

REVISÃO SISTEMÁTICA: APLICAÇÃO DE REDES NEURAIS PARA PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA

Eduarda A. Antonioli (UTFPR) E-mail: antonioli@alunos.utfpr.edu.br

José Airton Azevedo dos Santos (UTFPR) E-mail: professorjoseairton@gmail.com

Alex Lemes Guedes (UTFPR) E-mail: alexlemes@gmail.com

Leandro Antônio Pasa (UTFPR) E-mail: pasa@utfpr.edu.br

Carla Adriana Pizarro Schmidt (UTFPR) E-mail: carlaschmidt@professores.utfpr.edu.br

Resumo: A previsão do consumo de energia é importante para o gerenciamento dos sistemas, contribuindo para operação estável e confiável da matriz. Destaca-se o uso de redes neurais para modelagem de sistemas elétricos. O objetivo dessa revisão sistemática é avaliar 15 artigos que utilizaram redes neurais para previsão do consumo de energia elétrica, e, através da análise quanto as variáveis de entrada, configuração da rede e performance, identificar se este é um método adequado para previsão de energia elétrica. Observa-se que os artigos selecionados são atuais e foram publicados em periódicos de boa qualidade. As variáveis de entrada mais populares são relacionadas ao consumo e crescimento populacional. Na configuração da rede, normalmente são usadas redes com somente uma camada oculta. O número de neurônios varia, mas o maior valor encontrado foi de 10 neurônios. Para avaliação da performance, além de diversos tipos de erro, podem ser usadas ferramentas estatísticas, ou ainda comparação com outros modelos. Conclui-se que o uso de redes neurais foi adequado em 87% dos artigos analisados neste trabalho.

Palavras-chave: Projeção, modelos, eletricidade.

SYSTEMATIC REVIEW: APPLICATION OF NEURAL NETWORK TO FORECAST ELECTRICAL ENERGY CONSUMPTION

Abstract: The prediction of energy consumption is important for the management of the systems, contributing to the stable and reliable operation of the matrix. The use of neural networks to model electrical systems is highlighted. The aim of this systematic review is to evaluate 15 articles that used neural networks to forecast electricity consumption, and, through the analysis of the input variables, network configuration and performance, identify whether this is an appropriate method for predicting electricity. It was observed that the selected articles are current and have been published in journals of good quality. The most popular input variables are related to consumption and population growth. In network configuration, networks with only one hidden layer are typically used. The number of neurons varies, but the highest value found was 10 neurons. For performance evaluation, in addition to various types of errors, statistical tools can be used, or even comparison with other models. It was concluded that the use of neural networks was adequate in 87% of the articles analyzed in this study.

Keywords: Projection, models, electricity.

1. Introdução

A previsão de potência permite uma eficiência e qualidade maior do sistema, tendo impactos na segurança operacional e economia nas redes de energia (DI PIAZZA ET. AL., 2020). Fornece uma orientação no planejamento estratégico e implementação de processos (OGCU ET. AL., 2012). A exatidão da previsão contribui para a operação estável e confiável da matriz energética. Uma previsão acima do real implica em uso dos recursos financeiros em investimento supérfluos. Estimar abaixo implica em custos

maiores de operação e potenciais faltas de energia (KAYTEZ ET AL., 2015).

Há diversos modelos que foram usados na literatura, cada um com suas vantagens e desvantagens. A escolha do melhor modelo para previsão depende de uma série de fatores, como o histórico de dados disponíveis, o horizonte de tempo de previsão, entre outros. O uso de redes neurais tem se destacado devido a sua capacidade de descrever o comportamento de variáveis não-lineares, lidar bem com dados com ruído e boa previsibilidade. A energia elétrica é uma variável de modelagem muito complexa, irregular e apresenta variação dos fatores de influência (ZENG ET.AL., 2017).

