

Capítulo I – Aplicação de Redes Neurais Artificiais para a Gestão e Eficiência Energética em Sistemas Industriais e Comerciais

Bruno Pedroso de Toledo ¹

Layhon Roberto Rodrigues ²

Leonardo Yuji Ishizaki ³

RESUMO

Este trabalho investiga a gestão de energia e eficiência energética no Mercado Livre de Energia (MLE), com foco na aplicação de Redes Neurais Artificiais (RNA) para estimar o consumo energético (MWh) e otimizar a compra de energia, respeitando as normas vigentes. Especificamente, serão utilizadas Redes Perceptron Multicamadas (PMC) como aproximadoras de funções para prever padrões de consumo a partir de um banco de dados, permitindo projeções mais precisas. O estudo compara a abordagem baseada em RNA com um método tradicional de estimativa de demanda energética, visando demonstrar a capacidade das redes neurais de lidar com a volatilidade do Ambiente de Contratação Livre (ACL). O objetivo é consolidar um método eficiente para gerenciamento energético, minimizando custos operacionais e contribuindo para uma gestão mais sustentável e inteligente para empresas do Grupo Tarifário A.

Palavras-chave: Gestão de Energia, Eficiência Energética, Mercado Livre de Energia, Redes Neurais Artificiais, Perceptron Multicamadas.

Application of Artificial Neural Networks for Energy Management and Efficiency in Industrial and Commercial Systems

ABSTRACT

This study investigates energy management and energy efficiency in the Free Energy Market (MLE), focusing on the application of Artificial Neural Networks (ANNs) to estimate energy consumption (MWh) and optimize energy purchasing while complying with current regulations. Specifically, Multilayer Perceptron (MLP) Networks will be used as function approximators to predict consumption patterns based on a database, enabling more accurate projections. The study compares the ANN-based approach with a traditional energy demand estimation method, aiming to demonstrate the capability of neural networks to handle the volatility of the Free Contracting Environment (ACL). The goal is to establish an efficient energy management strategy, minimizing operational costs and contributing to a more sustainable and intelligent management for companies in the Group A Tariff category.

Keywords: Energy Management, Energy Efficiency, Free Energy Market, Artificial Neural Networks, Multilayer Perceptron.

¹ Engenheiro Eletricista. UniSenaiPR - Campus Londrina.

² Doutor em Engenharia Elétrica.

³ Mestre em Engenharia Elétrica.

1 INTRODUÇÃO

A crescente demanda pelo consumo de energia elétrica e a evolução da comercialização desse recurso vem ganhando atenção da indústria e pesquisadores, pois a dependência de energia elétrica se intensifica, impulsionada por uma diversidade de setores, dos mais diversos segmentos indústrias e residenciais. (HARRIS,2006).

O índice evolutivo de uma população segundo (KARDASHEV,1964) está diretamente relacionado a sua capacidade de aproveitar e controlar a energia disponível em seu ambiente. A capacidade de gerar e gerir este recurso, possui extrema relevância no âmbito comercial. Os apontamentos feitos pela Federação das Indústrias do Estado de Rio de Janeiro (FIRJAN, 2023) relatam que a energia elétrica é um insumo fundamental e estratégico sendo utilizado por 79% das empresas e chegando a representar mais de 40% de seus custos de produção.

Um relatório publicado pela Agência Internacional de Energia em (AIE, 2022), aponta que demanda global por eletricidade aumentou em 6% em 2021. Este aumento se sucederá ainda maior quando ambientalizamos o Mercado Livre de Energia (MLE), os quais podem realizar a compra de seu volume energético não só da companhia local concessionária, mas também de diversas outras comercializadoras, este assunto será abordado em mais detalhes na seção 1.3. Desde janeiro de 2023 através da Portaria nº465/2019 consumidores com consumo acima de 500kW já podem fazer parte do Ambiente de Contratação Livre (ACL), este fato que já possui grande impacto tende a aumentar ainda mais, uma vez que a Portaria nº50 que entrará em vigor a partir de 2024, permitirá que consumidores atendidos em Média Tensão (13.8kV) possam migrar ao ACL. Tal marco contribui verticalmente para o avanço da matriz energética e estratégias eficientes de gestão deste recurso, tanto para o meio social sustentável, quanto a estratégias de mercado e competitividade entre as empresas. (ENGIE,2020).

