

# **PREDIÇÃO DE DEMANDA DE ENERGIA PARA CURTO PRAZO DE UM SISTEMA FOTOVOLTAICO DE MINIGERAÇÃO INSTALADO NO CAMPUS DAS AURORAS (UNILAB-CEARÁ)**

**Marília Facundo Santana** (Unilab) - marilia\_facundo@hotmail.com

**Antonio Alisson Pessoa Guimarães** (UNILAB) - alisson@unilab.edu.br

## **Resumo:**

*Há pouco, a minigeração de energia elétrica em instituições públicas de ensino superior era um desafio devido aos entraves em se aprovar regras de implantação de projetos prioritários relacionados à eficiência energética e minigeração. Entretanto, com o propósito em inserir tais instituições nas questões de responsabilidade social, sustentabilidade, pesquisa e desenvolvimento, a Agência Nacional de Energia Elétrica (Aneel), a partir de Chamada Pública, lançou um conjunto de diretrizes para estimular a geração própria de energia nas Universidades e, assim, reduzir gastos com energia elétrica. Nesse contexto, a Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB) foi contemplada com recursos do Programa de Eficiência Energética (PEE), tendo como um dos benefícios, a instalação de uma usina fotovoltaica no Campus das Auroras. Diante da relevância em priorizar estratégias de eficiência energética em minimizar gastos com energia elétrica na UNILAB, este trabalho tem como objetivo prever, em curto prazo, a demanda de energia elétrica ao sistema fotovoltaico, por intermédio de algoritmo de inteligência computacional. Especificamente, propõe-se desenvolver uma Rede Neural Artificial (RNA) do tipo feedforward multicamadas com estrutura originada de modelo não linear e autoregressivo (NAR), no intuito de estimar demanda média dos 7 primeiros dias úteis do mês de setembro/2019, tendo como banco de dados para entrada da rede, as medições de demanda dos dias úteis de agosto/2019, para os períodos horários: 08:05h à 10:05h e 10:20h à 12:20h. Por fim, também vislumbra-se como contribuição deste trabalho, com as demandas médias geradas pela rede para um horizonte de curto prazo, fornecer aos setores administrativos da UNILAB, uma ferramenta computacional de auxílio às tomadas de decisão em termos de redução de gastos de energia elétrica, identificar a existência de módulos danificados e acompanhar, ao longo do tempo, a eficiência do sistema fotovoltaico, dentre outras.*

**Palavras-chave:** *Redes Neurais Artificiais; Previsão de Demanda; Energia Solar.*

**Área temática:** *Mercado, economia, política e aspectos sociais*

**Subárea temática:** *Impactos sociais, econômicos e ambientais de energias renováveis*

# PREDIÇÃO DE DEMANDA DE ENERGIA PARA CURTO PRAZO DE UM SISTEMA FOTOVOLTAICO DE MINIGERAÇÃO INSTALADO NO CAMPUS DAS AURORAS (UNILAB-CEARÁ)

**Marília Facundo Santana** – marilia\_facundo@hotmail.com

**Antônio Alisson Pessoa Guimarães** – alisson@unilab.edu.br

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB),  
Instituto de Engenharias e Desenvolvimento Sustentável (IEDS), Curso de Engenharia de Energias

**Resumo.** Há pouco, a minigeração de energia elétrica em instituições públicas de ensino superior era um desafio devido aos entraves em se aprovar regras de implantação de projetos prioritários relacionados à eficiência energética e minigeração. Entretanto, com o propósito em inserir tais instituições nas questões de responsabilidade social, sustentabilidade, pesquisa e desenvolvimento, a Agência Nacional de Energia Elétrica (Aneel), a partir de Chamada Pública, lançou um conjunto de diretrizes para estimular a geração própria de energia nas Universidades e, assim, reduzir gastos com energia elétrica. Nesse contexto, a Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB) foi contemplada com recursos do Programa de Eficiência Energética (PEE), tendo como um dos benefícios, a instalação de uma usina fotovoltaica no Campus das Auroras. Diante da relevância em priorizar estratégias de eficiência energética em minimizar gastos com energia elétrica na UNILAB, este trabalho tem como objetivo prever, em curto prazo, a demanda de energia elétrica ao sistema fotovoltaico, por intermédio de algoritmo de inteligência computacional. Especificamente, propõe-se desenvolver uma Rede Neural Artificial (RNA) do tipo feedforward multicamadas com estrutura originada de modelo não linear e autoregressivo (NAR), no intuito de estimar demanda média dos 7 primeiros dias úteis do mês de setembro/2019, tendo como banco de dados para entrada da rede, as medições de demanda dos dias úteis de agosto/2019, para os períodos horários: 08:05h à 10:05h e 10:20h à 12:20h. Por fim, também vislumbra-se como contribuição deste trabalho, com as demandas médias geradas pela rede para um horizonte de curto prazo, fornecer aos setores administrativos da UNILAB, uma ferramenta computacional de auxílio às tomadas de decisão em termos de redução de gastos de energia elétrica, identificar a existência de módulos danificados e acompanhar, ao longo do tempo, a eficiência do sistema fotovoltaico, dentre outras.