O objetivo desta revisão é analisar outros estudos que utilizam redes neurais para previsão do consumo de energia elétrica e verificar se são adequadas para esse fim. Visando facilitar o entendimento, esta revisão sistemática foi dividida em seções. Para situar o leitor ao objeto de estudo, apresenta-se uma breve revisão da literatura na seção 2 com os principais conceitos relacionados aos estudos de previsão de energia elétrica. Em seguida, na seção 3, explica-se a metodologia utilizada para seleção e avaliação dos artigos. A seção 4 trata de uma análise dos artigos, identificando pontos positivos e negativos dos trabalhos selecionados e comparando os estudos. Por fim, são mostradas as conclusões na seção 5 e as referências utilizadas neste artigo.

2. Fundamentação teórica

A modelagem de um sistema encontra a relação entre as variáveis de entrada e um conjunto de dados (NIZAMI E AL-GARNI, 1995). Para Di Piazza et. Al. (2020), os métodos de previsão podem ser divididos em cinco categorias:

- Métodos de persistência: assume que a variável a ser prevista continua a mesma após um incremento no tempo. Apesar da simplicidade, é adequada para previsões de curto e curtíssimo prazo;
- Modelos físicos: baseados em complexos modelos matemáticos, requerem significativos recursos computacionais. São usados em previsões de médio e longo prazo e têm melhores resultados quando as condições climáticas são estáveis;
- Modelos de séries temporais lineares: são fáceis de implementar e com baixo custo, mas não são adequados para modelar fenômenos que não são lineares;
- Modelos baseados em inteligência artificial: são adequados para dados sazonais e com não-linearidades, porém sua formulação e regulação são complexos;
- Estruturas híbridas.

As redes neurais podem ser descritas como uma tentativa de imitar o cérebro humano, uma vez que foram desenvolvidas com características semelhantes a neurônios biológicos. São uma alternativa que permite que os modelos sejam construídos sem o conhecimento explícito das variáveis (NIZAMI E AL-GARNI, 1995). Fundamentalmente, são funções parametrizadas. Tem a habilidade de aprender padrões complexos e generalizar a informação aprendida (OGCU ET. AL., 2012).

O treinamento da rede consiste na aplicação de um conjunto de passos ordenados com o

intuito de ajustar os pesos e limiares dos neurônios, sintonizando a rede para que suas respostas estejam próximas aos valores desejados (SILVA ET. AL., 2010).

A arquitetura da rede neural define a forma como os neurônios estão dispostos. A topologia, considerando determinada arquitetura, é definida como diferentes formas estruturais que a rede pode assumir. De acordo com Silva et. Al. (2010), a rede neural pode ser dividida em três partes, mostradas na figura 1 e nomeadas conforme abaixo:

- a) Camada de entrada: responsável pelo recebimento de dados externos;
- b) Camadas escondidas: composta por neurônios que possuem a responsabilidade de extrair as características do processo em que estão inseridas;
- c) Camada de saída: neurônios responsáveis pela produção e apresentação dos resultados advindos das camadas anteriores




Figura 1 – Topologia da rede neural

Fonte: adaptado pelo autor com base em Silva et. Al. (2010).

3. Metodologia

As bases de dados eletrônica Scopus, *ScienceDirect*, *Web of science* e *IEEEExplore* foram consultadas utilizando as palavras-chaves *Energy*, *Consumption*, *Forecast* e *Neural network*.

Foram selecionados inicialmente 40 artigos que atendiam aos requisitos com base nos títulos. Entre eles foram elegidos 15 artigos relacionados a previsão do consumo de energia elétrica e que utilizassem redes neurais como um dos principais métodos. Com relação ao ano e veículo de publicação, não foram feitas restrições. Os estudos que cumpriram os critérios de inclusão foram avaliados quanto à qualidade metodológica pelo Qualis, SCR e JCR.

A análise dos artigos foi realizada conforme as orientações propostas por Rahman et.al. (2018). Após a leitura completa, os trabalhos foram analisados quanto ao modelo utilizado, as variáveis de entrada, a configuração da rede, o critério de avaliação da precisão da previsão e, por fim, de acordo com a performance da mesma através de comparação com outros modelos ou variáveis estatísticas.

