Sensor Inteligente para Estimação do Ângulo de Irradiação Solar via Redes Neurais Artificiais

Yan Ferreira da Silva* Ernesto Franklin Marçal Ferreira**
Monik Silva Sousa*** Anselmo Cardoso de Paiva****
João Viana da Fonseca Neto†

* Pós-Graduação em Engenharia Elétrica, Universidade Federal do
Maranhão, MA, (e-mail:yan@nca.ufma.br))

** Instituto Federal do Maranhão, MA,
(e-mail:ernesto.ferreira@ifma.edu.br))

*** (e-mail:moniksousas@gmail))

**** (e-mail:paiva@nca.ufma.br))

† (e-mail:jviana@dee.ufma.br))

Abstract: Due to the emergence of IoT-oriented technologies (Internet of Things), the worldwide market for intelligent sensors has grown rapidly in recent decades, leading to the development of algorithms and technology for intelligent measurement architectures. Motivated by the demand for measurement devices oriented to monitoring and control, this paper presents the development of an embedded system to map the angular position of the maximum solar irradiance in photovoltaic cells. The proposed system consists of hardware for estimation of solar radiation and temperature sensors, the signals are sent to a cloud for monitoring the position of the sun in relation to the cells. The intelligent component of embedded system is an artificial neural network (RNA) of the Bayesian Regularization Backpropagation type, which receives online signals from the physical sensor and estimates the angle of highest solar incidence. For monitoring application, the performance tests of the intelligent measurement architecture presented satisfactory results in mapping the maximum power point (MPP) tracking to its position reference angle.

Resumo: Devido ao surgimento das tecnologias orientadas para *IoT* (*Internet Of Things*), o mercado mundial de sensores inteligentes teve um grande crescimento nas últimas décadas, conduzindo ao desenvolvimento de algoritmos e tecnologia para novas arquiteturas de medição inteligente. Motivado pela demanda de dispositivos de medição para monitoramento e controle, este artigo apresenta o desenvolvimento de um sistema embarcado para mapear a posição angular da máxima irradiância solar em conjunto de células fotovoltaicas. O sistema proposto é constituído por um *hardware* para estimação *online* da irradiação solar e sensores de temperatura, os sinais são enviados para uma *Cloud* para fins de monitoramento da posição do sol em relação as células. A componente inteligente do sistema embarcado proposto é uma rede neuronal artificial (RNA), do tipo *Bayesian Regularization Backpropagation*, que recebe os sinais *online* do sensor físico e estima o ângulo de maior incidência solar. Para aplicação de monitoramento, os testes de desempenho da arquitetura de medição inteligente apresentaram resultados satisfatórios no mapeamento do rastreamento do ponto máximo de potência (MPP) para seu ângulo de referência de posição.

Keywords: Intelligent Sensors, Embedded Systems, Artificial Neural Networks, Internet of Things.

Palavras-chaves: Sensores Inteligente, Sistemas Embarcados, Redes Neurais Artificiais, Internet das Coisas.

1. INTRODUÇÃO

De acordo com a Global Industry Analysts, Inc. O mercado mundial de sensores inteligentes atingiu US \$7,8 bilhões em 2015. Isso mostrou que a demanda global por sistemas inteligentes altamente integrados aumentou dramaticamente nos últimos anos. Mesmo que a crise econômica tenha prejudicado de certa forma sua expansão, de acordo com: *Smart Sensors: An International Market Report (BizA-cumen, Inc.)* as redes de sensores e sensores inteligentes estão sendo amplamente utilizados na indústrias, incluindo automotiva, médica, industrial, entretenimento, segurança e defesa, devido ao aumento do uso de controles de processo e elementos sensores em diferentes setores (Rastko R. Selmic, 2016).

O uso dos sensores inteligentes em aplicações de combate ao terrorismo, incluindo rastreamento de carga, biometria, entre outros, também está aumentando. Os sistemas inteligentes estão sendo prontamente aceitos pela indústria automobilística à medida que os fabricantes de automóveis exploram maneiras de salvar vidas, desviar as preocupações de segurança e levar a litígios dispendiosos (Yurish, 2009).