No contexto discutido anteriormente, de ambiente de contratação livre, de demanda energética, este trabalho visa implementar um estimador de demanda para otimizar a contratação de energia elétrica no mercado livre. Para isso, se implementa uma Rede Neural Artificial como uma aproximadora de funções, e esta, será treinada

de modo a interpretar o padrão de consumo sazonal para diversas áreas e estimar o volume energético demandado.

A seguir este trabalho está organizado da seguinte forma: a Seção 2 descreve a fundamentação teórica onde serão abordados aspectos relevantes da literatura que embasam este trabalho, como fundamentos de "Geração, Transmissão, Distribuição e Comercialização de Energia Elétrica" e fundamentos de Redes Neurais Artificiais (RNA), já na seção 3 será abordada a metodologia utilizada para implementação da RNA com foco em atingir os objetivos gerais e específicos citados na subseção 1.1 e 1.1.1. Na seção 4 e 4.1 serão apresentadas as conclusões e discussões de resultados, as métricas extraídas da metodologia implementada serão analisadas a partir do viés financeiro, por fim na seção 5 serão feitas considerações finais deste trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão discutidos aspectos relevantes da literatura que embasam este trabalho, na subseção 2.1 serão abordados fundamentos de "Geração, Transmissão, Distribuição e Comercialização de Energia Elétrica" com intuito de ambientar o cenário que motiva este estudo e, como este cenário possui vastas possibilidades de atuação dada sua complexidade e representatividade econômica global. Na subseção 2.2 será apresentado e contextualizado o ambiente de contratação regulada ACR. Na subseção 2.3 e 2.3.1 conduzirá uma análise sobre a dinâmica operacional do Ambiente de Contratação Livre (ACL). Serão abordados conceitos cruciais, tais como a atuação de órgãos reguladores e a legislação que dita as regras neste cenário. A compreensão desses elementos é fundamental para contextualizar as estratégias de implementação discutidas neste trabalho. Já na subseção 2.4 e 2.4.1 serão apresentadas funcionalismo das Redes Neurais Artificiais (RNA) de maneira a introduzir como estas ferramentas serão utilizados no desenvolvimento destes estudos. Nas subseções 2.4.1.1 até 2.4.1.3 são apresentados e discutidos os métodos de treinos que serão utilizados e comparados, nesta serão abordadas e discutidas as equações que modelam os treinos e como cada qual poderá contribuir para o desenvolvimento deste trabalho.

2.1 GERAÇÃO TRANSMISSÃO DISTRIBUIÇÃO E COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA.

A matriz energética possui diversos órgãos reguladores para sancionar leis e traçar as diretrizes no quesito comercialização e distribuição de energia, isto só foi possível graças ao inventor austríaco Nikola Tesla cientista o qual difundiu os conceitos da 'Alternate Currente' (AC), possibilitando assim os meios de transmissão de energia as quais utilizamos atualmente. (NIKOLA TESLA,2023).

Com o crescimento da matriz energética surgiram os órgãos regulatórios, como o “Conselho Nacional de Política Energética” (CNPE), “Ministério de Minas e Energia” (MME) “Agência Nacional de Energia Elétrica” (ANEEL), “Empresa de Pesquisa Energética” (EPE), “Comitê de Monitoramento do Setor Elétrico” (CMSE), Câmara de Comercialização de Energia Elétrica “(CCEE) “Operador Nacional do Sistema Elétrico” (ONS). Através da Figura 1 pode-se observar a configuração hierárquica destes órgãos.

Figura 1. Órgãos Regulamentadores Setor Elétrico Nacional.



Fonte:Falcão,2020.

Com o avanço do uso pelo sistema elétrico, foi-se criada uma segmentação em dois nichos, clientes do Grupo B (Baixa Tensão) descritos por unidades consumidoras que possuem demanda contratada abaixo de 75kW de representada por casas e pequenos comércios, para clientes com demanda contratada acima de 75kW são consideradas pertencentes ao Grupo A (Alta Tensão), isto é importante pois reflete leis e modelagem de tarifação diferentes para ambos que serão mais bem detalhadas nas subseções 1.3 e 1.4.

2.2 AMBIENTE DE CONTRATAÇÃO REGULADA (ACR).

O ambiente de contratação regulada (ACR) ou mercado cativo de energia elétrica é um modelo tradicional de comercialização no setor elétrico, em que os consumidores (Grupo B – Baixa Tensão) são atendidos por concessionárias de distribuição designadas, estabelecendo uma relação de exclusividade. É bastante relevante destacar neste modelo de comercialização de energia elétrica, os quais os consumidores não têm liberdade para escolher seu fornecedor de energia elétrica, sendo obrigados a adquiri-la da concessionária designada para a região em que estão localizados (ANEEL,2022).