4. Resultados e discussões

Essa seção foi separada em duas partes. A primeira apresenta os resultados análise da qualidade metodológica, ou seja, relativas aos veículos e ano de publicação e avaliação

dos periódicos. A segunda parte discute as informações apresentadas por cada artigo e sua contribuição para o estado da arte.

4.1. Avaliação da qualidade metodológica

O ano e o ISSN da publicação são mostrados na tabela 1. A avaliação do periódico pelo Qualis, SCR e JCR são exibidos na tabela 2.

Tabela 1 – Informação do ano e periódico de publicação dos artigos analisados

Artigo	Ano	Periódico
Azadeh et. Al. (2013)	2013	1364-0321
Azadeh et. Al (2008)	2008	0301-4215
Di Piazza et. Al. (2020)	2020	0378-4754
Katsatos e Moustiris (2019)	2018	1876-6102
Kaytez et. Al (2015)	2014	0142-0615
Lee et. Al. (2020)	2020	1996-1073
Mishra e Singh (2015)	2015	2405-8963
Mordjaoui et. Al. (2017)	2017	0360-3199
Neto e Fiorelli (2008)	2008	0378-7788
Nizami e Al-Garni (1995)	1995	0301-4215
Ogcu et. Al. (2012)	2012	1877-0428
Prado et. Al. (2020)	2020	0360-5442
Rahman et. Al. (2018)	2017	0306-2619
Seethalakshmi e Venkatalakshmi (2020)	2020	-
Zeng et. Al. (2017)	2017	0360-5442

Observa-se que um dos artigos, de Seethalakshmi e Venkatalakshmi (2020), não contém informações do periódico em que foi publicado. Esse fato se deve a origem do mesmo, que foi apresentado na *Fourth Internacional Conference of Computing Methodologies and Communication*.

Tabela 2 – Avaliação do Qualis, SJR e JCR dos periódicos dos artigos publicados

Periódico	Qualis	SJR	JCR
0142-0615	A2	1,20	3,588
0301-4215	A1	2,17	5,042
0306-2619	A1	3,61	8,848
0360-3199	A1	1,14	4,939
0360-5442	A1	2,17	6,082
0378-4754	B1	0,45	1,62
0378-7788	A2	2,06	4,867
1364-0321	A1	3,63	12,11
1876-6102	B3	0,55	-
1877-0428	B1	-	-
1996-1073	A2	0,64	2,702
2405-8963	B3	0,33	-

O periódico *Renewable & Sustainable Energy Reviews*, onde foi publicado o artigo de Azadeh et.al (2013), foi o que recebeu a melhor nota nas três plataformas de avaliação. As publicações *Energy Procedia*, *Procedia: Social and Behavioral Sciences* e *IFAC-Papersonline* não foram avaliadas pela plataforma JCR. A *Procedia: Social and Behavioral Sciences* também não possui uma avaliação atualizada de SJR, pois foi descontinuada em 2018. O último valor disponível, de 2015, foi um SJR de 0,158.

Observa-se que a pior avaliação de Qualis das publicações é B3, o que indica que foram selecionados estudos de qualidade. De fato, conforme a figura 2, quase metade dos artigos selecionado tem a melhor avaliação, A1.




Figura 2 – Distribuição de frequência percentual da avaliação Qualis dos artigos selecionados

4.2. Avaliação das características dos modelos

A análise dos modelos propostos foi subdividida em três partes. A primeira avalia as variáveis usadas como entrada. A segunda mostra as principais informações sobre a configuração das redes neurais, como número de camadas, número de neurônios e otimizadores utilizados. A última parte refere-se à avaliação da performance dos modelos desenvolvidos, com indicação das metodologias utilizadas e comparação com outros trabalhos.