**Palavras-chave:** Redes Neurais Artificiais, Previsão de Demanda, Energia Solar.

## 1. INTRODUÇÃO

Nos últimos anos, a Agência Nacional de Energia Elétrica (Aneel) vem constatando que o dispêndio de energia elétrica, em instituições públicas de ensino superior, reflete como um de seus principais itens de custeio e, tal afirmação é reforçada pela Secretaria de Ensino Superior (SESu) do Ministério da Educação, da qual sinaliza que as despesas de energia elétrica nas Universidades Federais representam o terceiro maior gasto, correspondendo a, aproximadamente, 9% dos gastos contabilizados no ano de 2015 (Aneel, 2016a). Contudo, com mudanças de hábitos, aplicação de políticas de sustentabilidade e de eficiência energética, tais gastos poderiam ser minimizados.

Aliado aos esforços do Governo Federal em reduzir as despesas de energia elétrica em instituições públicas de ensino superior, a Aneel promoveu em 2016 uma chamada pública para seleção de projetos de Eficiência Energética e de Pesquisa e Desenvolvimento (P&D), com o intuito de incentivar a geração própria de energia (minigeração) e desenvolver conhecimento técnico sobre o tema, por intermédio de projetos pilotos em Universidades Federais. O Edital de seleção em questão foi denominado de *Chamada N.º. 001/2016 Projeto Prioritário de Eficiência Energética e Estratégico de P&D: “Eficiência Energética e Minigeração em Instituições Públicas de Educação Superior”* (Aneel, 2016b).

Segundo Aneel (2017), em atendimento à Chamada, foram submetidas 27 propostas por 15 empresas do setor elétrico, totalizando cerca de R\$ 307 milhões e beneficiando 44 Instituições Públicas de Ensino Superior em todas as regiões do País, dentre as quais a Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB), localizada na região do Maciço de Baturité (estado do Ceará), em parceria com a Enel Distribuição Ceará. Nesses termos, o projeto desenvolvido na UNILAB visa estimular a comunidade acadêmica em reduzir a conta de energia; substituição, nos *Campi*, de equipamentos mais velhos e menos eficientes por novos; instalação de uma Usina Solar no Campus das Auroras no município de Redenção-Ceará, dentre outros.

Atualmente, foram trocadas 4.950 lâmpadas velhas por lâmpadas LEDs que são os modelos mais econômicos do mercado atual, o que garante uma economia de 188 MW/ano. Também foram instalados 762 painéis fotovoltaicos com uma potência de 247,5 kWp, além de também ter sido montada uma "árvore solar" (estrutura metálica no formato de uma árvore que tem o intuito de deixar o projeto executado mais visível) de 11 metros de altura, composta por 10

módulos fotovoltaicos que possuem a potência instalada de 2,75 kWp. Devido à usina e a troca de equipamentos, a UNILAB pode economizar 640 MW/ano (UNILAB, 2019).

Diante do projeto a qual a Universidade foi contemplada, os grupos internos de pesquisa passaram a ter a oportunidade de transformar a usina em uma fonte de estudo com foco em questões de eficiência energética. Portanto, no contexto da relevância em reduzir despesas de energia elétrica em instituições públicas de ensino superior, este trabalho tem como objetivo prever, em curto prazo, a demanda de energia elétrica da usina fotovoltaica da UNILAB, com suporte da ferramenta computacional de Inteligência Artificial, intitulada de Redes Neurais Artificiais (RNA's), a qual tem resultados satisfatórios em problemas previsão descritos em séries temporais (Machado, 2015; Pinheiro, Lovato e Ruther, 2017).

Com um pouco mais detalhes, propõe-se desenvolver uma RNA do tipo não linear e autorregressiva para prever a demanda média de energia relacionado ao sistema fotovoltaico de minigeração, num horizonte dos 7 primeiros dias úteis do mês de setembro/2019, a partir das amostras de dados dos dias úteis do mês anterior. Além disso, a validação do modelo, em termos do processo de treinamento, se restringirá à análise do erro quadrático médio, o qual está relacionada com valores de entrada e saída da rede.

Em conclusão, vislumbra-se como contribuições relevantes desta obra, fornecer uma ferramenta computacional de auxílio às tomadas de decisão na UNILAB, para um horizonte de curto prazo, visando a otimização de recursos e a redução de gastos com energia elétrica. Além disso, identificar a existência de módulos danificados e acompanhar, ao longo do tempo, a eficiência do sistema fotovoltaico, dentre outras.

## 2. REDES NEURAS ARTIFICIAIS

A previsão de séries temporais requer, a partir de observações num dado período, a construção de modelos adequados ao problema em questão. Normalmente, adota-se ferramentas estatísticas para o tratamento de séries estacionárias e não estacionárias, tais como: processos auto-regressivos, processos estocásticos, médias móveis, ergodicidade, dentre outras (Bueno, 2011). Alternativamente, tal previsão pode ser estabelecida por Redes Neurais Artificiais, cuja técnica permite a previsão de resultados futuros sem um entendimento profundo do comportamento estatístico das séries (Haykin, 1999).