Este trabalho trata do desenvolvimento de um sensor inteligente que realiza estimação do maior ângulo de irradiação utilizando modelos matemático. Este sensor conta um sistema embarcado desenvolvido para atuar como sensor físico, a nível de *software* para realizar a identificação e estimação do ângulo utiliza uma rede neuronal artificial, com algoritmo de treinamento *Bayesian Regularization Backpropagation*, que se trata de um método matemático que converte uma regressão não linear em um problema estatístico, bem posicionado na forma de regressão em crista, a principal vantagem de se aplicar esse modelo é sua robustez e seu processo de validação é desnecessário e trata-se de um método que dificulta a ocorrência de *overtrain*, (Hession, 1984), (Mancilla-David et al., 2014). Aplicando este método para obtenção resultados comparando com dados da irradiação solar de um banco de dados que tem a finalidade de treinar a rede e comparar o resultado gerados determinando assim o ângulo de maior geração de irradiação solar.

O artigo é organizado em seções, na Seção 2 tem-se explicações e conceitos de sensores inteligentes e suas classes e vertentes, na mesma seção tem-se uma explicação sobre *Smart Sensors* e a descrição do padrão IEEE 1451. Na Seção 3 tem-se explicações sobre a modelagem matemática do sistema da célula fotovoltaica e sua complexidades para obtenção dos parâmetros de irradiação solar, ainda na seção 3 tem-se todo desenvolvimento do *hardware* do sensor onde são usadas conceitos e técnicas de *IoT* e desenvolvimento da RNA responsável pela identificação e estimação. Na Seção 4 é avaliada a metodologia utilizada para análise dos resultados obtidos através da sua aplicação. As conclusões e propostas para trabalhos futuros são apresentados na Seção 6.

2. PRELIMINARES

Os sistemas inteligentes podem detectar um impacto iminente em sua natureza, a presença de ocupantes, sua posição e determinar o tipo de *airbags* ao serem disparados

informando a sua força e velocidade de durante seu acionamento. Sensores de rastreamento de movimento e sensores inerciais baseados em sistemas micro-eletromecânicos (MEMS) estão sendo amplamente utilizados em aplicações médicas, *IoT*, industriais e robótica. Dispositivos implantáveis que são pequenos em tamanho e ainda possuem alta confiabilidade, e dispositivos portáteis para uso em diagnósticos e monitoramento doméstico, principalmente impulsionam a demanda por tais sensores (Soloman, 2009), (Bhuyan, 2013).

Os sensores inteligentes são projetados para realizar operações específicas que necessitem de operações metrológicas de processamento de sinal do sensor embarcado, com ajuda de circuitos de processamento de sinal, conversor analógico digital (CAD) e microprocessador (Soloman, 2010). As operações metrológicas realizadas por um sensor inteligente são de calibração, linearização, compensação de erro, eliminação de deslocamento, conversão de analógico para digital, estimação de parâmetros entre outras operações (Yamasaki, 1996).

Um sensor convencional é considerado *burro* no contexto da inteligência e esperteza necessária para desenvolver determinadas atividades prologadas em condições ambientais flexíveis. Os sensores inteligentes estão devidos em duas categorias gerais diferenciados pelas suas funções que despenham ou pela tecnologia a partir da qual foram desenvolvidos (Yamasaki, 1996). Existem diversas técnicas de implementação de sensores inteligentes a nível de hardware, dependem de fatores como velocidade a ser mantida, possibilidade de integrar os módulos do sensor com o circuito de processamento e compatibilidade do processamento do sinal (Bhuyan, 2013).

Um sensor inteligente pode ser categorizado das seguintes maneiras com Base em funções que são *smart sensors*, convincentes, autoadaptativos, autovalidação; e sensores com base em técnicas são eles suave ou virtual, matemático, simbólico, computacional, baseado em RNA/baseado em lógica *fuzzy*, integração inteligente, integração em larga escala (*VLSI*), *MEMS*/microsensores (Soloman, 2010).