4.2.1. Variáveis de entrada

O consumo de demanda pode ser afetado por variáveis externas, como temperatura, umidade e dias (MISHRA E SINGH, 2015). Alguns trabalhos, inclusive, utilizam mais de uma variável de entrada. Para avaliar o tipo de entrada, as variáveis usadas foram agrupadas nas categorias data, consumo, climáticos, população, financeiro, imagens e ambientais.

A distribuição de frequência das variáveis usadas como entrada podem ser avaliadas na figura 3. Observa-se que a categoria mais popular é consumo, que inclui dados de consumo em kWh, cargas instaladas em kW, capacidade de geração em kVA, etc.

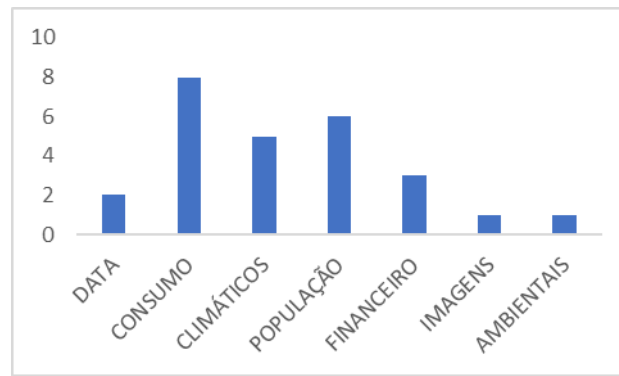


Figura 3 – Distribuição de frequência das variáveis de entrada utilizadas nos artigos

O trabalho de Lee et. Al. (2020) foi o único nesta análise a utilizar imagens para a previsão. Através dos dados noturnos de satélite, observando-se a luminosidade, foi analisada a distribuição espacial do consumo de energia no Vietnã. A partir dessa informação, do fator de desenvolvimento urbano e das estimativas de crescimento da população, usando redes neurais, foram identificadas regiões com maior possibilidade de expansão no consumo de energia. Com essa informação é possível executar um planejamento da rede elétrica no país com maior assertividade.

O objetivo de Azadeh et. Al. (2013) foi desenvolver uma rede neural para previsão de consumo de energias renováveis. Foram usadas neste trabalho variáveis diferenciadas, como emissão de gases e preço dos combustíveis, que foram incluídas na categoria ambiental e financeira, respectivamente.

O trabalho de Azadeh et. Al. (2008) foi inovador ao utilizar simulação de dados para o consumo mensal baseados no comportamento estocástico de um período de 30 dias.

Ao observar as variáveis de entrada, destaca-se o trabalho de Zeng et. Al. (2017), que utilizou a Análise de Impacto de Valor Médio (MIV) para identificar a relação entre entradas e saídas da rede neural. Após o treinamento da rede, os valores de cada neurônio são alterados em $\pm 10\%$ a cada simulação. A variação entre os erros entre as iterações identifica quais as variáveis de maior impacto. Na avaliação deste trabalho foi identificada que a população é o maior fator de influência, seguido do Produto Interno Bruto. A importação e exportação de energia não trazem alterações significativas.

Normalmente, o conjunto total de amostras é dividido em dois subconjuntos: treinamento e teste. O subconjunto de treinamento, composto por 60 a 90% dos dados é usada para o processo de aprendizado da rede. O subconjunto de testes, cuja composição é entre 10% e 40% das amostras, é usado para verificar se os aspectos da rede estão em parâmetros aceitáveis, possibilitando, assim, a validação da topologia (SILVA ET. AL., 2010). A tabela 3 mostra a divisão das amostras entre treinamento e validação nos artigos analisados. Observa-se que a maior parte dos trabalhos utiliza as faixas recomendadas pela literatura.

