização.

Os resultados apresentados na Figura 2 não permitem que se verifique visualmente o erro de aproximação das redes, por modelarem extremamente bem o conjunto de dados. Dessa forma, a fim de se permitir a visualização do erro de ajuste, apresenta-se, por exemplo na Figura 3 a rede que modela a concentração de acetileno, com destaque na região entre  $\pm 0,2$  ppm, evidenciando o quão pequeno é o erro residual desta rede, o qual em geral é inferior a 0,1 ppm. Este fato se repete para as demais redes analisadas, sendo que, para que o erro entre a saída das redes e os alvos seja efetivamente visualizado deve-se dar um zoom em torno da região de interesse.



**Figura 3** – Zoom na vizinhança de 0 ppm da figura 2(c).

A Tabela 3 apresenta os resultados da aplicação do método de propagação das incertezas, introduzido na seção 3, a cada uma das sete redes neurais apresentadas acima .

**Tabela 3** – Análise do Comportamento dos Gases Após a Perturbação de Cada Variável de Entrada

Gás	Variáveis Entrada	Incerteza (U)	Sensibilidade (C)	RMSE s/perturbação	RMSE c/Perturbação		Incerteza Combinada
					+ U	- U	
Metano	Rigidez Dielétrica	0,58	-1,0326	0,0065	+ U	0,5989	Figura 4(a)
					- U	0,5993	
	Fator de Potência	1%	-0,9899		+ U	0,0395	
			- U	0,0407			
	Densidade	0,0003	-0,9834	+ U	0,0065		
				- U	0,0065		
Acetileno	Rigidez Dielétrica	0,58	-0,3016	0,5775	+ U	0,6022	0,2152
					- U	0,614	
	Tensão Interfacial	0,2	-0,6264		+ U	0,5923	
			- U	0,5962			
	Densidade	0,0003	0,9506	+ U	0,5775		
				- U	0,5775		
Hidrogênio	Rigidez Dielétrica	0,58	-0,9192	0,077	+ U	0,5342	0,573
					- U	0,5374	
	Teor de água	0,1	-0,9553		+ U	0,096	
			- U	0,0979			
	Tensão Interfacial	0,2	-0,9349	+ U	0,1875		
				- U	0,1894		
Monóxido de Carbono	Tensão Interfacial	0,2	-0,9638	0,0084	+ U	0,1925	Figura 4(d)
					- U	0,1936	
	Densidade	0,0003	-0,9515		+ U	0,0084	
			- U	0,0085			
	Fator de Potência	1	-0,9508	+ U	0,0382		
				- U	0,0413		
Dióxido de Carbono	Rigidez Dielétrica	0,58	-0,3354	9,3659	+ U	9,3231	0,2522
					- U	9,4151	
	Tensão Interfacial	0,2	-0,8024		+ U	9,2614	
			- U	9,4726			
	Densidade	0,0003	-0,1564	+ U	9,366		
				- U	9,3659		
Etileno	Rigidez Dielétrica	0,58	0,8927	0,0038	+ U	0,5169	Figura 4(b)
					- U	0,5214	
	Tensão Interfacial	0,2	-0,9383		+ U	0,1879	
			- U	0,1884			
	Fator de Potência	1	-0,9684	+ U	0,0351		
				- U	0,0358		
Etano	Acidez	0,00366	-0,9958	0,0041	+ U	0,0054	Figura 4(c)
					- U	0,0055	
	Rigidez Dielétrica	0,58	-0,594		+ U	0,3498	
			- U	0,3612			
	Fator de Potência	0,0003	-0,9915	+ U	0,0325		
				- U	0,0328		