Os *Smart Sensors* são definidos como aqueles que são obtidos através da integração entre de sensores a um tipo de circuito de processamento do sinais (Rastko R. Selmic, 2016). De acordo com o padrão IEEE 1451 define um *Smart Sensors* como um sensor analógico ou digital integrado ou conectado a um circuito de armazenamento e contando um poder de processamento dos dados (uma forma de tratamento dos dados obtidos) (Ranky, 2002).

3. SISTEMA DE MEDIÇÃO INTELIGENTE

O sistema de medição inteligente desenvolvido e baseado em modelagem matemática do processo onde foi feita uma relação entre as células fotovoltaicas e os sensores de temperatura usados para aquisição dos dados permitindo gerar a irradiação solar. A rede neuronal é responsável pela parte inteligente do sistema embarcado. O passo seguinte foi o desenvolvimento da estrutura física do dispositivo. Na Figura 1, apresenta-se o diagrama de blocos do funcionamento do sensor a ser desenvolvido. Com a quantidade de 4 células fotovoltaicas

Figura 1. Diagrama de blocos do sensor do sistema de medição

3.1 Modelo do Processo

O modelo do processo para fins de obtenção do ponto de máxima potência gerada pela célula solar é dada por um circuito equivalente. O modelo de diodo anti-paralelo é mesmo aplicado neste trabalho, é substituído por fonte de corrente controlada permitindo a representação da ligação das células em paralelo e/ou série em um único circuito com os detalhes de cada célula (Mancilla-David et al., 2014). Associando ao circuito elétrico da fotocélula, tem-se a corrente no terminal do painel, é dada por

$$I = I_{irr} - I_{dio} - I_p, \quad (1)$$

sendo I_{irr} corrente de irradiação que é gerada pelos raios solares incidentes na célula exposta a luz solar, I_{dio} é a corrente no diodo anti-paralelo que é responsável pela característica não linear da célula, I_p por sua é a corrente de derivação devido ao resistor *shunt* R_p . Substituindo na eq (1) expressões I_{dio} para I_p a corrente no terminal é

$$I = I_{irr} - I_0 \left[\exp \left(\frac{q(V + IR_S)}{nkT} \right) - 1 \right] - \frac{V + IR_S}{R_p}, \quad (2)$$

sendo $q = 1.602 \times 10^{-19}$ é carga elétrica do elétron, $k = 1.3806503 \times 10^{-23}$ J/K que é a constante de Boltzmann, T é a temperatura da célula, I_0 trata-se da corrente de saturação do diodo, n é o fator ideal do diodo, R_S e R_p representam os resistores *shunt* em série e paralelo (Kuszamaul et al., 2010).

Este modelo de relação possibilita a generalização para um grande numero de células conectadas em série representadas por N_s e outra quantidade de células em paralelo representadas por N_p , para forma um arranjo de matriz de tamanho $N_S \times N_P$, assim formando um grupo de gerador de energia elétrica, esse modelo é conhecido como generalizado. Sendo assim o modelo generalizado assume um arranjo dado por

$$I_{array} = N_P I_{irr} - N_P I_0 \left[\exp \left(\frac{q(V + 1 \frac{N_S}{N_P} IR_S)}{N_S nkT} \right) - 1 \right] - \frac{V + 1 \frac{N_S}{N_P} IR_S}{\frac{N_S}{N_P} R_p} \quad (3)$$

