

LOCALIZAÇÃO DE USUÁRIOS EM AMBIENTES INTELIGENTES UTILIZANDO RFID ATIVO E FILTRO DE KALMAN

MARLON M. SOUDRÉ, ADOLFO BAUCHSPIESS.

LARA - Laboratório de Automação e Robótica

ENE - Departamento de Engenharia Elétrica

UnB - Universidade de Brasília, Caixa Postal 04386, 70904-970 Brasília DF

E-MAILS : MARLON_2MS@HOTMAIL.COM, ADOLFOBS@ENE.UNB.BR

Abstract — Set in an energy efficiency context, this work proposes the use of Artificial Neural Networks (ANN) in a building automation system based on tracking technique indoor users. More specifically, the study aims to analyze the performance of an RNA when trained by data provided by a radio frequency identification system and image processing, comparing it with the response provided by sensor fusion via Kalman filter. Therefore, we designed a RFID (Radio Frequency Identification) together with a camera system, supported by an image processing algorithm, which it was possible to obtain consistent data about to train a RNA acted in identifying the coordinate (x,y) of a user located inside the testing room. Once done the training and network validation, it employed a Kalman filter acting on the sensor fusion between the network response and the response of the imaging system, improving the accuracy and precision tracking and obtaining significant results for an error of up to 30cm accuracy.

Keywords — Artificial Neural Network, RFID, Indoor tracking, Kalman Filter.

Resumo — Inserido em um contexto de eficiência energética, o presente trabalho propõe a utilização de Redes Neurais Artificiais (RNA) em um sistema de automação predial baseado na técnica de rastreamento indoor de usuários. Em termos mais específicos, a pesquisa visa analisar o desempenho de uma RNA quando treinada mediante dados fornecidos por um sistema de identificação por radiofrequência e processamento de imagens, comparando-o com a resposta fornecida por fusão sensorial via filtro de Kalman. Para tanto, foi elaborado um sistema RFID (do inglês, Radio Frequency Identification) juntamente com um sistema de câmeras, amparado por um algoritmo de processamento de imagens, aos quais fosse possível a obtenção de dados consistentes a ponto de se treinar uma RNA que atuasse na identificação da coordenada (x,y) de um usuário localizado no interior do recinto de testes. Uma vez realizado o treinamento e validação da rede, lançou-se mão de um filtro de Kalman atuando na fusão sensorial entre a resposta da rede e a resposta do sistema de processamento de imagens, melhorando a acurácia e precisão do rastreamento e obtendo resultados expressivos para um erro de até 30cm de precisão.

Palavras-chave — Redes Neurais Artificiais, RFID, Rastreamento Indoor, Filtro de Kalman.

1 Introdução

O desenvolvimento sustentável é consenso e a comunidade científica tem relevante parcela de responsabilidade nesta área. A reavaliação do quadro de necessidades básicas, considerando o impacto ambiental, leva diretamente à questão energética e dentro desta, em particular, o uso racional da energia elétrica.

É sabido que no Brasil boa parte do consumo de energia correspondente a prédios públicos, comerciais e escritórios. Desse modo, amparado por uma política que evite desperdícios e preze pela eficiência energética, a automação predial tem ganhado cada vez mais força, possibilitando a criação dos chamados ambientes inteligentes, que visam não só o conforto e bemestar de seus usuários como também uma nova forma de minimizar e otimizar gastos.

Muitos são os desafios enfrentados quando se trata de rastreamento indoor. Fatores como a não operabilidade de tecnologias já consolidadas em ambiente *outdoor* como GPS (do inglês, Global Positioning Systems), devido as obstrução causada pela própria estrutura das construções, demandam uma busca por novos meios de rastreamento que venham a atender aos requisitos necessários em ambientes fechados.

