

Redes neurais artificiais e energias renováveis: uma revisão da literatura

Liviam Soares Lacerda (Universidade Federal da Paraíba) soaresliviam@gmail.com
Eugenio Afonso de Souza Fischetti (Universidade Federal da Paraíba) eugenioasfischetti@gmail.com
Victor Gonçalves Araújo (Universidade Federal da Paraíba) victor.g.araujo10@gmail.com
Paulo Rotela Junior (Universidade Federal da Paraíba) paulo.rotela@gmail.com
Lígia de Oliveira Franzosi Bessa (Universidade Federal da Paraíba) ligiafranzosi@hotmail.com

Resumo:

As redes neurais artificiais (RNA) começaram a ser estudadas no ramo da ciência da computação a partir de 1943. As RNAs são sistemas de processamento baseada no sistema nervoso biológico, que consistem em grupos de unidades chamadas neurais que são análogas aos neurônios nervosos. RNA tem sido cada vez mais utilizada como ferramenta de modelagem e previsão, em diversas áreas de conhecimento desde a medicina à engenharia. RNA tem como vantagem não requerer conhecimento prévio, pois possui como característica o aprendizado a partir de fonte de dados inseridos. O artigo tem como objetivo estudar RNA e sua aplicabilidade em energias renováveis, para isso foi necessário um estudo na literatura, utilizando como método de pesquisa a revisão sistemática da literatura. A partir da revisão da literatura, foi visto quais áreas de conhecimento estão aplicando RNA, e quais as tendências de pesquisa. Foi possível concluir que RNA é uma ferramenta robusta, com vantagens de velocidade, a simplicidade e a capacidade de modelar problemas complexos.

Palavras chave: Redes neurais artificiais, energia renováveis, aplicações em energia renováveis.

Artificial neural networks and renewable energies: a review of the literature

Abstract

Artificial neural networks (ANNs) began to be studied in the field of computer science from 1943 onwards. ANN are systems of processing based on the biological nervous system, which consist of groups of units called neural units that are analogous to nerve neurons. ANN has been increasingly used as a modeling and forecasting tool in many areas of knowledge from medicine to engineering. ANN has the advantage of not requiring prior knowledge, since it has as its characteristic the learning from the inserted data source. The article aims to study ANN and its applicability in renewable energies, for this it was necessary a study in the literature, using as a research method the systematic review of the literature. From the literature review, it was seen which areas of knowledge are applying ANN, and which are the research trends. It was possible to conclude that ANN is a robust tool, with advantages of speed, simplicity and the ability to model complex problems.

Key-words: Artificial neural networks, renewable energy, applicability in renewable energies

1. Introdução

As Redes Neurais Artificiais (RNA) fazem parte da chamada inteligência artificial, um ramo de pesquisa em ciência da computação. Foi apresentado pela primeira vez em 1943 pelo

neurofisiologista McCulloch e pelo matemático Walter Pitts (CAMELO *et al.*, 2018).

Redes neurais artificiais são os sistemas de processamento distribuído que foram inspirados pelo sistema nervoso biológico. Eles consistem em grupos de unidades chamadas “neurais” que são análogas aos neurônios nervosos. Cada neurônio é conectado um ao outro com os pesos, comumente chamado de pesos sinápticos (VELÁZQUEZ, CARTA e MATÍAS, 2011).

Redes neurais artificiais tem sido utilizadas cada vez mais como uma ferramenta de modelagem promissora em quase todas as áreas, onde abordagens quantitativas podem ser usadas para ajudar na tomada de decisões (BISSACOT *et al.*, 2016). Dados de sistemas de energia renovável, sendo inerentemente ruidosos, são bons candidatos a serem tratados com redes neurais (KALOGIROU, 2001).

Há muitos exemplos de aplicações que empregam redes neurais na resolução de problemas. Por exemplo, elas têm sido usadas em processamento de sinal, medicina, reconhecimento de padrões, robótica, controle, previsão, produção de fala, reconhecimento de voz, negócios, manufatura, sistemas de energia e nos campos de energia renovável e energia eólica (VELÁZQUEZ, CARTA e MATIAS, 2011).

O método das redes neurais artificiais, tem sido empregado com sucesso em muitos campos nos últimos anos e fornece resultados muito realistas em relação às previsões, é aplicado para realizar uma projeção orientada para o futuro (YILDIRIM, OZSAHIN, OKAN, 2014). Uma das vantagens das RNAs é que elas não requerem conhecimento prévio de distribuição de dados para realizar análises, e isso os distingue da análise estatística convencional (COELHO JUNIOR *et al.*, 2013).