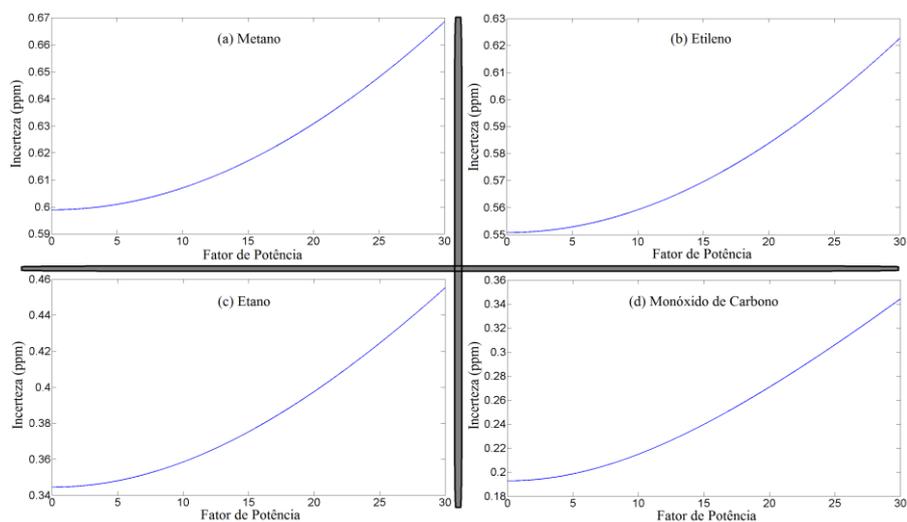
Os valores expressos na coluna sensibilidade, da Tabela 3, retratam o quão sensível a saída da rede é em relação à respectiva entrada. Por exemplo, a rede utilizada para modelar o acetileno tem como variáveis de entrada: rigidez dielétrica, tensão interfacial e densidade; cujas sensibilidades, em módulo, são respectivamente: 0,30; 0,63 e 0,95. Dessa forma, verifica-se que a variável de entrada que mais influencia a saída desta rede é a densidade, seguida pela tensão interfacial e, por último, a rigidez dielétrica. No entanto, o termo mais significativo da incerteza combinada, equação (3), será aquele que apresentar o maior produto entre a sensibilidade e sua respectiva incerteza. Desta forma, ainda para a rede do acetileno, tem-se que o termo mais significativo da incerteza combinada será relacionado à rigidez dielétrica, seguido daquele associado à tensão interfacial, e por último o da densidade, cujos produtos sensibilidade vezes incerteza valem respectivamente: 0,175; 0,125 e 0,000285. Ou seja, um ordenamento inverso aos valores de sensibilidade. Este fato é explicado pela incerteza da variável densidade, variável à qual a saída da rede é mais sensível, ser muito menor que as demais, fazendo com que o seu produto sensibilidade vezes incerteza torne-se menor do que aqueles obtidos para tensão interfacial e rigidez dielétrica.

No caso do monóxido de carbono, verifica-se que a sensibilidade da saída da rede em relação às três variáveis de entrada é quase igual, sendo que pode-se inferir que o termo mais significativo da incerteza combinada será aquele relacionado à variável de entrada que possuir a maior incerteza, no caso a tensão interfacial.

A Tabela 3 também apresenta o valor do erro médio quadrático (RMSE), para todas as redes analisadas. A coluna denominada RMSE sem perturbação refere-se ao RMSE obtido após o treinamento das redes. Por outro lado, a coluna RMSE com perturbação apresenta os valores obtidos ao se aplicar as perturbações nas variáveis de entrada. Nesta análise verificou-se a variação do RMSE tanto para perturbações positivas ( $x_i + \mu_i$ ) quanto negativas ( $x_i - \mu_i$ ) em torno de cada uma das variáveis de entrada ( $x_i$ ). Comparando-se os valores destas duas colunas pode-se verificar de forma direta como a incerteza de medição de cada uma das variáveis de entrada afetaria a saída de sua respectiva rede. Pode-se inferir que, para uma dada rede, o RMSE será mais afetado por perturbações naquelas variáveis de entrada que apresentarem o maior produto: coeficiente de sensibilidade ( $c$ ) vezes incerteza de medição ( $\mu$ ).

Observando-se a Tabela 3 percebe-se que os valores de RMSE obtidos para o dióxido de carbono foram muito superiores àqueles obtidos para os demais gases. Este fato é atribuído aos valores de concentração, em ppm, do dióxido serem muito maiores do que os verificados para os demais gases, e a observação dos valores expressos na coluna *valor médio* da Tabela 3 reforça esta constatação. Ou seja, apesar de em termos absolutos os valores do RMSE obtidos para o dióxido aparentarem elevados, em termos percentuais o RMSE do dióxido é equivalentes aos dos demais gases.