Sendo assim, a solução tecnológica a ser implementada deve se atentar a fatores críticos como o tamanho e a comodidade dos equipamentos utilizados no rastreamento, uma vez que irão ser portados por humanos, e ao efeito conhecido como caminhos múltiplos, causado pela reflexão das ondas eletromagnéticas pela mobília, equipamentos

eletroeletrônicos e estruturas metálicas presentes no ambiente em questão.

Na tentativa de se criar uma solução que leve em conta o custo-benefício entre eficácia da localização e viabilidade financeira e de execução, diversas tecnologias tem sido testadas por pesquisadores mundo a fora, tais como UWB (do inglês, Ultra Wide Band Width), WIFI e *Bluetooth*. Nesse sentido, a Universidade de Brasília veem desenvolvendo uma linha de pesquisa, na qual o presente trabalho se encaixa, visando à implementação de um sistema de rastreamento *indoor*, baseando-se no uso de RFID, que seja aceitável em termos de custos e ao mesmo tempo eficiente.

2 Propósitos

O presente trabalho pode ser visto como uma continuação de trabalhos anteriores desenvolvidos no laboratório LARA, cujo propósito geral é desenvolver um sistema de rastreamento *indoor* de usuário dentro das dependências do laboratório utilizando-se de dados provenientes de etiquetas RFID, visando o conforto, segurança e racionalização energética.

Essa frente de pesquisa da Universidade de Brasília teve início com Fonseca (2010), que desenvolveu estudos acerca do funcionamento da tecnologia RFID e do nível de interferência sofrido pelo sinal RSSI (do inglês, Received Signal Strength Indication), utilizado na identificação. Posteriormente foram implementados sistemas com tecnologias RFID ativas, com Silva Junior (2013), e passivas, com Oliveira e Rocha (2013).

Os resultados dos trabalhos supracitados mostraram que a tecnologia ativa sofre grande interferência do ambiente na qual está inserida, provocados por fatores como mobília, equipamentos e até pela água presente no corpo de pessoas próximas às etiquetas e antenas RFID. Tais interferências são menores em se tratando da tecnologia passiva, todavia, essa última esbarra no curto alcance de leitura das etiquetas portadas pelo usuário, o que demanda uma maior estrutura em termos de equipamentos para que a posição do usuário seja conhecida com acurácia. Nesse sentido, o presente trabalho traz como objetivo geral a utilização de uma RNA e de um filtro de Kalman na implementação de um sistema de rastreamento *indoor* que se utilize de dados provenientes de etiquetas RFID ativas e de imagens de câmeras fixadas ao teto do laboratório, na tentativa de melhorar a localização (x,y) do mesmo. Visando atingir o objetivo geral, foram estabelecidos como objetivos específicos:

- Implementar um sistema de aquisição de dados referentes ao posicionamento do usuário via identificação por radiofrequência.
- Implementar um sistema de aquisição de dados referentes à coordenada (x,y) do usuário via processamento de imagens;
- Coletar os dados necessários para treinamento e validação da RNA dentro do recinto escolhido para testes;
- Comparar a resposta obtida pela RNA com a resposta obtida pela fusão sensorial via filtro de Kalman, entre os dados fornecidos pela rede neural e os dados provenientes das câmeras;

3 Métodos

Visando a implementação do sistema descrito na seção anterior, foram utilizados os seguintes componentes de hardware e software.

3.1 Hardware do Sistema RFID

O hardware do sistema RFID foi composto por quatro leitoras do tipo L-RX900, operantes em 433 MHz, quatro antenas L-AN200 stub omnidirecional no plano radial e uma etiqueta ativa L-TG501 MS, todos fabricados pela Wavetrend, conforme ilustrado na Figura 1.



Figura 1. Foto ilustrativa de leitora, antena e etiqueta utilizadas no sistema RFID – Wavetrend® Ltd.

3.2 Middleware do Sistema RFID

A fim de fazer o gerenciamento entre as leitoras e os dados provenientes das etiquetas, utilizou-se o middleware desenvolvido por Fonseca (2010), em linguagem de programação Delphi. Esse software é capaz de se conectar até cinco leitoras e coletar informações das etiquetas tais como ID, o sinal RSSI, o número do pacote enviado, e período de envio.

