



III SEMANA DA ENGENHARIA DE ENERGIAS

Energia Limpa e Acessível:

Estratégias de Inovação e Sustentabilidade

DESENVOLVIMENTO E TREINAMENTO DE REDES NEURAIAS ARTIFICIAIS PARA PREVISÃO DE DEMANDA ELÉTRICA RESIDENCIAL

Marília Facundo Santana¹, Antônio Alisson Pessoa Guimarães²

Resumo: Prever a demanda elétrica de uma cidade ou região, principalmente de locais populosos, assegura que o abastecimento de energia seja suficiente e eficaz para a população local. Através do cálculo da demanda futura, os investimentos no setor energético podem ser pensados de acordo com um planejamento futuro. Permitindo, assim, que os sistemas energéticos Estaduais e Federais sejam idealizados de forma efetiva. Dentre as formas de prever a demanda elétrica, está o uso de Redes Neurais Artificiais (RNA) que obtém um bom resultado sem a necessidade de ser feito uma “pesquisa de mercado” como é feito tradicionalmente. Uma RNA pode ser definida como um conjunto de unidades artificiais que são interligadas por um grande número de interconexões. O seu uso dar-se-á através da inserção de dados específicos para os problemas, após isso a Rede já desenvolvida dará o resultado almejado. O objetivo desta pesquisa consiste em prever, através da utilização de uma RNA desenvolvida no projeto, a demanda elétrica necessária para abastecer uma residência.

Palavras-chave: Rede neural artificial. Eletricidade. Demanda energética.

INTRODUÇÃO

Redes Neurais Artificiais (RNAs) podem ser definidas como modelos computacionais que funcionam através da obtenção de dados, os utilizando em processos que objetivam prever algo. Sua estrutura é inspirada no funcionamento do sistema nervoso dos seres vivos. Uma RNA tem a capacidade de aprender através da experiência, após alguns testes a própria rede corrige sozinha seus erros. Além disso, uma rede neural possui um erro muito pequeno entre o seu resultado real e a previsão esperada. (SILVA; SPATTI; FLAUZINO, 2010)

A previsão da demanda (carga) energética visa saber com antecedência qual a quantidade de carga energética que será necessária no futuro para que um planejamento no setor elétrico seja feito com dados precisos e evite que ocorram problemas. Esta previsão é muito importante, pois assegura o abastecimento de energia,

¹Estudante, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Instituto de Engenharias e Desenvolvimento Sustentável, e-mail: marilia_facundo@hotmail.com

² Professor, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Instituto de Engenharias e Desenvolvimento Sustentável, e-mail: alisson@unilab.edu.br



III SEMANA DA ENGENHARIA DE ENERGIAS

Energia Limpa e Acessível:

Estratégias de Inovação e Sustentabilidade

prevê o cenário energético futuro e auxilia em tomadas de decisões estratégicas em investimentos nesse setor.

Existem várias formas de prever a demanda elétrica, sendo uma delas as Redes Neurais Artificiais. Devido ao seu bom desempenho e sua baixa tolerância a erros, a utilização de Redes torna-se uma opção segura e viável. Este trabalho, propõe-se a desenvolver uma RNA que tenha a capacidade de prever, em curto prazo, a carga energética

METODOLOGIA

Para o desenvolvimento da Rede, são utilizados dados que representam o objetivo final da RNA, ou seja, valores das cargas elétricas passadas. Esses dados foram obtidos pela empresa de distribuição de energia elétrica do sul da Califórnia – Southern California Edison (SCE) – que os disponibiliza para pesquisa.

A rede construída objetiva prever a demanda elétrica horária de todos os dias dos quatro primeiros meses de 2019, para isso ela utiliza 5 variáveis (camadas de entrada). Essas variáveis possuem as vinte e quatro horas de todos os dias do mês em estudo dos últimos 5 anos – 2014, 2015, 2016, 2017 e 2018. Todos os dados inseridos foram normalizados, ou seja, transformados em números entre 0 e 1 através da seguinte fórmula:

$$\text{Valor normalizado} = \frac{x_i - \min(x)}{\max(x) - \min(x)}$$

A Rede Neural criada é composta por 5 camadas de entrada, uma camada oculta e uma camada de saída. O algoritmo de aprendizagem usado foi o *backpropagation*, a análise de performance foi o Erro Quadrático Médio (EQM), a função de ativação foi a logística e a taxa de aprendizagem foi de 0,01.

A matriz de treinamento foi feita com a média de cada hora de todos os dias de cada mês. Dessa forma, ela possui 5 linhas (anos) e 24 colunas (horas). Os dados usados foram divididos em duas formas, 70% deles foram usados para o treinamento da



Rede e os 30% restantes foram usados para a validação dos resultados obtidos com o objetivo de quantificar o poder de generalização da RNA.

RESULTADOS E DISCUSSÃO

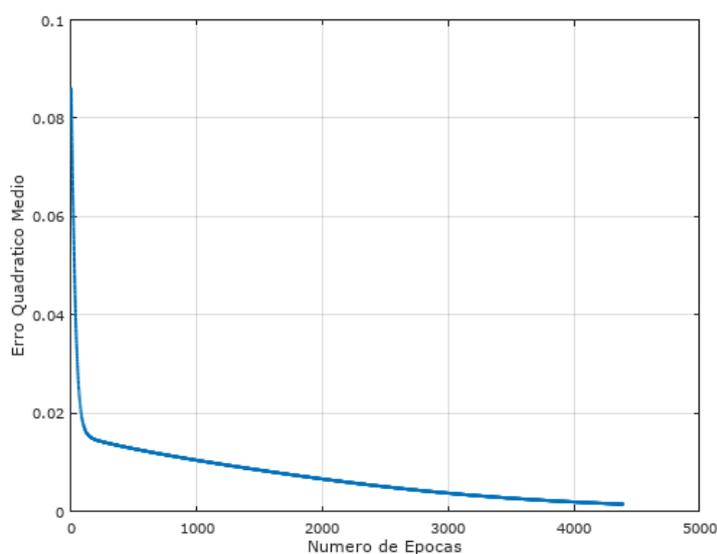
Após a construção da Rede Neural Artificial e a realização de testes na mesma, obteve-se resultados satisfatórios.