Os valores de incerteza combinada apresentados na Tabela 3 foram obtidos empregando-se (3), sabendo-se que as variáveis de entrada das redes analisadas são aleatoriamente independentes entre si. Estes valores representam a contribuição da incerteza das variáveis de entrada para a incerteza total de saída da rede. Assim como indicado na Tabela 3, a Figura 4 apresenta as incertezas combinadas dos gases metano, etileno, etano e monóxido de carbono. Conforme explicitado nesta Tabela, as redes neurais desenvolvidas para modelar a concentração destes quatro gases possuem o fator de potência como uma de suas variáveis de entrada. Dentre as seis possíveis variáveis de entrada, a única que não possui um valor de incerteza fixo ao longo de toda a sua faixa de valores é o fator de potência, para o qual o valor da incerteza é expresso em termos percentuais. Dessa forma, sabendo que a incerteza do fator de potência é 1%, e que as medidas do mesmo apresentaram valores entre 0,144 e 26,56, pode-se inferir que, em valores absolutos, a incerteza do valor de potência assume valores entre 0,00144 e 0,2656. Como a incerteza combinada da saída da rede, dada por (3), utiliza a incerteza de todas as variáveis de entrada da rede, percebe-se que, para casos nos quais a incerteza de uma ou mais variáveis de entrada não seja constante, a incerteza combinada da saída será função desta(s) variável(eis), como é o caso das redes que possuem o fator de potência como variável de entrada.



**Figura 4** – Incertezas combinadas das saídas das redes em função do fator de potência (a) Metano, (b) Etileno, (c) Etano e (d) Monóxido de Carbono.

## 5 Conclusões

O processamento e análise da incerteza de medição poderiam ser realizados através do método analítico ou método numérico. O presente trabalho apresentou um novo método de análise da propagação da incerteza de variáveis de entrada independentes em redes neurais. Também foi apresentado um estudo de caso, de forma a exemplificar a aplicação do método aqui proposto, baseado em redes neurais desenvolvidas para modelar a concentração de gases dissolvidos no óleo de transformadores de potência [1].

Os resultados obtidos ressaltam a importância de se considerar a incerteza das variáveis de entrada e de se estimar o impacto destas na incerteza da(s) saída(s). Esta análise eleva a confiabilidade nas estimativas realizadas pelas redes neurais, uma vez que se passa a associar um valor de incerteza à resposta da rede. Quando se utiliza uma rede neural para estimar um

parâmetro que é função de uma série de variáveis de entrada, deve-se conhecer a incerteza associada a cada uma destas variáveis, de forma a se poder estimar a incerteza da saída.

O método proposto também permite que se identifiquem quais as entradas da rede que mais contribuem para a incerteza de saída, sendo que as variáveis de entrada que apresentarem os maiores valores de sensibilidade, ou seja, aquelas variáveis que mais afetam a saída, idealmente devem possuir os menores valores de incerteza. Assim, pode-se avaliar quais dos instrumentos pertencentes a uma cadeia de medição estão contribuindo mais significativamente para a incerteza do parâmetro estimado pela rede. Dessa forma, é possível estabelecer uma política de planejamento que priorize a substituição daqueles equipamentos de medição que estão efetivamente limitando a incerteza do sistema.

Em trabalhos futuros pretende-se expandir a generalidade do método aqui desenvolvido, de forma a torná-lo, também, aplicável à análise da propagação da incerteza em redes neurais com variáveis de entrada dependentes entre si. Bem como o desenvolvimento da análise teórica do tema.

## 6 Referência

- [1] Barbosa, F. R. - Monitoramento on-line e diagnóstico inteligente da qualidade dielétrica do isolamento líquido de transformadores de potência. **Dissertação de Mestrado, UFC/CE/DEE – Departamento de Energia Elétrica, CE, (2008).**
- [2] Demuth, H. and Beale, M. Neural network toolbox for use with MATLAB, **MathWorks**, 846 pp., (2000).
- [3] Inmetro - NIT-DICLA-021: Expressão da Incerteza de Medição, **Norma Inmetro (2003).**
- [4] Mohd, J. B. J. – Uncertainty Analysis of Artificial Neural Network (ANN) Aproximated Function for Experimental Data Using Sequential Perturbation Method, **Dissertação (2009).**
- [5] Duval, M.; Dissolved Gas Analysis: It can save your transformer, **Dissertação (1989).**
- [6] Wang, Z. Artificial Intelligence Applications in the Diagnosis of Power Transformer Incipient Faults. **PhD Thesis, Virginia Polytechnic Institute and State University, Blacksburg, USA, 105 p, (2000).**
- [7] Zhang, Y. An Artificial Neural Network Approach to Transformer Fault Diagnosis, **Thesis, Virginia Tech, Blacksburg, USA, (1996).**