O objetivo deste artigo é estudar redes neurais artificiais na literatura e entender em quais áreas estão sendo aplicadas o método, para isso será necessária uma revisão sistemática da literatura afim de compreender de forma sistêmica o assunto, e buscar dados de qualidade e confiáveis afim de entender a pesquisa.

2. Método de pesquisa

O método de pesquisa adotado foi o de revisão sistemática da literatura, com o objetivo de analisar criticamente o tema Redes neurais artificiais e sua relação com energias renováveis, utilizando do método científico para o alcance do objetivo. A revisão sistemática consiste num método de pesquisa que utiliza como fonte de dados a literatura, com aplicação de métodos explícitos e sistematizados de busca, apreciação crítica e síntese da informação selecionada (SAMPAIO E MANCINI, 2007).

O processo de revisão sistemática iniciou com a definição das palavras chaves para busca, definidas a partir do objeto de pesquisa, sendo redes neurais artificiais e energias renováveis, com o intuito do melhor entendimento da aplicação. Posteriormente, determinou-se uma base de dados alinhada com o tema do estudo, o Web of sciences. Em uma busca inicial com as palavras chaves “Artificial Neural Network” e “renewable energy” obteve-se no Web of sciences, um resultado que representou 286 artigos. O processo de seleção de artigos operacionalizou-se como descrito na figura 1




Figura 1: Metodo de pesquisa

Diante do tamanho da amostra, foram analisados os artigos com o intuito de se obter uma amostra mais densa para estudo, como filtros foram utilizados o alinhamento de palavras-chave, alinhamento do título, alinhamento do resumo e por último o alinhamento do artigo completo. Foram considerados os artigos que envolvessem energias renováveis e aplicações de otimização do uso, artigos de revisões de literatura, considerados os artigos mais citados e mais recentes. Com a base colhida, foi visto a evolução nas pesquisas sobre RNA, a partir da Figura 2 é possível ver o crescimento recente nessa área, a partir de 2010, e um crescimento de 54% nos últimos três anos considerados 2016 a 2018, relacionados ao triênio anterior




Figura 2: Evolução de pesquisas acadêmicas

A partir da base de dados, foi analisada em rede as palavras chaves utilizadas nos artigos e suas referências, como é visto no mapa da Figura 3. Foi utilizado a ferramenta VOSviewer, que utiliza a técnica de mapeamento *visualization of similarities* VOS, a técnica é detalhada por Eck *et al.* (2010).




Figura 3: Network palavras-chaves

Com a análise de rede vista, é possível visualizar clusters de pesquisas envolvendo RNA, como confirmando no gráfico da Figura 3, as pesquisas são mais desenvolvidas a partir de 2010, e foi iniciado com estudos em energias renováveis, como gerenciamento de sistemas, energia eólica e energia solar. Algumas pesquisas recentes apontam para modelos de previsão, algoritmos de otimização, principalmente envolvendo energia eólica e solar, como também modelos de sistemas de energia híbridos.

3. Redes neurais artificiais

Haykin (2001) define redes neurais como “um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível”, o autor comenta que o conhecimento é adquirido através de processos de aprendizagem e os pesos sinápticos (similares a conexão entre neurônios) são utilizados para armazenar o conhecimento adquirido. O autor representa um modelo não-linear de um neurônio através da Figura 4.




Figura 4: Modelo não linear de um neurônio

Fonte: Haykin (2001)

O Kalogirou (2001) definiu redes neurais artificiais (RNA) como coleções de pequenas unidades de processamento individualmente interconectadas, no qual a informação é passada entre essas unidades de interconexão. As redes neurais foram inspiradas pelo sistema nervoso biológico, consistem em um grupo de unidades chamadas “neurônios” que são análogas aos neurônios nervosos, conectados um com os outros através de pesos sinápticos (VELÁZQUEZ, CARTA e MATIAS, 2011). Kalogirou (2001) descreve que uma conexão de entrada tem dois valores associados, um valor de entrada e um peso, e a saída da unidade é uma função do valor somado.

Haykin (2001) mostra que uma rede neural tem o poder de generalizar, a partir de sua estrutura e habilidade de aprender, possibilitando resolver problemas altamente complexos que são intratáveis. Haykin (2001) discute sobre as propriedades e capacidades do uso de redes neurais, abordadas no Quadro 1.