Além dos materiais supracitados, foram utilizados uma câmera LifeCam VX-600 e o software Matlab com a toolbox Neural Network.

3.3 Cenários de Testes

De modo a facilitar a implementação do sistema proposto, dividiu-se o mesmo em seis etapas sequenciais conforme indicado na Figura 2.




Figura 2. Fluxograma da metodologia adotada no projeto.

A primeira etapa consistiu na escolha do ambiente em que os testes seriam realizados. Por questões de conveniência e praticidade, escolheu-se como ambiente de testes uma sala de 3m x 5m conforme mostrado pela Figura 3. Essa escolha levou em consideração fatores como capacidade de espaço necessário para se dividir o ambiente em três ambientes menores, além da altura do teto. Esse último fator foi importante para que a câmera fosse posicionada no centro do ambiente, cobrindo-o por completo.

Trabalhos anteriores constataram que os posicionamentos das leitoras e das antenas influenciavam a qualidade do sinal. Desse modo, foi adotado o posicionamento das antenas recomendado por Silva Jr (2013).




Figura 3. Sala de testes com destaque para o posicionamento das leitoras 0, 1, 2 e 3.

Além das distâncias entre as leitoras e as paredes, representadas na Figura 3, adotou-se uma altura padrão de 1,4 m das mesmas com relação ao solo. Essa configuração permitiu que as quatro leitoras fossem dispostas de maneira a cobrir com folga todos os três ambientes da sala de testes.

A coleta dos dados foi feita de maneira que o usuário se deslocasse em uma primeira trajetória de modo a gerar dados de treinamento, deslocando-se uma segunda vez em um percurso diferente para gerar dados de validação.

Como já mencionado, o sistema RFID utilizado foi composto por quatro antenas acopladas a quatro leitoras, uma etiqueta ativa e um computador onde os dados eram recebidos e guardados através de um *middleware*. As leitoras comunicavam com o computador via rede *Ethernet*.

O sistema completo funcionou de forma a receber as leituras da emissão da etiqueta ativa, através do *middleware*, gravando os mesmos em um arquivo de texto. Esse arquivo continha os dados das quatro leitoras, identificadas como leitora 0, 1, 2 e 3, dispostos em ordem de leitura.

Utilizou-se o mesmo computador ligado ao sistema RFID para adquirir os dados da câmera, por meio de uma comunicação via cabo USB. Esse é um fator importante, devido à necessidade de sincronizar os dados provenientes do sistema RFID com os dados provenientes da câmera. Assim, como os mesmos são adquiridos na mesma máquina, não é preciso que haja sincronismo de relógios, medida que seria necessário caso fosse utilizada duas máquinas distintas.

A fim de que a posição (x,y) do usuário fosse identificada por meio do processamento de imagens, utilizou-se um marcador vermelho, boné, fixado ao pé do usuário. Quanto à fixação da etiqueta, adotou-se a estratégia de fixá-la junto ao marcador vermelho, no pé do usuário.

Uma vez fixada a etiqueta junto ao marcador, coletou-se dados de treinamento e de validação em todos os ambientes da sala de testes, procurando manter o compromisso de não se alterar a configuração da sala durante a realização do experimento. A Figura 4 ilustra o usuário portando o identificador e a etiqueta segundo os critérios supracitados.



Figura 4. Usuário portando identificador vermelho e etiqueta RFID ao pé, abaixo do identificador.

A fim de se obter dados para treinamento, o usuário se movimentou de modo a cobrir a maior área

possível em cada ambiente, gerando dados com elevada riqueza de informações. Em contrapartida, na etapa de obtenção de dados para validação, a preocupação em cobrir a maior área possível do ambiente onde está sendo realizados os testes não se faz tão necessária. Sabendo disso, a movimentação do usuário nesta etapa se caracterizou como simples e rápida, consistindo em uma caminhada que cruzasse o ambiente de ponta a ponta.