Para o mês de janeiro, a rede convergiu com aproximadamente 4500 épocas e o seu erro quadrático médio (EQM) foi menor que 0,02. O EQM pode ser definido como uma forma de avaliar a defasagem entre um estimador e o verdadeiro valor da quantia estimada.

Para compreender melhor o conceito de época, Barros (2019, p. 37) afirma que época é a

“[...] etapa de processamento em que todos os dados disponíveis para treinamento são apresentados para a rede. No final da apresentação de todos os dados a rede, ou seja, ao término de uma época, estes dados são embaralhados e reapresentados a rede, caracterizando uma nova época de treinamento.”

Figura 1: Gráfico da convergência da RNA no mês de janeiro.



Fonte: Autor (2019).



III SEMANA DA ENGENHARIA DE ENERGIAS

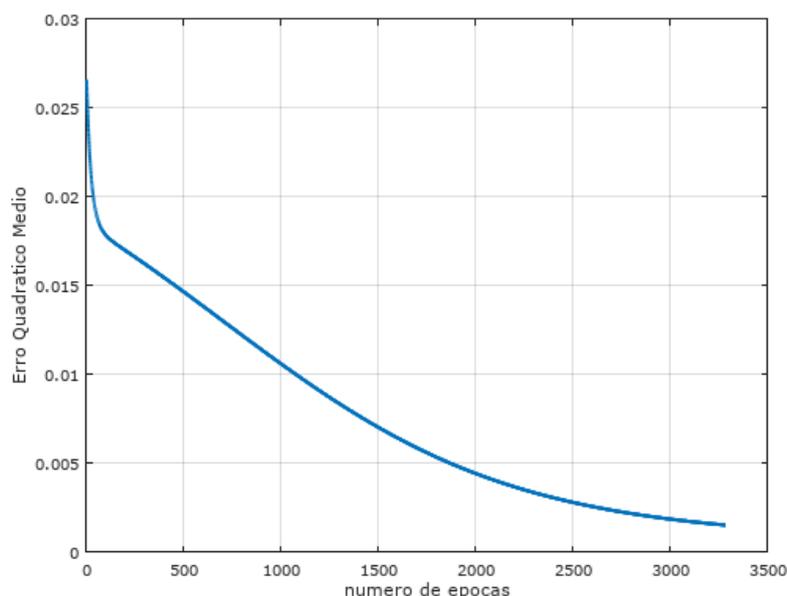
Energia Limpa e Acessível:

Estratégias de Inovação e Sustentabilidade

Para o mês de fevereiro, a rede convergiu com aproximadamente 2800 épocas e o seu EQM foi menor que 0,02. Para o mês de março, convergência da rede ocorreu com aproximadamente 3250 épocas e o seu EQM também foi menor que 0,02. Por fim, os resultados da previsão para o mês de abril também foram bons, pois a rede convergiu com aproximadamente 5700 épocas e o seu EQM foi pouco maior que 0,02.

É possível analisar, através das figuras que o número de épocas necessárias para a convergência da RNA é bem elevado. Isso ocorre devido a pequena quantidade de dados utilizados.

Figura 2: Gráfico da convergência da RNA no mês de março.



Fonte: Autor, 2019.

Em média, o Erro Quadrático Médio para os quatros meses calculados foi de 0,02. Esse número é muito baixo e significa que o valor da demanda previsto pela RNA foi extremamente próximo do valor real obtido pela distribuidora de energia elétrica a qual os dados foram retirados.

CONCLUSÃO

Após a realização dos testes com o algoritmo da Rede Neural, foi possível concluir que a sua utilização é muito eficaz, pois a diferença entre o valor real e o obtido



III SEMANA DA ENGENHARIA DE ENERGIAS

Energia Limpa e Acessível:

Estratégias de Inovação e Sustentabilidade

é muito pequena. Dessa forma, os dados fornecidos pela RNA podem ser usados seguramente para avaliar questões futuras que envolvam saber a demanda elétrica de um determinado local.

Portanto, o método utilizado neste trabalho realizou o objetivo proposto e demonstrou ser tão eficiente quanto outros métodos utilizados também para prever as cargas elétricas de um lugar.

AGRADECIMENTOS

Primeiramente, agradeço a Deus por ter me dado tantas oportunidades. Ao meu orientador, professor Alisson Guimarães, pela sua ajuda durante o processo de desenvolvimento da pesquisa. A professora Janaína Almada por contribuir com os seus conhecimentos. Ao Programa Institucional de Bolsa de Iniciação Científica – PIBIC – por me dar a incrível experiência que é ser uma pesquisadora. Ao meu namorado por me incentivar a vencer todos os meus desafios e aos meus pais que sempre me motivaram e apoiaram meus estudos.

REFERÊNCIAS

OLIVEIRA, André Luis Barros de. **Modelo neural para predição de demanda elétrica de curto prazo na região metropolitana da cidade de Fortaleza - CE**. 2019. 86 f. TCC (Graduação) - Curso de Engenharia de Energias, Universidade da Integração Internacional da Lusofonia Afro-brasileira, Redenção, 2019.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

Southern Califórnia Edison. Disponível em: <<https://www.sce.com/regulatory/load-profiles>> Acesso em: 14 de maio de 2019