
MODELAGEM: UMA ABORDAGEM TEÓRICA PARA A CALIBRAÇÃO AUTODIDATA DE SENSORES EM REDE

Antonio Marcos Ferraz de Campos*

Oséas Avilez**

Resumo

A modelagem de um processo de calibração autodidata robusta e não invasivo compreende a conclusão de processo de coleta, análise e decisão sobre a calibração, com base nos dados oriundos da própria medição/supervisão/monitoração de grandezas físicas medidas, sem intervenção externa de qualquer natureza. Trata-se de um modelo de processo estocástico que envolve séries temporais com a “fusão de dados”, no qual se aplica a técnica de controle adaptativo de sistemas dinâmicos em tempo discreto, utilizando o processo de identificação de sistemas com a finalidade de reconhecer, por meio de uma “caixa-preta”, a rede de sensoriamento instalada com característica desconhecida. A proposta prevê a eliminação de *outliers* e a análise do desempenho dos algoritmos adaptativos, objetivando a minimização da sua função custo, pelo método do gradiente estocástico com filtro FIR (transversal), em comparação com o procedimento calibração “ótimo” dado pelo utilização do filtro de Kalman. Por fim, a avaliação da calibração dos sensores individuais é feita por meio do controle estatístico de incertezas produzidas e pela predição da tendência, com estimação não paramétrica, da variação dos resultados de calibração autodidata da rede de sensores *wireless* ao longo da vida operacional (útil).

Palavras-chave: Modelagem, calibração autodidata, sensores em rede.

* Universidade Presbiteriana Mackenzie (UPM).

** Universidade Estadual de Campinas (Unicamp). Agradecemos ao Prof. Dr. Marco Antonio de Assis Melo as críticas, discussões e contribuições nos procedimentos de implementação dos processos de filtragens.

1 INTRODUÇÃO

O objetivo deste artigo é definir um modelo de calibração autodidata² robusta de sensores em redes *wireless* (IEEE 802.15.4), o qual deve ser aplicado de forma automática. Trata-se de um processo não invasivo em que não se utilizam recursos determinísticos de instrumentação externa.

A importância, o interesse e a pertinência deste trabalho vêm de sua aplicabilidade, principalmente quando as redes de sensores forem instaladas em pontos remotos de difícil acesso e/ou inóspitos e sem infraestrutura local, ou seja, em situações em que a medição é feita com uma rede de sensores sem fio (RSSF) ou há o risco de não fazê-la.

Portanto, a necessidade em saber se os resultados das medições feitas remotamente são confiáveis, quando analisadas em ponto centralizado (base), é que motiva a modelagem para a calibração autodidata dos sensores em rede. Levando-se em conta as próprias medidas do processo monitorado/medido, extrai-se o conhecimento para a escolha de um sensor de referência, e, a partir daí, identificam-se os sensores considerados calibrados, com a qualidade e confiabilidade adequadas ao serviço prestado e ao propósito da rede (ZIG BEE, 2009; GUM; ABNT; INMETRO, 2003; BALZANO, 2007a, 2007b; CAMPOS, 2003; MOSCATI, 2005).

2 METODOLOGIA PARA DESENVOLVIMENTO DA SOLUÇÃO

Entre as teorias “experimental” e “fenomenológica”, filosoficamente se optou pela primeira, seguindo a orientação do empirismo (VUOLO, 1996; FENG; POTKONJAK; QU, 2004; MORETIN; TOLOI, 2006; POINCARÉ, 2008) que leva em conta as evidências, os efeitos práticos sensíveis e as técnicas do raciocínio indutivo (VANIN; GOUFFON, 2008).

As ciências empíricas caracterizam-se por serem indutivas, embora recorram também à dedução que se constitui no cerne das ciências formais (lógica e matemática).

Como o método indutivo-dedutivo é um procedimento básico da ciência empírica, cujas formas de inferência indutiva são fundamentadas nas probabilidades, esse

² A calibração *autodidata* é também conhecida como *blind* ou “não supervisionada”.

procedimento, analogamente, é utilizado na explicação da natureza – como um dos pontos fundamentais que se buscam por meio da indução: *a regularidade* (BENETH, 2003; MAIA, 2007; COSTA, 1993).

Nesse contexto, adotou-se o modelo probabilístico (VUOLO, 1996), considerando a possibilidade de que a variável a ser estudada ocorra com alguma *incerteza*.