Após coletados os dados fez-se necessário processar os mesmos a fim de deixá-los no modelo exato a serem apresentados para treinamento e validação da rede neural. Essa etapa de preparação foi realizada via códigos desenvolvidos no *software Matlab*.

A primeira parte do processamento consistiu em, a partir dos quadros de imagem da movimentação do usuário e gravados no computador, identificar sua coordenada em *pixels* dentro do ambiente e gerar um arquivo que contivesse a posição (x,y) real (em centímetros) do mesmo. Para tanto, foi utilizado como referência uma marcação em fita feita previamente ao ambiente em questão, delimitando a área útil em que o usuário se deslocaria. Tal marcação foi estabelecida como o ponto de origem ao qual todos os *pixels* eram medidos.

Primeiramente importaram-se todos os quadros para o ambiente do *Matlab*, percorrendo os *pixels* de sua matriz a procura de valores (RGB) que caracterizasse a cor vermelha, escolhendo como resultado final o *pixel* que representasse a média entre todos os selecionados. O critério de escolha dos valores de intensidade das cores vermelha, verde e azul que caracterizasse o vermelho do identificador do usuário foi calibrado individualmente para cada um dos ambientes, pois tais valores variavam segundo a incidência de luz.

O algoritmo de obtenção dos quadros de vídeo foi configurado para gravar 5 (cinco) quadros por segundo, ao passo de que os dados provenientes da etiqueta eram recebidos a um período de 1,5 segundos, uma vez que a mesma se encontrava em movimento.

Feito isso, um algoritmo produzido em *Matlab* foi implementado de forma a correlacionar os dados provenientes do sistema RFID com seus respectivos frames, provenientes das câmeras, gerando um arquivo pronto para ser apresentado para treinamento da rede neural artificial.

Por conseguinte, visando maximizar o desempenho da rede empregada no treinamento dos dados provenientes das leitoras RFID, implementou-se um algoritmo para treinamento de uma rede *perceptron* multicamadas com função de ativação *sigmoid* e algoritmo de treinamento *Levenberg-Marquardt backpropagation* (*trainlm*). Desenvolveu-se um código em *Matlab* cujo objetivo consistiu em, partindo de uma configuração inicial com 10 neurônios na camada intermediária e 100 épocas de treinamento, treinar a rede e validá-la, obtendo um percentual de acertos mediante comparação da saída da mesma com a saída esperada para os dados de validação. Foi considerada uma margem de erro de

30 cm, por se tratar de uma distância razoável no perfil de aplicação proposto.

Por fim, na etapa de filtragem via filtro de Kalman, aplicou-se um modelo de um sistema linear de primeira ordem bidimensional fruto de uma adaptação de *Phil Kim* (2011).

4 Resultados

Por questão de espaço os resultados aqui apresentados estarão focados ao Ambiente 1. Além disso, os mesmos estão divididos em três partes, a saber, identificação por imagem, treinamento da rede neural e aplicação do filtro de Kalman, conforme mostrado a seguir.

4.1 Localização a partir da Imagem

A localização do usuário a partir da imagem da movimentação do mesmo para treinamento e validação pode ser verificada na Figura 5 (a) e (b).



a) Treinamento.

b) Validação.

Figura 5. Conjuntos de treinamento e validação.

4.2 Treinamento da Rede Neural Artificial

Ambas as configurações apresentaram melhor desempenho com uma rede neural com 50 neurônios na camada intermediária. Desse modo, adotando como padrão um erro de até 30 cm, obtiveram-se 70% de acerto para a Configuração 1 e 68% de acerto para a Configuração 2. A topologia da rede utilizada pode ser verificada na Figura 6.




Figura 6. Topologia da Rede Neural Artificial utilizada.

4.3 Aplicação do Filtro de Kalman

Aplicando-se o filtro de Kalman com o objetivo de se efetuar a fusão sensorial entre a identificação por imagem, resposta da rede e modelo do sistema, obteve-se os resultados ilustrados na Figura 7.