Propriedades/capacidades	Descrição
Não-linearidade	Um neurônio artificial pode ser linear ou não-linear. A não linearidade é uma propriedade importante, particularmente se o mecanismo físico responsável pela geração do sinal de entrada for inerentemente não-linear.
Mapeamento de Entrada-Saída	A rede aprende a partir de exemplos de tarefas (entrada única e saída desejada), que envolve a modificação dos pesos sinápticos, e a partir disso a construção de um mapeamento de entrada-saída para o problema considerado.
Adaptabilidade	Capacidade de adaptar seus pesos sinápticos a modificações do meio ambiente, pode ser facilmente <i>retrainada</i> para lidar com pequenas condições operativas do ambiente. As constantes de tempo principais do sistema precisam ser grandes o suficiente para que o sistema ignore pequenas perturbações, mas suficientes para responder a mudanças significativas, deixando o sistema robusto o suficiente.
Resposta a Evidências	A rede neural precisa ser projetada para fornecer informação sobre o padrão particular selecionado, assim como sobre a confiança ou crença na decisão tomada, rejeitando padrões ambíguos e melhorando o desempenho de classificação da rede
Informação contextual	O conhecimento é representado pela própria estrutura e estado de ativação de uma rede neural.
Tolerância a falhas	Devido à natureza distribuída da informação armazenada na rede, a rede neural pode continuar a responder de forma aceitável se for danificada. Para assegurar a

	tolerância a falhas pode ser necessário medidas corretivas no projeto do algoritmo utilizado.
Implementação em VLSI	VLSI (<i>very-large-scale-integration</i>) fornece um meio de capturar comportamentos realmente complexos de uma forma altamente hierárquica.
Uniformidade de análise e projeto	Os neurônios representam um ingrediente comum a todas as redes neurais, tornando possível compartilhar teorias e algoritmos de aprendizagem. Redes modulares podem ser construídas através de uma integração homogênea de módulos.
Analogia neurobiológica	O processamento paralelo de informações tolerante a falhas é rápido e poderoso. Os neurobiólogos utilizam RNA como ferramenta de pesquisa para a interpretação de fenômenos neurobiológicos, e os engenheiros procurando novos métodos para resolver problemas mais complexos.

Fonte: Haykin (2001)

Quadro 1- Propriedades e capacidades do uso de redes neurais

As RNAs não precisam de um modelo matemático rígido, e os parâmetros de calibração podem ser desenvolvidos usando dados por meio de treinamento ou processo de aprendizado (BOLANCA *et al.*, 2017). A modelagem de RNA é realizada em duas etapas, o primeiro passo é treinar a rede e o segundo passo é testar a rede com dados (OZGUR, 2014). O sistema precisa treinar em um conjunto de dados de entrada, conhecido como conjunto de dados de treinamento (SINGH, 2016).

Existem várias arquiteturas neurais, a mais amplamente utilizada em aplicações de engenharia é a rede neural multicamadas, que consiste em uma camada de entrada, uma camada de saída e uma camada oculta, Haykin (2001) representa um grafo de modelo visto na Figura 5. As camadas de entrada e saída representam as variáveis de entrada e saída do modelo, e as camadas ocultas mantêm a capacidade da rede de aprender as relações não-lineares entre as variáveis de entrada e saída (OZGUR, 2014).




Figura 5: Grafo de arquitetura de uma rede de múltiplas camadas

Fonte: Haykin (2001)

As RNA de multicamada, abordagem Multi Layer Perceptron (MLP), tem sido aplicada com sucesso para a resolução de problemas complexos, através do treinamento supervisionado através de um algoritmo de retropropagação de erro, baseado na regra de aprendizagem por correção de erro (HAYKIN, 2001). A rede neural multicamadas consiste em pelo menos três camadas: entrada, saída e camada oculta. As camadas de entrada e saída representam as variáveis de entrada e saída do modelo, e as camadas ocultas mantêm a capacidade da rede

aprender as relações não lineares entre variáveis de entrada e saída (KALOGIROU, 2001).

Existe uma estrutura de RNA conhecida como a rede de *feed-forward* de múltiplas camadas, que consiste em um algoritmo de aprendizagem de propagação, onde cada camada de nós recebe entradas das camadas anteriores (CAMELO *et al.*, 2018). RNA com algoritmos *feed-forward* aprende mudando os pesos das conexões, e essas mudanças são armazenadas como conhecimento. Bolanca *et al.* (2017) utilizaram uma RNA *feed-forward* de três camadas para a correlação em seus estudos.