Tabela 3 – Separação dos dados em treinamento e validação nos artigos analisados

Artigo	Treinamento	Validação
Azadeh et. Al. (2013)	85%	15%
Azadeh et. Al (2008)	89%	11%
Di Piazza et. Al. (2020)	80%	20%

Katsatos e Moustris (2019)	80%	20%
Kaytez et. Al (2015)	100%	0%
Lee et. Al. (2020)	70%	30%
Mishra e Singh (2015)	*	*
Mordjaoui et. Al. (2017)	Não informado	Não informado
Neto e Fiorelli (2008)	85%	15%
Nizami e Al-Garni (1995)	*	*
Ogcu et. Al. (2012)	98%	2%
Prado et. Al. (2020)	Não informado	Não informado
Rahman et. Al. (2018)	*	*
Seethalakshmi e Venkatalakshmi (2020)	Não informado	Não informado
Zeng et. Al. (2017)	65%	35%

*Dados sobrepostos no treinamento e validação

4.2.2. Configuração da rede neural

As características da rede têm impacto na performance da modelagem (KAYTEZ ET. AL., 2015). Assim, o sucesso da modelagem com redes neurais depende de suas características, como número de neurônios, número de camadas, função de ativação, algoritmo de aprendizados, pesos iniciais e número de iterações (OGCU ET. AL., 2012).

A figura 4 apresenta a distribuição percentuais dos trabalhos que utilizam uma ou duas camadas escondidas na configuração da rede, assim como aqueles trabalhos que não informaram nos artigos essa característica. A tabela 4 apresenta as informações sobre o número de neurônios usados em cada camada.




Figura 4 – Avaliação do número de camadas escondidas utilizadas nos modelos propostos pelos artigos

Observa-se na figura 4 que a rede com uma única camada oculta é a mais popular, usada em mais de metade dos artigos. Não foram analisados artigos que utilizaram mais de duas camadas escondidas

Tabela 4 – Número de neurônios na primeira e segunda camada escondida dos modelos de redes neurais dos artigos analisados

Artigos	1ª camada	2ª camada
Azadeh et. Al. (2013)	6	4
Azadeh et. Al (2008)	2	-

Di Piazza et. Al. (2020)	10	-
Katsatos e Moustris (2019)	Não-informado	Não-informado
Kaytez et. Al (2015)	10	9
Lee et. Al. (2020)	10	-
Mishra e Singh (2015)	10/07/05	-
Mordjaoui et. Al. (2017)	7	-
Neto e Fiorelli (2008)	3	3
Nizami e Al-Garni (1995)	4	-
Ogcu et. Al. (2012)	Não-informado	Não-informado
Prado et. Al. (2020)	Não-informado	Não-informado
Rahman et. Al. (2018)	Não-informado	-
Seethalakshmi e Venkatalakshmi (2020)	Não-informado	Não-informado
Zeng et. Al. (2017)	10	-

Os trabalhos de Katsatos e Moustris (2019), Prado et. Al. (2020), Ogcu et. Al. (2012) e Seethalakshmi e Venkatalakshmi (2020) não fornecem informações sobre o número de camadas escondidas nem do número de neurônios utilizados. Rahman et. Al. (2018) mostra que usou uma rede com uma camada oculta, mas não esclareceu o número de neurônios.

De acordo com Mishra e Singh (2015), um número alto de neurônios pode comprometer a memorização dos dados durante o treinamento, prejudicando o desempenho da rede. Assim, é preferível utilizar poucos neurônios.

As redes propostas foram desenvolvidas e implementadas usando o *software* MATLAB nos trabalhos Mordjaoui et. Al. (2017), Lee et. Al. (2020), Kaytez et. Al (2015) e Zeng et. Al. (2017). Os trabalhos restantes não especificaram o ambiente de desenvolvimento.

Entre os trabalhos, o algoritmo de *backpropagation* para o treinamento é o mais utilizado. Somente Neto e Fiorelli (2008), Prado et. Al. (2020) e Ogcu et. Al. (2012) não especificam qual o método utilizado. Di Piazza et. Al. (2020) utilizam o algoritmo de *backpropagation* conjugado com o algoritmo de Polak-Ribière para acelerar a convergência. Mordjaoui et. Al. (2017), Lee et. Al. (2020) e Zeng et. Al. (2017) especificam que utilizaram o método Levenberg-Marquardt, um tipo de *backpropagation*. Rahman et. Al. (2018) e Seethalakshmi e Venkatalakshmi (2020) utilizam o otimizador de pesos ADAM, que permite que a convergência seja mais rápida.