Figura 7. Filtro de Kalman (preto) implementa a fusão sensorial entre os dados obtidos por imagem (vermelho) e da RNA (azul). Sobreposição para os ambientes 1, 2 e 3.

O modelo em questão é de um sistema linear de primeira ordem bidimensional, ou seja, possui variáveis de estado que representam o eixo x e o eixo y . O vetor coluna das variáveis de estado foi representado por:

$$x = \begin{bmatrix} \text{posição}_x \\ \text{velocidade}_x \\ \text{posição}_y \\ \text{velocidade}_y \end{bmatrix}$$

Além das variáveis de estado referentes às posições x e y , foram assumidas outras duas variáveis representando a velocidade de deslocamento do usuário em cada uma das coordenadas. No entanto, para os fins do trabalho foram tomados apenas os valores das medidas de posição do usuário, uma vez que a velocidade desenvolvida pelo mesmo não está diretamente ligada aos propósitos pré-estabelecidos. O modelo em espaço de estados do sistema em questão é definido pelas seguintes equações:

$$x_{k+1} = Ax_k + w_k \quad (1)$$

$$z_k = Hx_k + v_k \quad (2)$$

Os termos w_k e v_k nas equações (1) e (2) são relativos ao ruído, sendo o primeiro o ruído proveniente do sistema, afetando as variáveis de estado, e o segundo, proveniente das medições do sensor.

A matriz A , conhecida como matriz de transição de estados, descreve como o sistema muda ao longo do tempo, podendo ser entendida como a matriz que contém as equações de movimento do sistema. Para os fins do presente trabalho, definiu-se tal matriz como:

$$A = \begin{bmatrix} 1 & dt & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & dt \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

Sendo $dt = 1.5$, correspondendo ao intervalo de aquisição de dados pelas leitoras RFID.

A matriz H representa a relação entre as medições realizadas e as variáveis de estado e foi definida como:

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Os ruídos do sistema em espaço de estados foram representados por duas matrizes diagonais. A primeira delas, matriz Q , é conhecida como matriz de covariância do ruído do proveniente do sistema (w_k).

Já a segunda, matriz R, é conhecida como matriz de covariância do ruído proveniente das medições (v_k). Tais matrizes foram definidas como:

$$Q = \begin{bmatrix} 2 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 2 & 0 \\ 0 & 0 & 0 & 2 \end{bmatrix}$$

$$R = \begin{bmatrix} 10 & 0 \\ 0 & 10 \end{bmatrix}$$

Sabendo-se que o ganho K é definido por $K_k = P_k^- H^T (H P_k^- H^T + R)^{-1}$, levando a:

$$K_k = \frac{P_k^- H^T}{H P_k^- H^T + R} \quad (3)$$

Pela equação (3), é notório que o ganho K_k decresce com o crescimento de R. Isso faz com que a contribuição das medições para o estado estimado do filtro também decresça, aumentando a contribuição da predição. Assim, para o presente trabalho, em que as medições provindas da rede neural são bastante ruidosas e pouco confiáveis, é interessante que se diminua a contribuição das mesmas na estimação do filtro aumentando o valor de R.

Em contrapartida, a predição do erro da covariância aumenta com o aumento de Q. Porém, a equação (3) discutida a pouco, mostra que o ganho K_k aumenta a medida que se aumenta o valor de P_k^- . Logo, para os fins deste trabalho, além do aumento de R, é interessante que se tenha um decrescimento de Q.

De modo a se obter um resultado mais quantitativo dos resultados apresentados anteriormente, traçou-se, para cada um dos ambientes e das configurações, o gráfico da coordenada x pelo deslocamento, da coordenada y pelo deslocamento e o gráfico do deslocamento pelo tempo, conforme indicados na Figura 9, Figura 10 e Figura 11 respectivamente. Os dados são referentes ao ambiente 1 da configuração 1.