As principais vantagens da RNA em comparação a outros sistemas especialistas são a velocidade, a simplicidade e a capacidade de modelar um problema multivariado para resolver relações complexas entre as variáveis e extrair as relações não lineares por meio de dados de treinamento (VELÁZQUEZ, CARTA e MATIAS, 2011). A metodologia de RNA é mais robusta (ou seja, não requer um alto nível de julgamento do operador), e usa um sofisticado modelo não linear para alcançar um alto desempenho de classificação (BISSACOT *et al.*, 2016).

4. Uso de redes neurais

Redes neurais artificiais têm sido utilizadas em aplicações sobre desenvolvimento sustentável no setor energético em termos de produção e uso de energia. Kennedy, Dinh e Basu (2016) mostraram a aplicação de RNAs no reconhecimento de padrões e interpretaram sua influência na previsão do comportamento do cliente em relação à escolha tecnológica. Redes neurais artificiais apresentam uma solução ideal para resolver muitos problemas em muitas aplicações de sistemas elétricos como controle, identificação e classificação (MOKHTAR, 2016).

Yan, Abbes, Francois (2017) utilizaram RNA levando em consideração a incerteza da previsão em sistemas fotovoltaicos, para avaliar a incerteza utilizaram três camadas para estimar erros de previsão de carga e energia. Karabacak e Cetin (2014) discutiram aplicações de RNAs em sistemas de energia renovável, como fotovoltaica, energia eólica e sistemas híbridos. Os autores mostram que para a energia solar, os estudos se baseiam na previsão da irradiação solar e dimensionamento de sistemas de energia. Mokhtar (2016) realizou uma aplicação para o controle e análise de um gerador fotovoltaico e a energia reativa no sistema de geração, propondo um modelo razoável de sistema de geração.

As RNAs têm a capacidade de aprendizado, são orientadas por dados e possuem alta precisão de predição se comparadas a outros métodos, por esses motivos tornaram-se métodos alternativos as técnicas convencionais em diversas aplicações de energia solar (CHITEKA, ENWEREMADU, 2016). Chiteka, Enweremadu (2016) desenvolveram um modelo de RNA que pode ser usado como ferramenta eficiente para prever a radiação solar sem equipamentos de medição direto. Bou-Rabee *et al.* (2017) desenvolveram um modelo de previsão baseado em Redes Neurais Artificiais para prever a radiação solar média diária em cinco locais diferentes e possuíam arquiteturas *feed-forward*, os resultados mostraram que o modelo é preciso e aplicável e com eficiência de 94,75%, o modelo desenvolvido foi direcionado para ser uma ferramenta de avaliação para prever a instalação de energia solar estimar a quantidade de energia que pode ser aproveitada.

Dervilis (2014) utiliza RNA em métodos de reconhecimento de padrão no campo de energia eólica. Manobel *et al.* (2018) utiliza um método baseado em RNA para calcular a curva de potência de qualquer turbina eólica que depende de um grupo mínimo de variáveis de entrada, sendo velocidade do vento e direção do vento. Os autores concluíram que a combinação da filtragem de processos Gaussianos com modelagem RNA oferece um método automático e

preciso para calcular a curva de potência, com economias subsequentes de recursos quando comparada com a filtragem manual e outros métodos paramétricos e não paramétricos.

Singh (2016) apresentou um modelo de previsão de energia eólica na arquitetura de rede neural em feed- forward. e mostrou que RNA é uma ferramenta eficiente e valiosa para a estimativa de energia eólica para geradores eólicos. Ozgur (2014) mostrou um modelo de RNA baseada em análise de valor presente líquido, para o estudo da viabilidade econômica, mostrando que os sistemas de energia eólica para diferentes tipos de turbinas são lucrativos.

Dombayci (2010) desenvolveu um modelo de RNA para prever o consumo de energia de aquecimento por hora de uma casa modelo projetada, seus resultados mostram que os valores de consumo de energia podem ser ditos com grande precisão, indicando que a RNA é um método muito eficaz para ser usado para este tipo de previsões. Cabrera *et al.* (2017) utilizaram RNA como ferramenta de sistema de controle para um protótipo de pequena de escala de uma planta de dessalinização.