No presente trabalho, escolheu-se uma rede perceptron multicamadas (PMC) de arquitetura *feedforward*, processo de aprendizagem caracterizado pelo algoritmo *backpropagation* e com arranjo topológico originário do modelo Autorregressivo (AR) (Silva, Spatti e Flauzino, 2010). Tal arranjo permite prever valores, para um determinado instante de tempo de  $t$ , em termos do conhecimento de valores passados da série temporal. Noutros termos, a saída consiste no valor subsequente de uma sequência de amostras passadas, cujo modelo AR de mapeamento entrada/saída é dado por:

$$y(t) = \Phi(x(t-1), x(t-2), \dots, x(t-n_p)), \quad (1)$$

em que,  $y(t)$  representa a saída do modelo no instante de tempo  $t$ , a sequência  $x(t-1), x(t-2), \dots, x(t-n_p)$  indica os valores de entrada em instantes passados, a constante temporal  $n_p$  representa a ordem do preditor, isto é, a quantidade de medidas passadas para prever o termo seguinte da série  $x(t)$  e, por fim,  $\Phi(\cdot)$  é a função, geralmente não-linear, de mapeamento entrada/saída. Por vezes,  $y(t)$  e  $x(t)$  são denominados, respectivamente, de saída obtida pelo mapeamento e saída de desejada no instante de tempo  $t$ , e o erro de aproximação instantâneo é dado por

$$e(t) = y(t) - x(t), \quad n_p + 1 \leq t \leq N, \quad (2)$$

sendo  $N$  a quantidade total de amostras coletadas ao longo do tempo.

Em termos da topologia de uma RNA não linear autorregressiva (NAR), a camada de entrada é descrita por  $n_p$  amostras sequencialmente atrasadas no tempo e a camada de saída produzirá a resposta do sistema  $y(t)$  que predirá o valor esperado para  $x(t)$ . Na Figura 1 é ilustrada uma rede neural com uma camada oculta (podendo ter múltiplas camadas ocultas) e com inclusão de uma polarização ou bias de entrada, cujo parâmetro corresponde a um maior grau de liberdade ao processo de minimização ou ajustes dos pesos sinápticos.

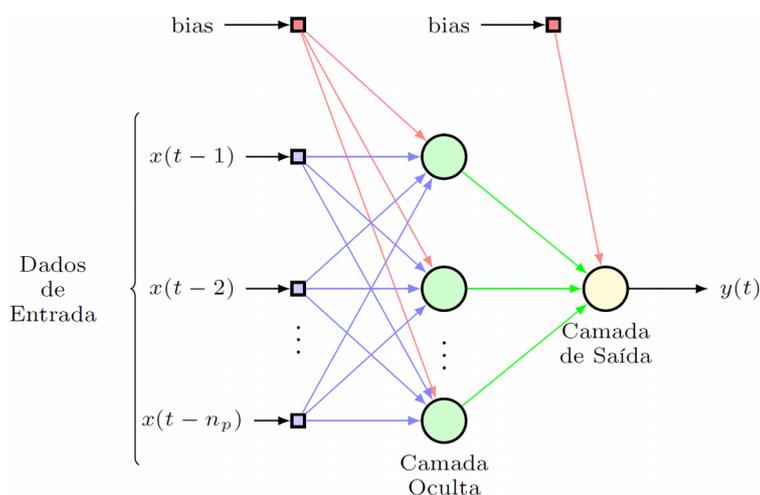


Figura 1 – Descrição de uma RNA não linear autorregressiva.

Com mais detalhes, para cada instante de tempo discreto  $t$ , pertencente ao intervalo  $[n_p + 1, N]$ , o algoritmo de treinamento desse tipo de rede necessita que seja fornecida  $n_p$  amostras como entradas, sendo valores sucessivos da série histórica e o processo de aprendizagem ajustará os pesos a partir da resposta do sistema  $y(t)$  que buscará prever o termo subsequente da série, no caso,  $x(t)$ . Após a fase de predição das amostras autênticas da série, a RNA inicia, propriamente, a predição de valores futuros para  $n$  passos à frente.

Para melhor entendimento do processo, toma-se por exemplo, um modelo com cinco amostras  $x(1), x(2), x(3), x(4), x(5)$  ( $N = 5$ ) e ordem de preditor  $n_p = 2$ . Assim, durante a fase de treinamento, inicia-se com  $t = n_p + 1 = 3$  e com entradas à rede  $x(2)$  e  $x(1)$ , para prever a amostra da série  $x(3)$ . Em seguida, incrementa-se o parâmetro  $t$  em uma unidade, isto é, faz-se  $t = 4$ . Assim, são geradas as entradas  $x(3)$  e  $x(2)$  para prever o valor de  $x(4)$  e, por fim, para concluir a primeira época do treinamento do algoritmo, toma-se  $t = 5$  para estimar o valor  $x(5)$  da amostra da série temporal. A Tabela 1 resume, para uma época, o processo de treinamento da RNA Autoregressiva proposta.

Tabela 1 – Processo de treinamento de uma NAR para uma série de cinco amostras com  $n_p = 2$ .

| Tempo ( $t$ ) | Entradas à rede | Saída desejada | Saída obtida | Erro instantâneo, $e(t)$ |
|---------------|-----------------|----------------|--------------|--------------------------|
| 3             | $x(2), x(1)$    | $x(3)$         | $y(3)$       | $y(3) - x(3)$            |
| 4             | $x(3), x(2)$    | $x(4)$         | $y(4)$       | $y(4) - x(4)$            |
| 5             | $x(4), x(3)$    | $x(5)$         | $y(5)$       | $y(5) - x(5)$            |

Após obter-se, devidamente, a rede treinada, testada e validada, define-se a quantidade de passos à frente para estimação de valores futuros. Retornando, pois, ao exemplo anterior, e considerando a previsão de três passos à frente, a RNA terá a função de prever os valores de  $x(6), x(7)$  e  $x(8)$ , conforme explicitado na Tabela 2.