Os gráficos representados pelas figuras 9, 10 e 11, ilustram o deslocamento do usuário na obtenção de dados de validação. Os saltos presentes são referentes aos momentos em que não se obteve dados consistentes por parte das leitoras e/ou câmeras. Desse modo, descartaram-se os instantes de tempo em que tais inconsistências ocorreram.




Figura 9. Gráfico da coordenada X pelo deslocamento no ambiente 1, por meio da configuração 1 (unidades expressas em pixel).




Figura 10. Gráfico da coordenada Y pelo deslocamento no ambiente 1, por meio da configuração 1 (unidades expressas em pixel).




Figura 11. Gráfico do deslocamento pelo tempo no ambiente 1 da configuração 1.

Vale ressaltar ainda que os gráficos representa uma variação de 0 até o máximo de 500 pixels, o que compreende a área útil de movimentação do usuário, tendo como origem a marcação em fita já citada anteriormente. A correspondência entre pixel e centímetros encontrada dentro da área de movimentação foi de 64 pixel a cada 30 cm.

Por fim, a Tabela 1 traz um comparativo da raiz quadrada do erro quadrático médio calculado para cada um dos ambientes.

	Ambiente 1	Ambiente 2	Ambiente 3
$\sqrt{EMQ}$ Kalman (X)	0,38 m	0,3 m	0,28 m
$\sqrt{EMQ}$ RNA (X)	1,36 m	1,2 m	1,06 m
$\sqrt{EMQ}$ Kalman (Y)	0,46 m	0,34 m	0,46 m
$\sqrt{EMQ}$ RNA (Y)	1,25 m	1,5 m	1,25 m

Tabela 1. Raiz quadrada do Erro Quadrático Médio.

5 Discussões

Observou-se que a resposta da rede, mediante aos padrões RSSI apresentados à mesma, apresentou-se bastante ruidosa, visto as características de construção, equipamentos e mobiliário encontrados no laboratório.

No entanto, em se tratando da identificação por imagem e pelos resultados obtidos e expressos na seção 4, percebe-se que, mesmo diante de dificuldades como calibração e fixação da câmera ao teto do laboratório, foram obtidos dados satisfatórios e consistentes acerca da movimentação do usuário dentro dos ambientes de teste. Essa foi uma parte fundamental do trabalho, visto que sem ela não se teria veracidade da posição (x,y) do usuário na sala de testes, tornando inviável o treinamento da rede neural e a fusão sensorial via filtro de Kalman.

Esse último artifício pode ser visto como a maior contribuição do presente trabalho ao grupo de pesquisas ao qual o mesmo se encaixa. Projetos anteriores já haviam feito uso da ferramenta de Kalman, mas não na configuração de fusão sensorial. Desse modo, percebeu-se que o filtro melhorou substancialmente a resposta da rede, apresentando estimações muito próximas ao *groundtruth*. Isso comprova sua eficácia e encerra os propósitos buscados com os experimentos realizados neste trabalho e descritos ao longo do texto.

6 Conclusões

Diante da metodologia adotada e dos resultados obtidos, o que se conclui é que, apesar das dificuldades recorrentes aos sistemas de localização *indoor*, é possível se obter resultados satisfatórios lançando mão de diversos artifícios. O processamento de imagens e o filtro de Kalman são algumas das ferramentas que ajudam a dar consistência à localização RFID. Dessa forma, o presente trabalho veio atestar o bom funcionamento de tais ferramentas e a consistência de seus resultados.

O trabalho foi concebido em uma única sala de testes dividida em três ambientes. Como perspectivas futuras coloca-se a expansão da área de testes para todo o laboratório, permitindo uma aplicabilidade maior ao sistema. Além disso, não foi feita a integração entre a resposta final do sistema de rastreamento com um supervisor que pudesse monitorar a movimentação de múltiplos usuários e atuar de fato na iluminação e nos aparelhos de ar condicionado.