Macedo *et al.* (2015) utilizaram RNAs para escolher as políticas mais adequadas para cada tipo de consumidor, mostrou desempenho satisfatório possibilitando a otimização do sistema e o preço dinâmico com base nos hábitos do consumidor. Bolanca *et al.* (2017) criaram um modelo para definir uma política mais eficiente e ambientalmente mais sustentável, devendo ser transferível a outros lugares aplicando o procedimento de treinamento de RNA descritos.

Azadeh, Babazadeh, Asadzadeh (2013) apresentaram uma abordagem para estimativa e previsão otimizadas do consumo de energia renovável, considerando fatores ambientais e econômicos, a RNA treina e testa os dados com a abordagem Multi Layer Perceptron (MLP). Os autores mostraram que o modelo de RNA proposto pode ser muito benéfico para melhorar e otimizar o consumo de energia renovável em algumas localidades remotas ou rurais, sem dispositivos disponíveis para medir o consumo de energia renovável.

Aien *et al.* (2014) criaram uma metodologia para estimativa de estado em tempo real, preços de energia por estudos probabilísticos de fluxo de potência ótima usando o conceito de redes neurais artificiais híbridas. Analogamente, Barelli *et al.* (2018) propuseram um modelo de RNA para prever o escalonamento de cargas programáveis considerando as condições climáticas relativas ao dia atual e ao anterior, além da previsão do tempo para o dia seguinte. Aien *et al.* (2014) mostraram o uso de RNA em diferentes aplicações de sistemas de potência, como previsão de carga, previsão de preço de eletricidade, previsão de velocidade do vento e estimativa de estado em sistema de distribuição.

O uso de redes neurais artificiais pode ser particularmente útil quando o objetivo principal é a classificação de resultados e interações importantes ou não-linearidades complexas existirem em um conjunto de dados, também requer treinamento estatístico menos formal e pode ser desenvolvido usando múltiplos algoritmos de treinamento diferentes (BISSACOT *et al.*, 2016).

5. Conclusões

As redes neurais artificiais está associada como um sistema de processamento de sinal e informação, consistindo de um grande numero de processadores simples, chamados neurônios, que simulam sistemas nervosos biológicos.

A metodologia de RNA é robusta (não requer um alto nível de julgamento do operador), e usa um sofisticado modelo não linear para alcançar um alto desempenho de classificação (BISSACOT *et al.*, 2016). Em vez de regras complexas e rotinas matemáticas, as redes neurais

artificiais são capazes de aprender os principais padrões de informação dentro de um domínio de informação multidimensional (VELÁZQUEZ, CARTA e MATIAS, 2011).

Modelos de redes neurais artificiais para reconhecimento, previsão e classificação de padrões avançaram significativamente ao longo da última década, as RNAs provam ser mais rápidas que simulações dinâmicas tradicionais, com destaque para sua capacidade de previsão (KENNEDY, DINH e BASU, 2016).

Foi visto que RNA é um método importante para modelagem de sistemas, com o mínimo de entrada de dados, pois a ferramenta permite o aprendizado, trazendo confiabilidade e diminuindo as incertezas do sistema. Azadeh, Babazadeh e Asadzadeh (2013) mostraram que o modelo de RNA proposto é superior quando comparado a outras abordagens de previsão, e que pode ser efetivamente utilizado para a previsão do consumo de energia renovável. As operações de RNA são altamente dependentes da seleção dos dados usados em seu treinamento, é aconselhável que se use estratégias específicas para captura de dados operacionais (CABRERA *et al*, 2017).

A partir da revisão sistemática, foi possível analisar que algumas pesquisas recentes sobre RNA apontam para modelos de previsão, algoritmos de otimização, principalmente envolvendo energia eólica e solar, como também modelos de sistemas de energia híbridos. Podendo concluir que aplicações de RNA em energias renováveis são lacunas na literatura a serem exploradas.

Agradecimentos

Os autores agradecem a Capes e CNPq pelo auxílio financeiro e incentivo à pesquisa.