A maior parte dos trabalhos propôs um modelo único de rede neural. Em Di Piazza et. Al. (2020) foram gerados três modelos, porém somente um deles era dedicado a previsão de energia elétrica, sendo os outros dois destinados a radiação solar e velocidade do vento. Lee et. Al. (2020) testou dois modelos, sendo que um deles incluía os dados de população e o segundo não.

Em Katsatos e Moustris (2019) foram testadas 9 redes, sendo três para o consumo de energia elétrica, três para o consumo de gás natural e três para previsão de consumo de cargas para refrigeração. Para cada uma das categorias, as variáveis de entrada das redes foram alteradas para verificar qual modelo descrevia melhor o comportamento das funções.

Neto e Fiorelli (2008) implementou seis redes, sendo 3 com base na temperatura externa e 3 usando como entrada condições climáticas, como temperatura, radiação e velocidade dos ventos. Para os dois casos, foram feitas redes para todos os dias, dias de semana e

fins de semana/feriados.

O trabalho de Prado et. Al. (2020) é muito relevante neste tópico. Apesar de propor um modelo único, o pós-processamento com algoritmo genético otimiza a combinação de 13 modelos individuais, que permitem mais de 9000 configurações para a rede neural. Assim, o método escolhido varia de acordo com a combinação da série, o período analisado e os pesos obtidos na rede.

Outros artifícios também podem ser usados para melhora do processamento. O algoritmo de momentum em Mishra e Singh (2015) permite que a aprendizagem tenha uma perspectiva mais ampla, comparando o erro atual com os anteriores e identificando casos de atualizações opostas, prevenindo que os pesos voltem para valores que não estão na direção da redução do erro. Dessa forma, evita-se que o treinamento seja mais longo que o necessário.

Redes neurais recorrentes modelam as dependências temporais através de conexões de feedback, mantendo na memória valores dessas variáveis em tempos passados Rahman et. Al. (2018). A NARX (rede não-linear autorregressiva com variáveis exógenas), usada no trabalho Di Piazza et. Al. (2020), consiste em uma rede neural *perceptron* que considera os valores das entradas e antigas saídas para atualizar a saída.

O trabalho de Rahman et. Al. (2018) utiliza *Long Short-Term Memory* (LSTM), ou memória de curto-prazo longa, para armazenar essas variáveis. Da mesma forma, o trabalho de Seethalakshmi e Venkatalakshmi (2020) utiliza esse método, junto com um conjunto de otimizadores.

O resultado do treinamento da rede neural depende dos pesos iniciais e limites. O algoritmo de evolução diferencial, aplicados em Zeng et. Al. (2017) e Seethalakshmi e Venkatalakshmi (2020), permite uma otimização das redes. Ele encontra o valor ideal para ser usado como peso inicial.

4.2.3. Avaliação dos resultados

Nos trabalhos analisados, foram utilizados como parâmetros de avaliação da performance dos modelos os seguintes itens:

- MAE – Erro médio absoluto;
- MSE – Erro médio quadrático;
- MAPE – Erro percentual absoluto médio;
- NRMSE – Erro quadrático normalizado;
- RMSE – Raiz quadrada do erro quadrático;
- MBE – Erro médio sistêmico;
- R^2 - Coeficiente de correlação.