Na relação I-V, as caraterísticas de desempenho de uma única celular solar e matriz são dadas pelas equações (2) e (3), e respectivamente os parâmetros I_{irr} , I_0 , R_P , R_S e n dependem diretamente da irradiância solar (G), já a temperatura da celular (T) influenciam outros parâmetros de referencia denominados G_{ref} , T_{ref} , $I_{irr,ref}$, $I_{0,ref}$, $R_{P,ref}$, $R_{S,ref}$ e n_{ref} descritas nas equações que são

$$I_{irr,ref} \frac{G}{G_{ref}} (1 + \alpha'_T (T - T_{ref})), \quad (4)$$

$$I_0 = I_{0,ref} \left(\frac{T}{T_{ref}} \right)^3 \exp \left(\frac{E_{g,ref}}{kT_{ref}} - \frac{E_g}{kT} \right), \quad (5)$$

$$R_P = R_{P,ref} \left(\frac{G}{G_{ref}} \right), \quad (6)$$

$$R_S = R_{S,ref}, \quad (7)$$

$$n = n_{ref}. \quad (8)$$

Em (4), α'_T é o coeficiente de temperatura relativo da corrente de curto-circuito, que representa a taxa de variação da corrente de curto circuito em relação a temperatura da célula solar (Mancilla-David et al., 2014). A relação e dada pelos fabricantes, tal relação é dada por

$$\alpha_T = \alpha'_T I_{irr,ref} \quad (9)$$

3.2 Rede Neuronal Artificial

O método *Bayesian Regularization Backpropagation* ou BR, tem uma função objetiva que inclui uma soma residual de quadrados e a soma de destes pesos para minimizar os erros de estimativa e para alcançar um bom modelo generalizado (Kayri, 2016).

Redes neurais artificiais que utilizam o método de *Bayesian Regularization Backpropagation* são mais robustas do que as redes de *backpropagation* padrão e podem reduzir ou eliminar a necessidade de uma longa validação cruzada (Haykin, 2005).

O método *Bayesian Regularization* é um processo matemático que converte uma regressão não linear em um problema estatístico bem posicionado na forma de uma regressão em crista (Kayri, 2016). A vantagem do modelo é sua robustez e o seu processo de validação é desnecessário, sendo que o processo de validação em *backpropagation* padrão é escalável (Haykin, 2005).

Este método dificulta a ocorrência *overtrain* (quando o algoritmo treina mais do que o necessário e prejudica o aprendizado), uma vez que os procedimentos de evidência fornecem um critério bayesiano objetivo para interromper o treinamento (Braga et al., 2011). O método calcula e treina em um número de parâmetros de rede ou pesos efetivos, efetivamente desligando aqueles que não são relevantes. Este número efetivo é geralmente consideravelmente menor que o número de pesos em uma rede neural padrão de retropropagação totalmente conectada (Yue et al., 2011).

No seu treinamento o método é introduzido para atualização dos pesos é dado por

$$F(\omega) = aE\omega + \beta E_D, \quad (10)$$

sendo a e β são parâmetros das funções objetivas, e a variável $E\omega$ é a soma quadrada dos pesos da rede e a variável E_D é a soma dos erros da rede. Os pesos da rede são variáveis aleatórias e a distribuição dos pesos da rede e o treinamento são considerados distribuição Gaussiana. Os

valores de a e β são definidos pelo Teorema de Bayes, que relaciona duas variáveis A e B com base em suas probabilidades de variáveis anteriores e probabilidades posteriores, dadas pela equação

$$P(A|B) = \frac{P(A|B)P(A)}{P(B)}, \quad (11)$$

sendo $P(A|B)$ a probabilidade posterior de A condicional em B , $P(B|A)$ o anterior de B condicional em A e $P(B)$ a probabilidade anterior diferente de zero do evento B , que funciona como uma constante de normalização. Com o objetivo de encontrar o espaço de peso ideal, a equação 11 precisa ser minimizada, o que equivale a maximizar a posterior função de probabilidade dada por

$$P(a|\beta) = \frac{P(D|a, B, M)P(a, \beta|M)}{P(D|M)}, \quad (12)$$

sendo a e β são fatores necessários para otimizar, D é o peso da distribuição, M é a arquitetura da rede neural, $P(D|M)$ é o fator de normalização, $P(a, \beta|M)$ é a densidade prévia uniforme para os parâmetros de regularização e $P(D|a, B, M)$ é a função de probabilidade de D para o dado a, β, M . Maximizando a função posterior $P(a, \beta|D, M)$ é equivalente e maximizar a probabilidade da função $P(D|a, \beta, M)$.