Tabela 2 – Processo de treinamento de uma NAR para uma série de cinco amostras com  $n_p = 2$ .

| Tempo ( $t$ ) | Entradas     | Saída estimada |
|---------------|--------------|----------------|
| 6             | $x(5), x(4)$ | $x(6)$         |
| 7             | $x(6), x(5)$ | $x(7)$         |
| 8             | $x(7), x(6)$ | $x(8)$         |

Nota-se, portanto, que o primeiro valor estimado é obtido a partir das amostras da série histórica e, os valores futuros subsequentes são obtidos das saídas estimadas geradas pela própria rede, o que induz um acúmulo natural de erros de estimação para as outras amostras na sequência.

### 3. METODOLOGIA

Esta seção está dedicada aos procedimentos metodológicos destinados à projeção de demanda elétrica ao sistema fotovoltaico instalado na UNILAB. Tais procedimentos estão sequencialmente elencados e serão detalhados no decorrer da seção:

- (a) coleta e pré-processamento dos dados;
- (b) definição e estruturação da RNA;
- (c) treinamento do modelo.

### 3.1 Coleta e pré-processamento dos dados

A usina fotovoltaica da UNILAB foi instalada em meados de janeiro de 2019, nesse sentido, não se tem ainda um registro significativo no banco de dados gerado pelo sistema. Diante da problemática, optou-se por estruturar uma RNA do tipo AR, a partir dos dados coletados de geração de energia elétrica para os dias úteis mês de agosto de 2019, tomando-se como referência dois intervalos de duas horas do turno da manhã, objetivando-se, portanto, a predição de demanda para os sete primeiros dias úteis de setembro/2019, segundo os intervalos pré-determinados. Os perfis de demanda para sábados, domingos e feriados não foram levados em consideração em virtude da Universidade não apresentar o mesmo volume de atividades curriculares em dias não letivos.

Especificamente, os dados foram coletados a cada 15 minutos durante os dias de agosto/2019 e tais medições foram particionadas em dois períodos horários: de 08:05h à 10:05h e de 10:20h às 12:20h. Na sequência, considerou-se a média de demanda de energia elétrica para cada intervalo dos 21 dias úteis do mês, cujos valores estão discriminados na Tabela 3.

Tabela 3 – Dados históricos de demanda de 21 dias úteis de agosto/2019 para os períodos de 08:05h à 10:05h e de 10:20h às 12:20h.

| Dia útil | Demanda (kWh)         | Demanda (kWh)         | Dia útil | Demanda (kWh)         | Demanda (kWh)         |
|----------|-----------------------|-----------------------|----------|-----------------------|-----------------------|
|          | (08 : 05h – 10 : 05h) | (10 : 20h – 12 : 20h) |          | (08 : 05h – 10 : 05h) | (10 : 20h – 12 : 20h) |
| 1        | 81,70                 | 100,08                | 12       | 59,67                 | 89,58                 |
| 2        | 99,06                 | 100,00                | 13       | 80,86                 | 262,53                |
| 3        | 137,36                | 155,21                | 14       | 80,33                 | 110,52                |
| 4        | 82,32                 | 84,04                 | 15       | 98,50                 | 121,88                |
| 5        | 70,30                 | 92,11                 | 16       | 84,56                 | 112,11                |
| 6        | 80,79                 | 138,07                | 17       | 74,11                 | 126,43                |
| 7        | 115,46                | 84,08                 | 18       | 100,82                | 116,38                |
| 8        | 125,08                | 116,43                | 19       | 102,80                | 143,61                |
| 9        | 91,89                 | 116,68                | 20       | 138,61                | 146,11                |
| 10       | 55,68                 | 65,53                 | 21       | 106,61                | 152,81                |
| 11       | 79,28                 | 100,60                | –        | –                     | –                     |

Para a inserção da base de dados na rede, e para adequar-se com a função de ativação que produzirá a saída do sistema, as demandas foram normalizadas para valores compreendidos entre 0 e 1, segundo o critério de normalização (Silva, Spatti e Flauzino, 2010):

$$x_{\text{normalizado}} = \frac{x - \min \{x\}}{\max \{x\} - \min \{x\}} \quad (3)$$

em que,  $x$  representa o vetor de dados de entrada da RNA, o termo  $x$  é uma componente de tal vetor que indica um determinado valor da série histórica que será normalizado para  $x_{\text{normalizado}}$  e, na sequência,  $\max \{x\}$  e  $\min \{x\}$  representam os valores máximo e mínimo, respectivamente, de demanda da série.

### 3.2 Definição e estruturação da RNA

A rede proposta neste trabalho é do tipo perceptron multicamadas (PMC) de arquitetura *feedforward*, processo de aprendizagem caracterizado pelo algoritmo *backpropagation* e com arranjo topológico originário do modelo não linear autorregressivo, conforme descrito na Seção 2, e a demanda prevista, que é caracterizada pela saída da rede, é avaliada em termos do Erro Quadrático Médio (EQM). Ainda em termos de topologia, adotou-se  $n_p = 10$  sendo a ordem do preditor, ou seja, serão dez variáveis normalizadas de entrada (amostras passadas) necessárias para prever um horizonte de 7 dias à frente. Os parâmetros complementares da implementação da RNA, estão descritos na Tabela 4.