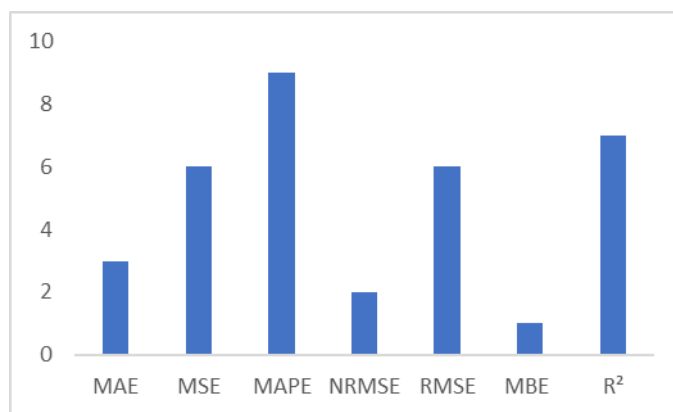


Figura 5 – Distribuição de frequência dos erros utilizados para avaliar os modelos de previsão de consumo de energia

Observa-se na figura que o erro percentual absoluto médio é a técnica mais utilizada. Além do erro, podem ser usadas outras abordagens para comprovar a efetividade e precisão dos métodos propostos.

Azadeh et. Al (2008) e Nizami e Al-Garni (1995) utilizaram análise de variância para avaliar se há diferenças significativas entre os valores previstos no teste e nos valores efetivos.

Mishra e Singh (2015) utilizou estatística no pré-processamento. Analisando o coeficiente de correlação foi possível identificar dados que poderiam ser agrupados em uma só variável. Neste caso, os dados de segunda a quinta-feira foram considerados um único grupo. De fato, conforme a figura 5, a correlação foi a segunda ferramenta mais utilizada pra analisar a adequabilidade dos modelos desenvolvidos.

A comparação com outros modelos também é uma forma de avaliação válida. Lee et. Al. (2020) e Rahman et. Al. (2018) desenvolveram mais de um modelo em seus trabalhos. A avaliação foi feita pela comparação entre seus próprios resultados.

As redes desenvolvidas por Azadeh et. Al (2008) e Di Piazza et. Al. (2020) foram comparadas com séries temporais. Zeng et. Al. (2017) avaliou seus resultados com base em resultados de algoritmos de colônias de formigas e algoritmos de colônias de abelhas de outros trabalhos. Azadeh et. Al. (2013) desenvolveu um algoritmo com Fuzzy para avaliação. Outros *softwares*, como EnergyPlus, usado em Neto e Fiorelli (2008) também fornecem uma previsão que pode ser usada como referência.

Conforme a figura 6, conclui-se que em 87% dos trabalhos analisados o uso de redes neurais apresentou resultados adequados ou foi o melhor entre os modelos comparados.




Figura 6 – Avaliação da adequação de redes neurais aos problemas propostos

Os trabalhos em que a rede neural não foi a melhor escolha são os trabalhos de Kaytez et. Al (2015) e Ogcü et. Al. (2012). Em Kaytez et. Al (2015), é usada uma máquina de vetor de suporte com o método dos mínimos quadrados, denominada LS-SVR, para fazer a previsão de consumo de eletricidade na Turquia. Enquanto o erro quadrático médio deste modelo foi de 0,169, o das redes neurais foi de 3,31. Assim, o modelo LS-SVM foi considerado um método de previsão mais rápido e preciso neste caso.

As condições apresentadas em Ogcü et. Al. (2012) são semelhantes a Kaytez et. Al (2015). Em Ogcü et. Al. (2012) também foi usada a máquina de vetor de suporte, porém, com regressão, na chamada regressão de vetores de suporte (SVR). Os modelos foram comparados com o MAPE. No período de testes a rede neural apresentou um erro percentual absoluto médio de 3,9% enquanto que o modelo SVR teve um erro de 3,3%. Dessa forma, conclui-se que os dois métodos são capazes de identificar tendências de consumo de energia elétrica, porém, o modelo SVR tem uma performance melhor e mais próxima da realidade dos que as redes neurais

5. Conclusão

Este trabalho revisou artigos que utilizam redes neurais para a previsão do consumo e energia elétrica. As publicações analisadas são de periódicos com boas avaliações e atualizadas.

Uma ampla gama de variáveis pode ser utilizada como entrada. Destaca-se para a popularidade das variáveis relacionadas ou consumo histórico e população.