Como resultado deste processo, os valores ótimos para a e β para um dado espaço de peso são encontrados. Depois, o algoritmo move-se para a fase LM, onde os cálculos da matriz de Hessiana ocorrem e atualiza o espaço de peso, a fim de minimizar a função objetivo. Então, se a convergência não for atendida, o algoritmo estima novos valores para a e β e o todo processo se repete até que a convergência seja alcançada (Yue et al., 2011).

3.3 Desenvolvimento do Sensor

Para a realização deste trabalho foi desenvolvido o sistema físico/hardware para fazer a captação dos dados de radiação solar e geração de potência. Para o desenvolvimento deste protótipo físico foram utilizadas 4 placas fotovoltaicas com as dimensões de 5cm comprimento por 2cm de largura, com tensão máxima de saída de 5V, gerando uma potência máxima de 0.5w; uma plataforma Arduino Uno R3 contendo microcontrolador ATmega 328P; um módulo *wireless* transceptor ESP01 com suporte à rede 802.11 b/g/n e com alcance aproximado de 90 metros; uma bateria de 9V para alimentação de todo sistema.

Foi desenvolvido um sensor físico denominado sensor inteligente de estimação de ângulo de maior incidência solar, a Figura 2 mostra o sensor em 3 perspectivas, na primeira perspectiva (a) temos uma vista frontal, onde estão as 4 placas estão distribuídas em um com 180°, o número 1 indica placa fotovoltaica em seu respectivo ângulo; (b) - corte frontal, mostra o sensor de temperatura LM35 presente embaixo das placas; (c) - vista superior, pode-se identificar os elementos presentes na imagem - 2 microcontrolador Arduino Uno R3 que é responsável ler e converter os sinais das células fotovoltaicas, 3 - circuitos divisor de tensão da ESP01, um para o módulo *wireless* devido sua operação 3.3V, 4 - bateria responsável pela alimentação de

todo o sistema, 5 - outro circuito divisor de tensão para as células fotovoltaicas devido as variações bruscas de tensão de saída podendo danificar as portas analógicas do arduino; (d) lateral elemento número 3 trata-se da ESP01.

Figura 2. Sensor solar desenvolvido para rastreamento de pontos irradiação solar.

O sensor físico funciona da seguinte forma, as células fotovoltaicas foram instaladas em um arco com um ângulo de 180°, as 4 placas foram posicionadas com intervalo entre elas de 40° parada cada placa, estas placas foram numeradas de 1 a 4, sendo a placa 1 instalada no ângulo 40°, 80°, 120°, 160° e possui um sensor de temperatura LM35 em sua parte central (nos primeiros teste a variação foi mínima entre as placas, então optou-se por um único sensor em toda estrutura). O arduino faz toda parte de recepção e leitura dos sinais gerados pelas placas, sabendo que a variação de tensão é de 0 a 5V, então utilizando resistores de 5,6 kΩ, para fazer o divisor de tensão para cada porta analógica, para recepção dos sinais enviados. Fazendo a leitura do nível de tensão que chega até a porta do microcontrolador, com uma resistência fixa e igual para todas células fotovoltaicas podemos calcular a potência é gerada dada por

$$P = \frac{U^2}{R} \quad (13)$$

por meio dessa equação obtemos aproximadamente a potência gerada em cada ângulo, U é a tensão e R a resistência.

Após o arduino fazer a leitura de conversão dos dados gerados pelas células fotovoltaicas ele faz o envio desses dados utilizando um módulo *wireless* ESP01 conectado à internet transmitindo os dados para uma *Cloud* chamada de ThingsSpeak, que se trata de uma plataforma de análise IoT que permite agregar, visualizar e analisar *streams* de dados, de uma forma muito simples. Uma das grandes vantagens do ThingsSpeak é que permite visualizar os dados enviados pelos nossos dispositivos, online, mas

também a possibilidade de analisar os mesmos recorrendo ao MATLAB, assim possibilitando aplica as ferramentas dele de modo online e também permite ao usuário exportar seus dados para o EXCEL ou direto para o MATLAB. O envio de dados para a plataforma ThingSpeak é feita via HTTP/HTTPS a cada 15 segundos (no mínimo, isto na conta gratuita). Então os pacotes de dados enviados pela ESP01 foi programada para enviar os dados com *delay*(atraso) de 60 segundos, isto foi feito devido ao número de amostras captadas durante 8 horas.