3 MODELO DE CALIBRAÇÃO AUTODIDATA DE SENSORES

3.1 Considerações gerais

O conhecimento prévio do posicionamento do conjunto de sensores (RSSF) inteligentes é necessário para a sua identificação e a formação do(s) *cluster(s)* tanto na coleta como na análise das medidas dos sensores observados (FENG; POTKONJAK; QU, 2004).

Um ciclo de calibração corresponde a um conjunto de k instantâneos (*snapshots*), e a cada instantâneo corresponde um conjunto de n sensores com suas medidas.

Durante o período de vida útil da RSSF, ocorrerão vários ciclos de calibração, cuja periodicidade dependerá das necessidades exigidas pelo processo ou fenômeno monitorado/supervisionado. Nessas condições, os sensores podem ter o seu desempenho mantido ou degradado, refletido pela série histórica de suas calibrações.

Portanto, para se obter a confiabilidade dos resultados das medições, os sensores devem ser calibrados periodicamente, de preferência mantendo as condições de ambientação, como coleta de dados feita nos mesmos horários (GUM; ABNT; INMETRO, 2003).

A opção pela calibração automática (*on-line*) deve ser entendida como um *modo de operar* em função da facilidade/agilidade em fazer a calibração a qualquer momento, por meio da integração de processos via conexão de comunicação (*gateway*) dos sistemas aplicativos de *calibração autodidata automática da RSSF (main)* e *supervísório da base central (sink) da RSSF*.

Em análise preliminar (*a priori*) das medidas para calibração, considerou-se um *processo estocástico não estacionário de segunda ordem* que pode ser caracterizado por uma distribuição gaussiana (MORETIN; TOLOI, 2006), como indicado na fórmula apresentada a seguir (GUM; ABNT; INMETRO, 2003; ABNT, 2005).

$$\text{Medida } [y] = \text{média}[\bar{y}] + \text{ruído branco}[\varepsilon]$$

3.2 Descrição do modelo

Nos resultados de medição de um grupo de sensores em uma determinada área (*cluster*), estabelece-se a hipótese de que haverá certa regularidade, com determinada probabilidade de acontecer, condicionada a um intervalo de confiança, e extrai-se daí um conhecimento para definir o sensor de referência do *cluster*.

Nesse modelo, a calibração será tratada como um processo estocástico, definida anteriormente, de comparação dinâmica das amostras medidas pelos sensores simultaneamente nos momentos de tempo discretos equiespaçados.

A Figura 1 indica uma área de sensoreamento, em que S é o conjunto de sensores que indicam os sinais contínuos do mensurando, e, ao lado, apresentam-se os sinais amostrados em tempo discretos.




Figura 1 Processo contínuo com medições discretas.

As quantidades n (sensores lidos em cada instantâneo – *snapshot*) e k (instantâneos tomados ao longo do tempo) representam o fenômeno medido, de acordo com a frequência de amostragem (Nyquist).

Como a base central da RSSF que gerencia todo o processo de medição está *on-line* com o processo de sistema de calibração autoidadada da RSSF, que detecta a quantidade mínima ($n \geq 3$ sensores e $k \geq 3$ instantâneos) de dados que possibilite a calibração, pode-se dar início imediato ao processamento do lote (*batch*) lido das amostras de sinais daquele *cluster* considerado (FENG; POTKONJAK, QU, 2004).

A seguir, apresenta-se a descrição sucinta do modelo por meio dos passos, compreendendo um conjunto de procedimentos e programas: MED (medição), EST (estimação), ANA (análise) e TEN (tendência) (Figura 2).

- Passo 1 – *Leitura das medidas* (MED): faz-se a leitura *on-line* dos dados para a matriz $Y[n,k]$ provenientes da RSSF, que serão os insumos para todo o modelo do processo. São armazenados na matriz de medição para que o programa gerenciador da aplicação (*main*) inicie o processo de calibração autoidadada.