Tabela 4 – Parâmetros complementares da RNA.

| Parâmetros                         | Descrição/Valores |
|------------------------------------|-------------------|
| Função de ativação                 | Função sigmóide   |
| Taxa de aprendizagem               | 0,1               |
| Nº de camadas ocultas              | 1                 |
| Nº de neurônios na camada oculta   | 5                 |
| Nº de neurônios na camada de saída | 1                 |
| Inclusão de bias à rede            | Sim               |
| Critério de parada                 | Análise do EQM    |

O algoritmo NAR foi, totalmente, desenvolvido pelos autores desta obra, com suporte do *software* livre GNU Octave, o qual é uma plataforma computacional de alta performance similar ao MATrix LABoratory (MATLAB) da MathWorks (GNU Octave, 2019). Nesse contexto, a construção da matriz de pesos da RNA, em sua primeira iteração, foi gerada aleatoriamente, a partir da distribuição uniforme e a atualização dos pesos, para cada época de treinamento, seguiu-se pela regra de retropropagação (algoritmo *backpropagation*).

### 3.3 Treinamento do modelo

Normalmente, os dados originalmente coletados são normalizados e particionados em três subconjuntos, com porcentagens pré-definidas pelo projetista, para atuarem nas fases de treinamento, validação e teste da rede (Silva, Peres e Boscaroli, 2016).

Com mais detalhes, na fase de treinamento a rede é alimentada utilizando-se em torno de 70% do total de amostras do conjunto de dados e, nessa fase os pesos das conexões serão ajustados até que a taxa de erro for suficientemente pequena, ou seja, quando for menor que um erro admissível, assim o processo de treinamento é interrompido. Na fase de validação, a qual é destinada para o desempenho da rede, há um segundo treinamento, porém com um conjunto menos denso de amostras, no caso na proporção de 15%. Após a rede passar pelas fases de treinamento e validação, os dados que não foram previamente utilizados (15% do total) são inseridos à rede, com a matriz de pesos obtida na fase de treinamento, para confirmar a capacidade de generalização da rede. Caso seja verificado, em cada fase, a eficiência da rede quanto a sua capacidade de generalização, tal modelo é então integrado ao sistema computacional da aplicação (Lima, Pinheira e Santos, 2014).

Contudo, a escolha para tais porcentagens não são fixas e dependerá do volume de dados disponíveis. Em virtude disso, como série temporal apresentada na Tabela 3 possui apenas 21 amostras, devido à usina fotovoltaica da UNILAB ter sido recentemente instalada, ficaria inviável particionar a série em conjuntos de dados muito pequenos, principalmente, para serem aplicados nas fases de validação e teste. Optou-se, portanto, por implementar uma RNA para executar apenas a fase de treinamento, com análise de desempenho mediante o critério do EQM.

## 4. RESULTADOS E DISCUSSÕES

Como previamente comentado, o modelo de rede do tipo NAR proposto tem por objetivo prever a demanda média de energia elétrica com horizonte dos 7 primeiros dias úteis referente ao mês de setembro/2019, para intervalos de 2 horas com observações nos períodos 08:05h – 10:05h e 10:20h – 12:20h dos dias úteis de agosto/2019. Ademais, utilizou-se como critério de comparação dos dados de saída da rede em relação as amostras da série histórica, o erro quadrático médio. Contudo, para uma melhor apresentação dos resultados, os referidos períodos serão analisados separadamente.

### 4.1 Estimação de demanda para o primeiro período de observação

A Figura 2 apresenta o comportamento da curva do EQM em termos do número de épocas de treinamento, ou seja, em termos da quantidade de vezes que as amostras do conjunto de treinamento são inseridas à rede para ajustar a matriz de pesos.

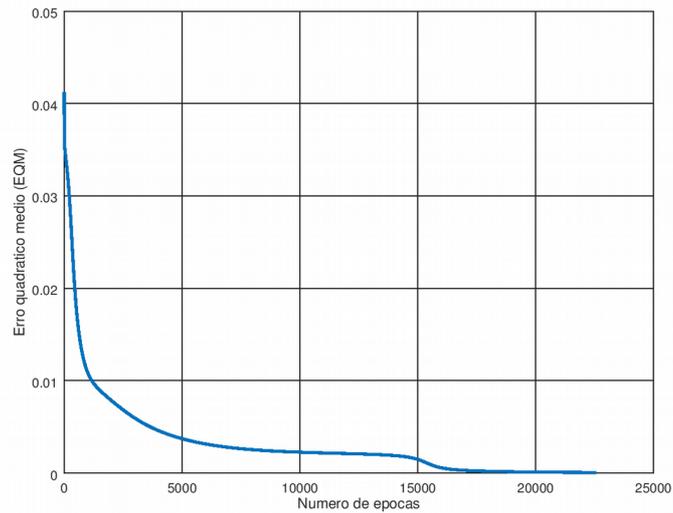


Figura 2 – Comportamento do EQM em função do número de épocas de treinamento (primeiro período de observação).

Observa-se um acentuado decrescimento da curva a medida que o número de épocas são incrementadas, estabilizando-se num EQM praticamente nulo, sinalizando que os valores gerados na saída da rede são muito próximos dos valores desejados e, tal afirmação é confirmada na Figura 3, a qual ilustra o resultado do treinamento da rede.