Para o desenvolvimento deste trabalho foi realizado usando Toolbox Neural NetTimes Series do MATLAB, foi escolhido devido pesquisas bibliográficas, seu uso bastante frequente na literatura e a facilidade em realizar os experimentos e testes.

4. RESULTADOS EXPERIMENTAIS

Os dados coletados foram exportados diretamente para o MATLAB, porém ocorram alguns conflitos de compatibilidade de versão de softwares, então foi exportado para uma planilha no EXCEL, onde foi montando um banco de dados, após esses sinais gerados foram importados para o MATLAB, onde foi seleção dos dados, isto ocorreu devido as primeiras amostras dados não terem passado por um circuito de divisão de tensão, assim chegou-se a um conjunto de dados com o tamanho 117x4 para entrada da RNA.

Após o tratamento feito, foram realizadas normalizações e outras operações de maneira a preparar os dados para o MATLAB, chegou-se a um conjunto dados cujo o tamanho 60x4, todo esse tratamento se deu devido para obtenção de dados de entrada para a rede neuronal, na Figura 3 pode-se observar os sinais entradas utilizados como *inputs* da rede. Em seguida foi acessado o site (Topo, 2018), do qual eles informam a posição dos ângulos Zenith e Azimute.

Figura 3. Sinais gerados pelas células fotovoltaicas.

Para gerar os dados de treinamento da rede foi importado do site as variações de posições do sol utilizando o Ângulo Zenith de São Luís do Maranhão no dia 30 de novembro de 2018 das 12h às 17:30, foram colhidas 60 posições para o treinamento da rede neuronal desenvolvida no MATLAB, na Figura 4 mostra o sinal desejado pela rede (*targets*), vale ressaltar o período das coletas do site (Topo, 2018) foram os mesmo período das coletas realizadas pelo sensor inteligente.

Figura 4. Sinal de Referência utilizado para treinamento da RNA.

Para a determinação do número de atrasos e número de neurônios da camada escondida, vários treinamentos e testes são realizados de maneira a se encontrar um resultado satisfatório. Inicialmente buscou-se uma configuração do modelo série-paralelo com uma boa predição de um passo à frente. Resultado satisfatório foi obtido com uma rede com 4 neurônios na camada de entrada, 15 neurônios na camada escondida e com atrasos de ordem 4 nas entradas da rede.

O algoritmo utilizado para o treinamento o *back-propagation* da rede com o algoritmo regularização Bayesiana para o ajuste dos pesos sinápticos dos neurônios, esse algoritmo levou mais tempo para o processamento, mas foi o algoritmo que demonstrou os melhores resultados. O processo de regularização Bayesiana minimiza uma combinação dos erros quadráticos e pesos da rede de maneira a melhorar a generalização. No gráfico da Figura 5 é possível observar o comportamento do seu treinamento onde foi possível atingir melhor resultado de treinamento seu MSE (*Mean Squared Error*) em português erro quadrático medido foi de $8,2441 \cdot 10^{-10}$ em 957 *epochs*, porém durante sua fase de teste não foi como o esperado, porém foi satisfatório.

Figura 5. Performance e melhor treinamento.

A resposta de saída da rede foi satisfatória mesmo que tenha alguns erros, mas isso ocorreu devido ao número de coletas, como pode ser observado na Figura 6 no gráfico dos erros o resultado satisfatório mesmo que tenha ocorrido alguns durante a sua saída, porém a rede conseguiu atingir seu objetivo como podemos como podemos contar observando o gráfico de entrada e saída, porém durante o teste de *Output* (saída da rede) apresentou maior parte dos erros, assim comprovando que a Figura 6 mostra em relação ao período de treinamento.