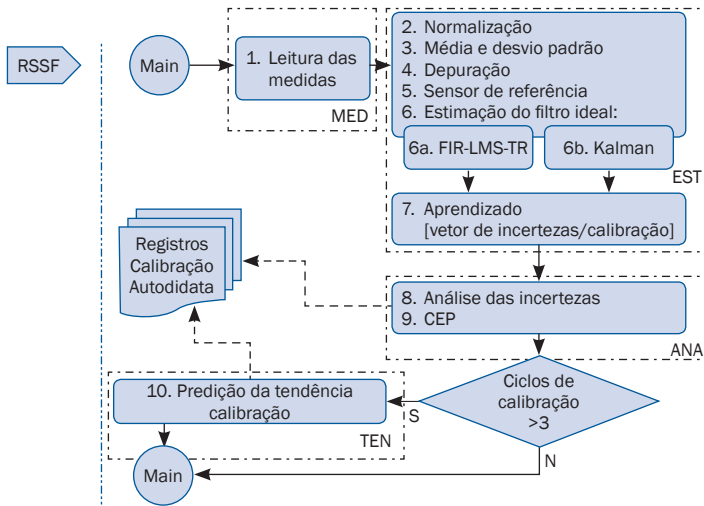


Figura 2 Fluxograma de modelagem do processo de calibração.

• Passo 2 – *Normalização dos dados*: visando a comparações entre os sensores, dentro do *cluster*, é necessário trabalhar com a mesma base espacial, portanto normaliza-se para y^N todos os valores medidos, tendo como y_{\min} e y_{\max} os valores mínimo e máximo lidos, respectivamente.

$$y^N = \frac{y_i - y_{\min}}{y_{\max} - y_{\min}}$$

• Passo 3 – *Média e desvio padrão*: definiram-se os limites inferior e superior, e seu limite de incerteza máximo de três desvios. Dessa forma, faz-se um primeiro nível de depuração dos *outliers*, considerados severos (MURTEIRA, 1993), que correspondem a sensores com defeito ou contêm uma incerteza além do permitido e que, portanto, estarão entre os sensores descalibrados. Os sensores restantes, aparentemente, estarão no rol dos sensores em condições de participar do processo de calibração propriamente dito, pois estes estarão em condições de produzir conhecimento em função do próprio sensor e de seus vizinhos, além de suas mútuas influências, trabalhadas pelo conceito de inteligência do “enxame” (*swarm*) dentro do *cluster*.

• Passo 4 – *Depuração dos dados*: da necessidade de trabalhar com os dados com um mínimo de ruído, deve-se refinar a depuração, num segundo nível, dos dados aplicando-se o critério de Chauvenet (VUOLO, 1996). Nesse caso, foi assumido que esses sensores estão com defeitos e são considerados também *outliers*, portanto serão

sensores excluídos do processo de calibração (GUM; ABNT; INMETRO, 2003; VANIN; GOUFFON, 2008).

- Passo 5 – *Sensor de referência*: é fundamental que se reforce a diferença da calibração convencional da calibração autodidata em uma RSSF. Esta última é feita por meio da comparação com os resultados da referência extraída do conhecimento da própria rede de sensores, assumindo que esta tenha o mesmo nível hierárquico rastreável (COOMBS JR., 1995; VIM, 2010; ABNT, 2005). Portanto, mantém-se a aderência ao que já está estabelecido em normas internacionais como parte da proposta de uma solução para a calibração autodidata. Será adotado como referência aquele que apresentou a menor distância euclidiana em relação à média das medidas dos vários sensores, dentro do *cluster* considerado. Essa operação pode ser representada pela norma euclidiana:

$$\|d_i\|_2 = \left(\sum_1^k |\bar{y} - s_i|^2 \right)^{1/2}$$

- Passo 6 – *Estimação do filtro ideal*: cada *cluster* de sensores deve ter a sua referência/padrão, sendo todos eles perfeitamente localizados e identificados (GUM; ABNT; INMETRO, 2003; FENG; POTKONJAK; QU, 2004; PINA, 1995). Neste ponto, é necessário interpretar as medidas para explicar o modelamento da RSSF instalada, esquematicamente representado na Figura 3. Como os parâmetros (*gain* e *off-set*) dos conversores A/D dos sensores da rede são desconhecidos, serão representados pelos filtros adaptativos nos modelos dinâmicos.

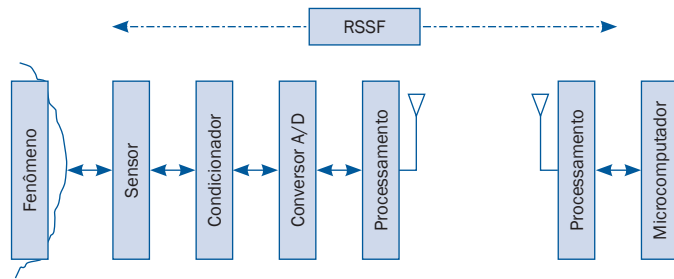


Figura 3 Elementos componentes da RSSF.