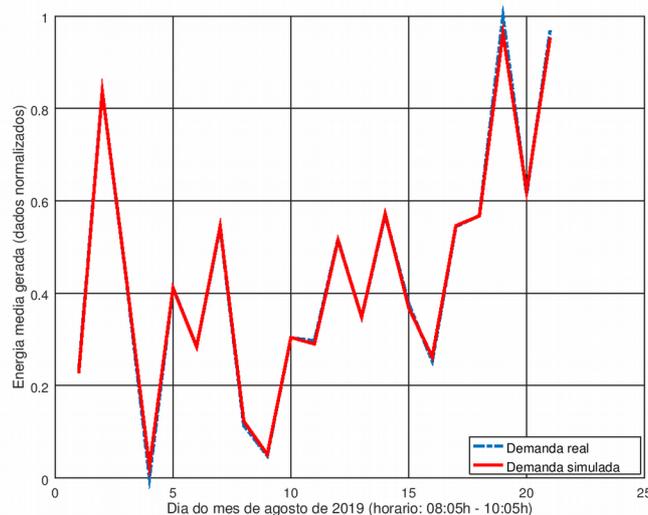


Figura 3 – Resultado do treinamento da rede para o período de observação 08:05h – 10:05h.

O treinamento da RNA evidencia o quão próximos são os valores reais e simulados de demanda média para os dias 21 dias úteis do mês de agosto de 2019. Além disso, tal processo de aprendizagem foi capaz de aprender o comportamento temporal da série histórica, a partir dos parâmetros escolhidos para a execução da rede neural autorregressiva.

Na sequência, a Figura 4 ilustra o resultado num horizonte de previsão de 7 passos à frente que corresponde aos 7 primeiros dias úteis de setembro/2019 para o período de 08:05h à 10:05h, com dados de demandas desnormalizados, cuja expressão de desnormalização é resultante da Equação 3, a qual é dada por:

$$x_{desnormalizado} = y \cdot [\max \{x\} - \min \{x\}] + \min \{x\}, \quad (4)$$

sendo,  $y$  a saída produzida pela rede, cujo valor fica limitado ao intervalo  $[0, 1]$  devido a função de ativação sigmóide escolhida no modelo de RNA proposto.

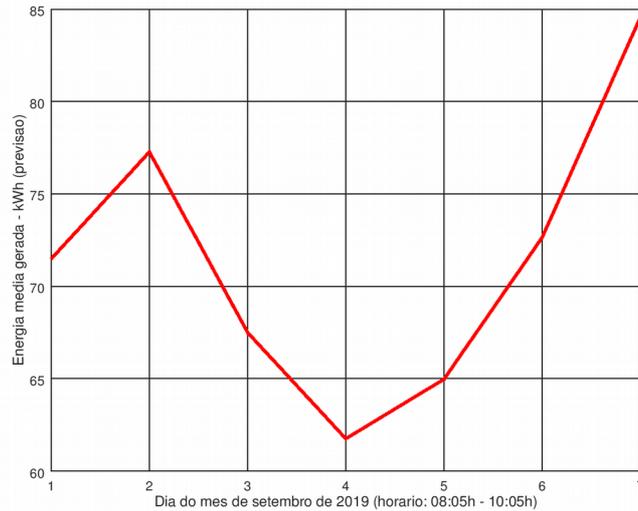


Figura 4 – Previsão de demanda média para o período de observação 08:05h – 10:05h (mês de setembro).

Como a base de dados possui 21 amostras, os resultados de previsão podem não ser tão precisos, porém são suficientes para estimar o comportamento futuro do sistema em questão.

#### 4.2 Estimação de demanda para o segundo período de observação

Similarmente ao apresentado no primeiro período de observação, serão analisados a convergência do EQM, o resultado do treinamento da RNA e, por fim, a predição de demanda de 7 passos à frente, adotando-se os mesmos parâmetros de rede já estabelecidos.

Como esperado, a curva do erro quadrático médio decresce a cada iteração do número de épocas e tende a um valor suficientemente pequeno ao final do processo de aprendizagem da rede, conforme esboçado na Figura 5.

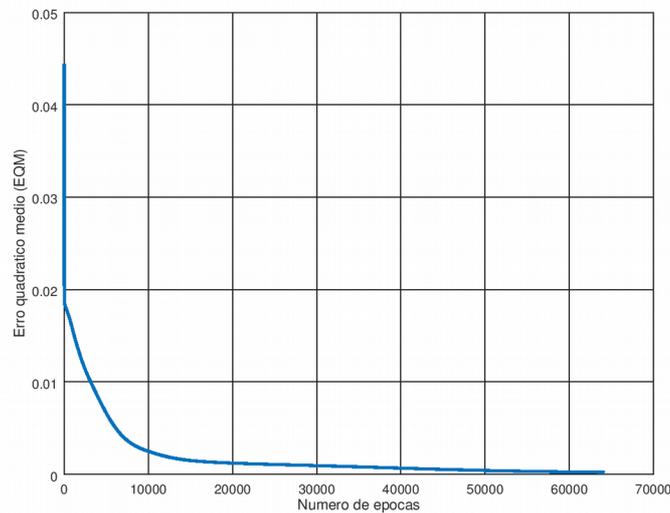


Figura 5 – Comportamento do EQM em função do número de épocas de treinamento (segundo período de observação).

A Figura 6 apresenta o comparativo das curvas de demanda entre os valores resultantes do treinamento do modelo NAR com as amostras da série de dados, para o período de 10:20h à 12:20h.