Figura 6. Comparação de entrada com a saída da rede.

5. CONCLUSÃO

Neste trabalho foi apresentada uma metodologia para desenvolvimento de um sensor inteligente usando rede neuronal com múltiplas camadas *Bayesian Regularization Backpropagation* (RB) para estimação do maior ângulo de irradiação solar, isto levando ao ponto de máxima de potência (MPP). Os resultados obtidos através deste estudo foram satisfatórios viabilizando o desenvolvimento

do sistema embarcado responsável pela captação do dados online para RNA. Foi possível também compreender toda estrutura de funcionamento e desenvolver um sensor inteligente, foi possível obter conhecimento em outras áreas tais como *IoT*, intensificação de sistemas e controle. Foi notável a importância de ter-se utilizado o algoritmo RB, que apresentou clareza e robustez em seus resultados e conseguiu-se estimar o ângulo de maior incidência solar comprando os resultados com outros algoritmos encontrados na literatura utilizado para obtenção do angulo de maior incidência este algoritmo atendeu as necessidades do trabalho proposto. Para a sugestão de trabalhos futuros é um melhoramento da parte física do sistema embarcado utilizando sensores UVA e UVB, para realizar o desenvolvimento de uma rede neuronal, que estima além da irradiação solar também a radiação ultravioleta.

REFERÊNCIAS

- Bhuyan, M. (2013). *Intelligent Instrumentation : Principles and Applications*. CRC Press.
- Braga, A.d.P., Carvalho, A., and Ludermir, T. (2011). *Redes Neurais Artificiais - Teoria e Pratica*. LTC, 2nd edition.
- Haykin, S. (2005). *Redes neurais: Principios e pratica*. Bookman, 2nd edition.
- Hession, PJ e Bonwick, W. (1984). Experience with a sun tracker system. *Solar energy*, 32(1), 3–11.
- Kayri, M. (2016). Predictive abilities of bayesian regularization and levenberg-marquardt algorithms in artificial neural networks: a comparative empirical study on social data. *Mathematical and Computational Applications*, 21(2), 20.
- Kuszamaul, S., Ellis, A., Stein, J., and Johnson, L. (2010). Lanai high-density irradiance sensor network for characterizing solar resource variability of mw-scale pv system. 000283–000288. doi:10.1109/PVSC.2010.5615868.
- Mancilla-David, F., Riganti-Fulginei, F., Laudani, A., and Salvini, A. (2014). A neural network-based low-cost solar irradiance sensor. *IEEE Transactions on Instrumentation and Measurement*, 63(3), 583–591. doi:10.1109/TIM.2013.2282005.
- Ranky, P.G. (2002). Smart sensors. *Sensor review*, 22(4), 312–318.
- Rastko R. Selmic, Vir V. Phoha, A.S.a. (2016). *Wireless Sensor Networks: Security, Coverage, and Localization*. Springer International Publishing, 1 edition.
- Soloman, S. (2009). *Sensors Handbook, Second Edition*. 2 edition.
- Soloman, S. (2010). *Sensors And Control Systems In Manufacturing*. McGraw-Hill, 2nd ed edition.
- Topo, S. (2018). *Solar Topo - Solar Calculations with topographics*. URL <http://www.solartopo.com/>.
- Yamasaki, H. (ed.) (1996). *What are the intelligent sensors*, volume 3 of *Handbook of Sensors and Actuators*. Elsevier Science B.V. doi:[https://doi.org/10.1016/S1386-2766\(96\)80026-0](https://doi.org/10.1016/S1386-2766(96)80026-0).
- Yue, Z., Songzheng, Z., and Tianshi, L. (2011). Bayesian regularization bp neural network model for predicting oil-gas drilling cost. In *2011 International Conference on Business Management and Electronic Information*, volume 2, 483–487. IEEE.
- Yurish, S.Y. (2009). Sensors: Smart vs. intelligent. *Sensors and Transducers Journal*.