- Passo 6a – *FIR LMS “ideal”*: na montagem transversal, o filtro utilizado é o FIR (Figura 4), que tem a finalidade de fazer a estimação dos coeficientes/pesos (*w*) do filtro, visando calcular o filtro que represente o aprendizado correto com base nas características dinâmicas do sinal medido pelo sensor de referência definido no passo anterior.

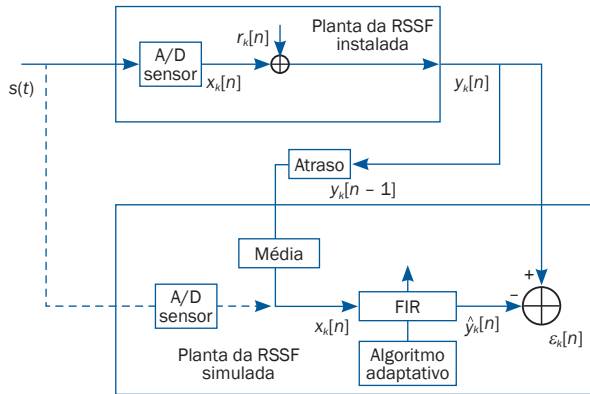


Figura 4 Modelo para referência de calibração autodidata.

Com o vetor X_k dando entrada no filtro adaptativo, inicia-se propriamente a calibração. A caracterização da filtragem digital adaptativa, por meio de um sistema dinâmico representado por um filtro linear adaptativo, tem sua identidade com a RSSF instalada na seguinte equação:

$$\hat{Y}[k,1] = W[k,m].X[m,1]$$

$$\hat{Y}[k,1] = \begin{bmatrix} \hat{y}[0] \\ \hat{y}[1] \\ \hat{y}[2] \\ \vdots \\ \hat{y}[k-1] \end{bmatrix}_{k \times 1} = \begin{bmatrix} x[0] & 0 & 0 \\ x[1] & x[0] & 0 \\ x[2] & x[1] & x[0] \\ \vdots & \vdots & \vdots \\ x[k-1] & \dots & x[k-1-m] \end{bmatrix}_{k \times m} \begin{bmatrix} w[0] \\ w[1] \\ \vdots \\ w[m-1] \end{bmatrix}_{m \times 1}$$

A equação matricial que representa o ajuste da incerteza/erro para o algoritmo do gradiente estocástico (LMS) utilizado no processo é a seguinte:

$$\varepsilon[k] = Y[k] - \hat{Y}[k]$$

$$\begin{bmatrix} \varepsilon[0] \\ \varepsilon[1] \\ \varepsilon[2] \\ \vdots \\ \varepsilon[k-1] \end{bmatrix}_{k \times 1} = \begin{bmatrix} y[0] \\ y[1] \\ y[2] \\ \vdots \\ y[k-1] \end{bmatrix}_{k \times 1} - \begin{bmatrix} \hat{y}[0] \\ \hat{y}[1] \\ \hat{y}[2] \\ \vdots \\ \hat{y}[k-1] \end{bmatrix}_{k \times 1}$$

No processo de medição com o sensor, existem fontes que determinarão a incerteza do resultado da medição, que será maior do que aquela incerteza encontrada no processo de calibração do sensor. Portanto, vamos estimar os coeficientes do filtro ideal.

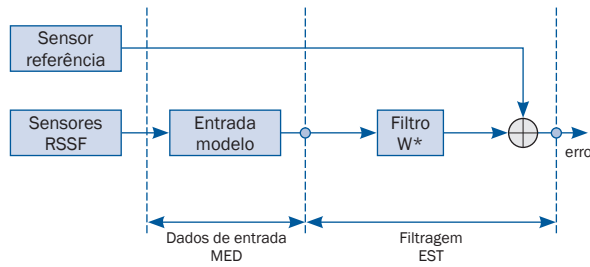


Figura 5 Modelo para filtragem.

Com as amostras de cada sensor na entrada do filtro ideal definido pelo modelo anterior (W), feita a filtragem do sinal, adotam-se para o filtro os coeficientes fixos ($W^* = W$). Compara-se dinamicamente com o sensor de referência, que é o sinal desejado, resultando, na saída, no vetor das incertezas do aprendizado.