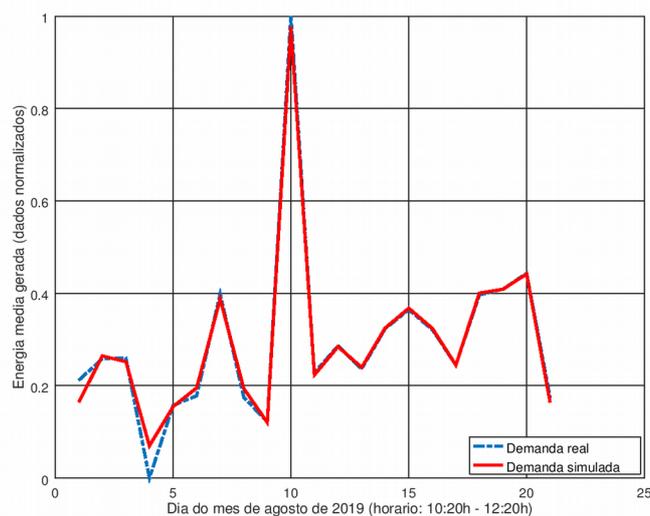


Figura 6 – Resultado do treinamento da rede para o período de observação 10:20h – 12:20h.

Embora o padrão de demanda do segundo período de observação exibir um comportamento distinto do primeiro, a rede mostrou-se, novamente, muito eficiente no processo de aprendizagem e capacidade de generalização, pois classificou corretamente, em quase sua totalidade, os padrões apresentados.

Por fim, com dados desnormalizados, a previsão de demanda média no horizonte dos 7 primeiros dias úteis de setembro/2019, para o período de 08:20h – 10:20h, é ilustrada na Figura 7.

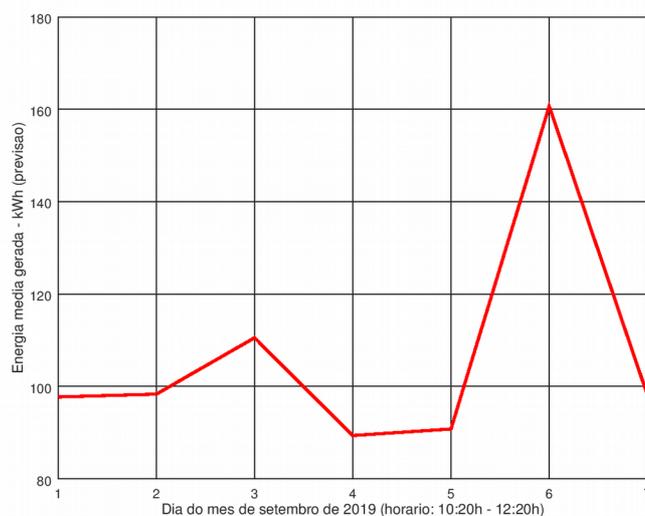


Figura 7 – Previsão de demanda média para o período de observação 10:20h – 12:20h (mês de setembro).

Como esperado, o comportamento da curva de predição de demanda obtido está relacionado aos padrões do período horário de observação, tendo, portanto, perfil diferenciado do intervalo 08:05h – 10:05h.

## 5. CONSIDERAÇÕES FINAIS

Este trabalho concentrou-se em desenvolver uma metodologia de projeção de demanda média de energia elétrica, num horizonte de curto prazo, tendo como objeto de estudo a usina fotovoltaica de minigeração instalada no Campus das Auroras, localizada no município de Redenção-Ceará, da Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB). Diante da base de dados disponível, referente as demandas do mês de agosto de 2019 para os períodos de 08:05h à 10:05h e 10:20h à 12:20h, implementou-se, com sucesso, uma rede neural artificial do tipo não linear autorregressiva, garantindo-se portanto, que amostras anteriores refletissem o comportamento temporal da série histórica. Especificamente, o modelo proposto previu, satisfatoriamente, a demanda média de curto prazo para os

primeiros 7 dias úteis de setembro, referente a cada período de observação e, tal modelo foi validado pelos excelentes resultados no processo de aprendizagem e pela obtenção de erros quadráticos médios quase nulos, mesmo para uma pequena quantidade de amostras na série temporal. Como perspectiva de estudo futuro, pretende-se estimar demanda de energia elétrica ao sítio fotovoltaico da UNILAB, em função da rede de modelagem de série temporal denominada de *não linear autoregressiva com entradas exógenas* (NARX), com a instalação de uma estação solarimétrica, a qual ficará integrada ao sistema fotovoltaico.

### Agradecimentos

Os autores ao Programa Institucional de Bolsas de Iniciação Científica (PIBIC) vinculado à Pró-Reitoria de Pesquisa e Pós-Graduação (PROPPG) da UNILAB, a Professora Janaína Barbosa Almada (IEDS/UNILAB) e a todos que disponibilizaram informações para a realização do trabalho.