A configuração da rede afeta a performance da previsão. Apesar de não haver uma metodologia fixa para sua determinação, é recomendável realizar testes para identificar qual a arquitetura que melhor se adequa a necessidade.

Para avaliação da rede, não deve ser analisado somente o erro, mas também outros parâmetros, como regressão, análise de variância ou ainda outras ferramentas estatísticas. A comparação com outros modelos de previsão também é uma abordagem válida.

Conclui-se que, apesar de não ser a única ferramenta disponível, a rede neural é adequada para realizar a previsão do consumo de energia elétrica.

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, Nov. 2013.

AZADEH, A.; GHADERI, S. F. & SOHRABKHANI, S. *A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran*. Energy policy, v. 36, n. 7, p. 2637–2644, Jul. 2008.

DI PIAZZA, A.; DI PIAZZA, M. C.; LA TONA, G. & LUNA, M. *An artificial neural network-based forecasting model of energy-related time series for electrical grid management*. Mathematics and computers in simulation, May 2020.

KATSATOS, A. L. & MOUSTRIS, K. P. *Application of Artificial Neuron Networks as energy consumption forecasting tool in the building of Regulatory Authority of Energy, Athens, Greece.* Energy Procedia, v. 157, p. 851–861, Jan. 2019.

KAYTEZ, F.; TAPLAMACIOGLU, C.; CAM, E. & HARDALAC, F. *Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines.* International Journal of Electrical Power & Energy Systems, v. 67, p. 431–438, May 2015.

LEE, H.-Y.; JANG, K. M. & KIM, Y. *Energy Consumption Prediction in Vietnam with an Artificial Neural Network-Based Urban Growth Model.* Energies, v. 13, n. 17, p. 4282, 19 Aug. 2020.

MASON, K.; DUGGAN, J. & HOWLEY, E. *Forecasting energy demand, wind generation and carbon dioxide emissions in Ireland using evolutionary neural networks.* Energy, v. 155, p. 705–720, Jul. 2018.

MISHRA, S. & SINGH, V. K. *Monthly energy consumption forecasting based on windowed momentum neural network.* IFAC-PapersOnLine, v. 48, n. 30, p. 433–438, 2015.

MOURDJAIOU, M.; HADDAD, S.; MEDOUED, A. & LAOUAF, A. *Electric load forecasting by using dynamic neural network.* International journal of hydrogen energy, v. 42, n. 28, p. 17655–17663, Jul. 2017.

NETO, A. H. & FIORELLI, F. A. S. *Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption.* Energy and Buildings, v. 40, n. 12, p. 2169–2176, Jan. 2008.

NIZAMI, K. & AL-GARNI, A. *Forecasting electric energy consumption using neural networks.* Energy policy, v. 23, n. 12, p. 1097–1104. 1995.

OĞCU, G.; DEMIREL, O. F. & ZAIM, S. *Forecasting Electricity Consumption with Neural Networks and Support Vector Regression.* Procedia - Social and Behavioral Sciences, v. 58, p. 1576–1585, Oct. 2012.

PRADO, F.; MINUTOLO, M. C. & KRISTJANPOLLER, W. *Forecasting based on an ensemble Autoregressive Moving Average - Adaptive neuro - Fuzzy inference system – Neural network - Genetic Algorithm Framework.* Energy, v. 197, p. 117159, Apr. 2020.

RAHMAN, A.; SRIKUMAR, V. & SMITH, A. D. *Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks.* Applied energy, v. 212, p. 372–385, Feb. 2018.

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

SEETHALAKSHMI, P. & VENKATALAKSHMI, K. *Prediction of Energy Demand in Smart Grid Using Deep Neural Networks with Optimizer Ensembles.* 2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC). IEEE, 11 Mar. 2020

SILVA, I. N. da; SPATTI, D. H. & FLAUZINO, R. A.. *Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático.* São Paulo: Editora Artliber, 2010.

ZENG, Y. R.; ZENG, Y.; CHOI, B. & WANG L.. *Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network.* Energy, v. 127, p. 381–396, May 2017.