- Passo 6b – *Filtro de Kalman*: é um procedimento matemático, considerado *ótimo*, representado por um conjunto de equações recursivas, descritas em termos de espaço de estados, aplicado aos sistemas/processos estacionários ou não. Foi aqui aplicado devido à sua capacidade de rápida adaptação (HAYKIN, 2002; WIDROW; STEARNS, 1985; GREWAL; ANDREWS, 2008):

- atualização do tempo discreto

$$x[n+1] = T[(n+1),n].x[n] + v_1[n]$$

em que T é a matriz de transição de estados, e v_1 , ruído do processo de transição;

- e correção da medida

$$y[n] = Y[n].x[n] + v_2[n]$$

em que v_2 é ruído do processo de correção.

- Passo 7 – *Aprendizado real para a calibração*: calculado o vetor de incertezas da calibração, que corresponde às possíveis diferenças entre as medidas estimadas pelos

dois métodos (6a, 6b), em relação às medidas do sensor de referência, passa-se a analisar comparativamente o aprendizado *ótimo* com o real do modelo proposto. Os processos iterativos que buscam a solução otimizada dão robustez ao resultado da calibração autodidata dos sensores da RSSF. As duas proposições já fazem estimativas, levando em conta as contribuições das perturbações/interferências que tornam o processo ruidoso (como covariâncias e incertezas aleatórias e sistemáticas) de calibração (SAYED, 2003).

- Passo 8 – *Análise das incertezas*: como essas variações, no vetor das incertezas representado por $f(\varepsilon_1, \varepsilon_2, \dots, \varepsilon_N)$, podem ser assumidas como seguindo uma gaussiana (VUOLO, 1996) – ver teorema de Lindberg-Feller (VUOLO, 1996) –, então esse processo será tratado com a técnica do controle estatístico do processo (CEP). O teorema de Lindeberg-Feller que traduz a conclusão pode ser anunciado como segue:

Incertezas aleatórias independentes ε_k foram admitidas como tendo distribuições de probabilidade quaisquer com variâncias finitas, e tais que nenhum ε_k particular é muito maior que os demais. Nestas condições, a incerteza/erro total somatório dos ε_k , a distribuição de erros converge para uma distribuição gaussiana, no limite de $k \rightarrow \infty$.

Sendo assim, calculam-se as suas estatísticas para controle das incertezas da calibração.

- Passo 9 – *CEP para calibração autodidata – relatórios/gráficos do controle estatístico do processo de calibração dos sensores da rede*: a partir deste ponto, pode-se concluir que, quando se aplica o teste de hipóteses e se indicam os *níveis de confiança*, é possível garantir para as $y[k]$ as medidas de cada sensor. Nesse caso, pode-se afirmar que está “ok” (sensor calibrado) e, em caso contrário, “não ok” (sensor descalibrado). Os gráficos individuais, para cada sensor, em cada ciclo de calibração, permitem também detectar possíveis compensações das incertezas provenientes de deriva (*drift*) dos sensores que pudessem alterar resultados, mascarando assim o resultado de desempenho da calibração dos sensores da rede.

- Passo 10 – *Predição de tendência da calibração autodidata*: ampliando um pouco mais o conceito de calibração, para complementar a gestão do sistema da qualidade, sugere-se o acompanhamento dos vários ciclos consecutivos de calibração, pelo menos a cada três ciclos, para que se possa fazer uma previsão de futuros resultados, antecipando possíveis problemas de calibração.

A consequência secundária desta análise é permitir de forma pragmática alterar ou manter a *periodicidade* das calibrações autodidatas futuras feitas ao longo do tempo de vida útil da rede de sensores (MORETIN; TOLOI, 2006; CONOVER, 1999; CAMPOS, 2003).