### REFERÊNCIAS

- Agência Nacional de Energias Elétrica (Aneel), 2016. P&D e Eficiência Energética. Disponível em: <[https://www.aneel.gov.br/sala-de-imprensa-exibicao/-/asset\\_publisher/XGPXSqdMFHrE/content/projeto-prioritario-incentiva-acoas-de-eficiencia-energetica-nas-instituicoes-publicas-de-educacao-superior/656877?inheritRedirect=false](https://www.aneel.gov.br/sala-de-imprensa-exibicao/-/asset_publisher/XGPXSqdMFHrE/content/projeto-prioritario-incentiva-acoas-de-eficiencia-energetica-nas-instituicoes-publicas-de-educacao-superior/656877?inheritRedirect=false)>. Acesso em: 01 de dez. De 2019.
- Agência Nacional de Energias Elétrica (Aneel), 2016. Chamada Nº. 001/2016 Projeto Prioritário de Eficiência Energética e Estratégico de P&D: “Eficiência Energética e Minigeração em Instituições Públicas de Educação Superior”. Disponível em: <<https://www.aneel.gov.br/documents/656831/14930433/Prioritario+e+Estrategico+%28Edital+final%29/7817f2ab-0f65-42b8-b8d4-e91a2b61239f>>. Acesso em: 01 de dez. De 2019.
- Agência Nacional de Energias Elétrica (Aneel), 2017. ANEEL avalia 27 projetos de eficiência energética e minigeração em instituições de ensino superior. Disponível em: <[https://www.aneel.gov.br/sala-de-imprensa-exibicao-2/-/asset\\_publisher/zXQREz8EVIZ6/content/aneel-avalia-27-projetos-de-eficiencia-energetica-e-minigeracao-em-instituicoes-de-ensino-superior/656877/pop\\_up?\\_101\\_INSTANCE\\_zXQREz8EVIZ6\\_viewMode=print&\\_101\\_INSTANCE\\_zXQREz8EVIZ6\\_languageId=pt\\_BR](https://www.aneel.gov.br/sala-de-imprensa-exibicao-2/-/asset_publisher/zXQREz8EVIZ6/content/aneel-avalia-27-projetos-de-eficiencia-energetica-e-minigeracao-em-instituicoes-de-ensino-superior/656877/pop_up?_101_INSTANCE_zXQREz8EVIZ6_viewMode=print&_101_INSTANCE_zXQREz8EVIZ6_languageId=pt_BR)>. Acesso em: 01 de dez. De 2019.
- Bueno, R. L. S., 2011. Econometria de Séries Temporais, Cengage Learning.
- GNU Octave, 2019. GNU Octave: Scientific Programming Language. Disponível em: <<https://www.gnu.org/software/octave/>>. Acesso em: 29 de nov. de 2019.
- Haykin, S., 1999. Neural Networks: A comprehensive foundation, Prentice-Hall.
- Machado, L. M. G., 2015. Projeção de Demanda de Energia Elétrica a Curtíssimo Prazo Considerando a Inserção de Micro e Minigeração Fotovoltaica, Monografia de graduação, UFRGS, Porto Alegre.
- Lima, I., Pinheiro, C. A. M., Santos, F. A. O., 2014. Inteligência Artificial, Elsevier.
- Pinheiro, E., Lovato, A., Ruther, R., 2017. Aplicabilidade de Redes Neurais Artificiais para Análise de Geração de Energia de um Sistema Fotovoltaico Conectado a Rede Elétrica, Revista Brasileira de Energias Renováveis, v.6, n.5, p.875-892.
- Silva, I. N., Spatti, D. H., Flauzino, R. A., 2010. Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: fundamentos teóricos e aspectos práticos, Artliber Editora.
- UNILAB, 2019. Unilab e Enel efetivam Projeto de Eficiência e Minigeração Energética com inauguração da Árvore Solar Fotovoltaica, no Campus das Auroras. Disponível em: <<http://www.unilab.edu.br/noticias/2019/01/16/unilab-e-enel-efetivam-o-projeto-de-eficiencia-e-minigeracao-energetica-com-inauguracao-da-arvore-solar-fotovoltaica-no-campus-das-auroras/>>. Acesso em: 01 de dez. De 2019.

### PREDITION OF ENERGY DEMAND FOR A SHORT-TERM OF A PHOTOVOLTAIC SYSTEM OF MINIGENERATION INSTALLED IN AURORAS CAMPUS (UNILAB-CEARÁ)

**Abstract.** *Recently, the minigeneration of electricity in public institutions of higher education was a challenge due to the obstacles in approving rules for the implementation of priority projects related to energy efficiency and minigeneration. However, with the purpose of inserting such institutions in the issues of social responsibility, sustainability, research and development, the National Agency of Electric Energy (Aneel), from Public Call, launched a set of guidelines to stimulate the own generation of energy in Universities and thus reduce spending on electricity. In this context, the University of International Integration of Afro-Brazilian Lusophony (UNILAB) was contemplated with resources from the Energy Efficiency Program (PEE), having as one of the benefits, the installation of a photovoltaic plant in the Campus of Auroras. Given the importance of prioritizing energy efficiency strategies in minimizing expenditures with electrical energy in UNILAB, this work aims to predict, in the short term, the demand for electrical*

energy to the photovoltaic system, by means of computational intelligence algorithm. Specifically, it is proposed to develop an Artificial Neural Network (RNA) multi-layer feedforward type with structure originated from nonlinear and autoregressive model (NAR), in order to estimate the average demand of the first 7 working days of the month of September/2019, having as database for network input, the measurements of demand from working days of August/2019, for the time periods: 08:05h to 10:05h and 10:20h to 12:20h. Finally, it is also seen as a contribution of this work, with the average demands generated by the grid for a short term horizon, to provide the administrative sectors of UNILAB, a computational tool to aid decision making in terms of reducing electric energy costs, identify the existence of damaged modules and monitor, over time, the efficiency of the photovoltaic system, among others.

**Key words:** Artificial Neural Networks, Demand Forecasting, Solar Energy.