Referências

- AZADEH, A.; BABAZADEH, R.; ASADZADEH, S. M.** Optimum estimation and forecasting of renewable energy consumption by artificial neural networks. *Renewable and Sustainable Energy Reviews*, v. 27, p. 605–612, 2013.
- BARELLI, L.; BIDINI, G.; BONUCCI, F.; OTTAVIANO, A.** Residential micro-grid load management through artificial neural networks. *Journal of Energy Storage*, v. 17, n. February, p. 287–298, 2018.
- BISSACOT, A. C. G.; SALGADO, S. A. B.; BALESTRASSI, P. P.; PAIVA, A. P.; ZAMBRONI SOUZA, A. C.; WAZEN, R.** Comparison of Neural Networks and Logistic Regression in Assessing the Occurrence of Failures in Steel Structures of Transmission Lines. *The Open Electrical & Electronic Engineering Journal*, v. 10, n. 1, p. 11–26, 2016.
- BOLANČA, T.; STRAHOVNIK, T.; UKIC, S.; STANKOV, M. N.; ROGOSIC, M.** Modeling of policies for reduction of GHG emissions in energy sector using ANN: case study—Croatia (EU). *Environmental Science and Pollution Research*, v. 24, n. 19, p. 16172–16185, 2017.
- BOU-RABEE, M.; SULAIMAN, S. A.; SALEH, M. S.; MARAFI, S.** Using artificial neural networks to estimate solar radiation in Kuwait. *Renewable and Sustainable Energy Reviews*, v. 72, n. January, p. 434–438, 2017.
- CABRERA, P.; CARTA, J. A.; GONZÁLEZ, J.; MELIÁN, G.** Artificial neural networks applied to manage the variable operation of a simple seawater reverse osmosis plant. *DESALINATION*, v. 416, p. 140–156, 2017.
- CAMELO, H. N.; LUCIO, P. S.; LEAL JUNIOR, J. B. V.; CARVALHO, P. C. M.; SANTOS, D. V. G.** Innovative hybrid models for forecasting time series applied in wind generation based on the combination of time series models with artificial neural networks. *Energy*, v. 151, p. 347–357, 2018.
- CHITEKA, K.; ENWEREMADU, C. C.** Prediction of global horizontal solar irradiance in Zimbabwe using artificial neural networks. *Journal of Cleaner Production*, v. 135, p. 701–711, 2016.
- DERVILIS, N.; CHOI, M.; TAYLOR, S. G.; BARTHORPE, R. J.; PARK, G.; FARRAR, C. R.; WORDEN, K.** On damage diagnosis for a wind turbine blade using pattern recognition. *JOURNAL OF SOUND AND VIBRATION*, v. 333, n. 6, p. 1833–1850, mar. 2014.

DOMBAYCI, Ö. A. The prediction of heating energy consumption in a model house by using artificial neural networks in Denizli-Turkey. *Advances in Engineering Software*, v. 41, n. 2, p. 141–147, 2010.

KARABACAK, K.; CETIN, N. Artificial neural networks for controlling wind-PV power systems: A review. *Renewable and Sustainable Energy Reviews*, v. 29, p. 804–827, 2014.

KENNEDY, M.; DINH, V.-N.; BASU, B. Analysis of consumer choice for low-carbon technologies by using neural networks. *JOURNAL OF CLEANER PRODUCTION*, v. 112, n. 4, p. 3402–3412, jan. 2016.

MACEDO, M. N. Q.; GALO, J. J. M.; ALMEIDA, L. A. L.; LIMA, A. C. C. Demand side management using artificial neural networks in a smart grid environment. *Renewable and Sustainable Energy Reviews*, v. 41, p. 128–133, 2015.

MANOBEL, B.; SEHNKE, F.; LAZZÚS, J. A.; SALFATE, I.; FELDER, M.; MONTECINOS, S. Wind turbine power curve modeling based on Gaussian Processes and Artificial Neural Networks. *Renewable Energy*, v. 125, p. 1015–1020, 2018.

MOKHTAR, B. Active and reactive power neurocontroller for grid-connected photovoltaic generation system. *Journal of electrical Systems*, v. 1, n. August 1955, p. 146–157, 2016

SAMPAIO, R. F.; MANCINI, M. C. Estudos de revisão sistemática: um guia para síntese criteriosa da evidência científica. *Revista brasileira de fisioterapia*, v. 11, n. 1, p. 83-89, 2007.

VELÁZQUEZ, S.; CARTA, J. A.; MATÍAS, J. M. Influence of the input layer signals of ANNs on wind power estimation for a target site: A case study. *Renewable and Sustainable Energy Reviews*, v. 15, n. 3, p. 1556–1566, 2011.

YAN, X.; ABBES, D.; FRANCOIS, B. Uncertainty analysis for day ahead power reserve quantification in an urban microgrid including PV generators. *Renewable Energy*, v. 106, p. 288–297, 2017.

YILDIRIM, I.; OZSAHIN, S.; OKAN, O. T. Prediction of non-wood forest products trade using artificial neural networks. *Journal of Agricultural Science and Technology*, v. 16, p. 1493–1504, 2014.