MODELING: A THEORETICAL APPROACH FOR THE AUTODIDACT CALIBRATION OF NETWORKED SENSORS

Abstract

The proposed modeling of a autodidactic calibration process non-invasive means completion of the entire process of data collection, analysis, decision on the calibration, based on data from the actual measurement/supervision/monitoring of physical measures without outside intervention of any kind. This is a model of stochastic process involving time series, with "data fusion", using the technique of adaptive control of dynamic systems, discrete time, using the process of system identification in order to recognize, through a "black box" installed sensing network with characteristic unknown. The proposal was made by the performance of adaptive algorithms and extracting outliers, aiming at the minimization of its performance function, the stochastic gradient method with FIR filter (transversal), compared with calibration procedure "optimal" given by the use of the Kalman filter. Finally, the evaluation of calibration of individual sensors through the control of statistical uncertainties produced, and the predicted trend, with non-parametric estimation, the degradation of the calibration results of the self-taught network of sensors wireless throughout the time span.

Keywords: Modeling, autodidact calibration, network of sensors.

REFERÊNCIAS

ABNT. NBR ISO/IEC – 17025:2005 – requisitos gerais para competência de laboratórios de ensaio e calibração. São Paulo: ABNT, 2005.

BALZANO, L. K. *Addressing fault and calibration in wireless sensor networks*. 2007. Thesis (Master of Science in Electrical Engineering)–University of California, Los Angeles, 2007a.

_____. *Blind calibration of sensor network*. IPSN'07 April 25-27, 2007. Cambridge, MA, 2007b.

BENETH, D. J. *Aleatoriedade*. São Paulo: Martins Fontes, 2003.

- CAMPOS, A. M. F. *Modelo para avaliação preditiva de desempenho de processos e aplicação para linhas digitais de dados*. 2003. 100 p. Dissertação (Mestrado em Engenharia Elétrica)–Universidade Estadual de Campinas, Campinas, 2003.
- CONOVER, W. J. *Practical nonparametric statistics*. 3. ed. New York: John Wiley & Sons, 1999.
- COOMBS JR., C. F. *Electronic instrument handbook*. 2. ed. Singapore: McGraw-Hill, 1995.
- COSTA, N. C. *Lógica indutiva e probabilidade*. 2. ed. São Paulo: Hucitec, Edusp, 1993.
- FENG, J.; POTKONJAK, M.; QU, G. *Sensor calibration using nonparametric statistical characterization of error models*. Los Angeles: IEEE, 2004.
- GREWAL, M. S.; ANDREWS, A. P. *Kalman filtering*. 3. ed. New Jersey: John Wiley, 2008.
- GUM; ABNT; INMETRO. *Guia para a expressão da incerteza de medição*. 3. ed. São Paulo: GUM, ABNT, Inmetro, 2003.
- HAYKIN, S. *Adaptive filter theory*. 4. ed. New Jersey: Prentice Hall, 2002.
- MAIA, N. F. *A ciência por dentro*. 7. ed. Petrópolis: Vozes, 2007.
- MORETIN, P. A.; TOLOI, C. M. C. *Análise de séries temporais*. 2. ed. São Paulo: Edgard Blücher, 2006.
- MOSCATI, G. As bases científicas da metrologia e vice-versa. In: ENCONTRO PARA A QUALIDADE DE LABORATÓRIOS DO ESTADO DE SÃO PAULO-REMESP, 2005, São Paulo. São Paulo: Remesp, 2005.
- MURTEIRA, B. J. F. *Análise exploratória de dados, estatística descritiva*. Lisboa: McGraw-Hill, 1993.
- PINA, H. *Métodos numéricos*. Lisboa: McGraw-Hill, 1995.
- POINCARÉ, H. *Ensaio fundamentais*. Rio de Janeiro: Contraponto, Editora PUC-Rio, 2008.
- SAYED, A. H. *Fundamentals of adaptive filtering*. New Jersey: IEEE Press, 2003.
- VANIN, V. R.; GOUFFON P. *Tópicos avançados em tratamento estatístico de dados em física experimental*. São Paulo, 2008.
- VIM. Disponível em: <http://www.inmetro.gov.br/metCientifica/vim/vim_completo.pdf> dez 2008>. Acesso em: 22 jan. 2010.
- VUOLO, J. H. *Fundamentos da teoria de erros*. 2. ed. rev. ampl. São Paulo: Edgard Blücher, 1996.
- WIDROW, B.; STEARNS, S. D. *Adaptive signal processing*. New Jersey: Prentice-Hall, 1985.
- ZIG BEE. Specification. Disponível em: <<http://www.nd.edu/~mhaenggi/ee67011/zigbee.pdf>>. Acesso em: jan. 2009.

Contato

Antonio Marcos Ferraz Campos
e-mail: a.marcos.campos@gmail.com