Outro ponto importante remete-se a utilidade comercial do sistema proposto. Sabe-se que o presente projeto atende apenas a fins de pesquisa. Para que se obtivesse valor comercial seria necessário lançar mão de diferentes estratégias de rastreamento. Isso porque, um ambiente como o LARA é bastante dinâmico, pessoas transitam pelo mesmo a todo instante e objetos e moveis são mudados de lugar constantemente. Assim, uma rede neural treinada para uma dada configuração do ambiente perderia seu poder mediante as alterações sofridas pelo mesmo. Dessa forma, seriam necessários treinamentos periódicos ou um sistema adaptativo que pudesse contornar as implicações desse dinamismo.

Os resultados gerais obtidos pela estimação do filtro de Kalman poderiam ser melhorados pela aplicação de um modelo não linear, em substituição ao modelo linear utilizado neste trabalho. Um possível modelo é apresentado pelas equações (1) e (2).

$$x_{(k+1)} = x(k) + r \cos \theta(k) + w(k) \quad (1)$$

$$y_{(k+1)} = y(k) + r \sin \theta(k) + v(k) \quad (2)$$

Estas equações mostram uma interdependência entre as coordenadas x e y , sendo r o raio do deslocamento e θ o ângulo da orientação do usuário no ambiente.

Além dos fatores supracitados, pessoas possuem alturas diferentes e até limitações especiais, como uma pessoa de cadeira de rodas, sendo necessários treinamentos específicos para cada caso. Sendo assim, percebe-se que o rastreamento *indoor* RFID é uma abordagem promissora, mas cercada de desafios, demandando pesquisas futuras.

Referências Bibliográficas

- Huang, C.-H.; Lee, L.-H.; Ho, C. C.; Wu, L.-L. and Lai, Z.-H. (2015) Real-Time RFID Indoor Positioning System Based on Kalman-Filter Drift Removal and Heron-Bilateration Location Estimation. IEEE Transactions on Instrumentation and Measurement, Vol. 64, No. 3, pp. 728-739.
- Aztiria, A.; Izaguirre, A. and Augusto, J. C. (2010) Learning Patterns in Ambient Intelligence Environments: A Survey, Artif Intell Rev (2010) 34:35–51.
- De Paola, A.; Gaglio, S.; Lo Re, G., Ortolani, M. (2012) Sensor9k: A Testbed for Designing and Experimenting with WSN-based Ambient Intelligence Applications. Pervasive and Mobile Computing 8:448–466
- Fonseca, L. O. (2010). Sistema de localização RFID de Usuários Visando a Racionalização de Energia em Ambientes Inteligentes. TG, UnB.
- Silva Júnior, C. A. (2012). Classificação de Ambientes Prediais para Usuários Utilizando Tags RFID Ativas e Filtro de Kalman. Dissertação de Mestrado, UnB.
- Oliveira, F. R.; Rocha, F. S. P. (2013). RFID Passiva no Rastreamento de Usuários para a Automação Predial. TG, UnB.
- Fluerasu, A., Picois, A. V., Boiero, G.; Ghinamo G.; Lovisolo, P. Samama, N. (2010) Indoor Positioning Using GPS Transmitters: Experimental Results. IPIN - IEEE International Conference on Indoor Positioning and Indoor Navigation
- Harvey, A.C. (1989), Forecasting. Structural Time Series Models and the Kalman Filter. Cambridge University Press.
- Aguirre, L. A. (2007) Introdução à Identificação de Sistemas. 3a Ed., Editora UFMG, Belo Horizonte - MG.
- Phil Kim (2011), Kalman Filter for Beginners with MATLAB Examples – Translated by Lynn Huh.
- Bradski, G.; Kaehler, A.; Learning OpenCV – Computer Vision with the OpenCV Library. Sept. 2008. 557pp.
- Souza, A. L. G.; Oliveira, G. F. (2011). Sistema de Localização para Robô Móvel. Trabalho de Graduação em Engenharia de Controle e Automação. UnB.