As concessionárias de energia são responsáveis por comercializar e distribuir energia elétrica aos consumidores finais, gerenciar a infraestrutura de distribuição e garantir a qualidade e confiabilidade do serviço (ANEEL,2022). As concessionárias atendem a todos consumidores residências, que fazem parte da topologia ACR para a contratação de energia elétrica, toda as diretrizes regulatórias são regidas pela Agência Nacional de Energia Elétrica (ANEEL), a qual estabelece as tarifas e regulamentações a serem seguidas pelas concessionárias. (“CARTILHA MERCADO LIVRE DE ENERGIA ELÉTRICA”, 2019)

No mercado cativo, as tarifas de energia elétrica são definidas com base em critérios estabelecidos pela ANEEL, que leva em consideração os custos de geração, de transmissão, de distribuição e de encargos setoriais. Os consumidores cativos são faturados de acordo com estes custos, os quais variam de acordo com o perfil de consumo e a categoria de cliente.

2.3 COMERCIALIZAÇÃO ENERGIA ELÉTRICA E SURGIMENTO DO AMBIENTE DE CONTRATAÇÃO LIVRE (ACL).

O sistema elétrico possui grande impacto no mercado econômico mundial, com o aumento e expansão das fontes geradoras de energias renováveis como Usinas Fotovoltaicas (UFV), Usinadas Eólicas (UE), Biomassa e Pequenas Centrais Hidrelétricas (PCH's) surgiu um nicho de mercado muito atrativo, onde grandes empresas com enfoque comercial, passaram ter a possibilidade de gerar sua própria energia e injetá-las no sistema elétrico de distribuição das concessionárias , isto

expandiu o método de comercialização pois com isto não apenas a concessionária de energia é capaz de gerar e distribuir mas sim diversas empresas que investem neste mercado. Com isto segundo (SILVA,2020), a possibilidade de compra com diversos fornecedores permitiu cotações mais baratas ao valor unitário do MWh comercializado, sendo assim em 2019 houve uma economia de R\$ 200 bilhões de reais aos consumidores que operaram no mercado livre de totalizando 34% de redução em seus custos com energia elétrica.

Este modelo de comercialização passou a ser “Livre”, denominando-se assim ACL (Ambiente de Contratação Livre), porém com o surgimento deste cenário houve necessidade de criação de leis que sustentação as diretrizes de como este ambiente se sucederá, a Lei 9074 de 1995 estabelece as normativas bem como os meios para comercialização do volume energético no ACL. (MACHADO,2022).

Este ambiente de contratação segundo (SILVA,2022) expandiu o mercado econômico mundial e trouxe maior flexibilidade na negociação e aquisição de energia elétrica. O modelo ACL surge como uma proposta de superar o modelo tradicional do setor elétrico, que é caracterizado por um modelo verticalmente integrado, em que as concessionárias de distribuição eram responsáveis tanto pela geração, transmissão, distribuição e pela comercialização da energia. No entanto, este o modelo ACR apresenta limitações em termos de competitividade, de transparência e de possibilidade da escolha entre qual fornecedor realizar a compra de sua energia.

Com o advento do Ambiente de Contratação Livre (ACL), houve a separação das atividades de geração e comercialização de energia elétrica. Contudo, as fases de transmissão e distribuição permanecem sob a responsabilidade da concessionária, incumbida de zelar pela manutenção da infraestrutura. Em decorrência dessa estruturação, são pagos a companhia de energia elétrica apenas a "Tarifa pelo Uso do Sistema de Distribuição (TUSD)" após celebração do "Contrato pelo Uso do Sistema de Distribuição (CUSD)", tal topologia de distribuição é representada pelo Sistema Interligado Internacional (SIN). (“CARTILHA MERCADO LIVRE DE ENERGIA ELÉTRICA”, 2019)

O Mercado Livre de Energia, viabilizado pela Câmara de Comercialização de Energia Elétrica (CCEE), possibilita que consumidores e geradores negociem contratos de energia de forma livre, estabelecendo preços e condições de acordo com

suas necessidades e interesses. De acordo com (CASADEI,2023) a inserção nesse ambiente propicia a redução significativa, podendo alcançar até 20%, nos custos finais com energia elétrica para consumidores atendidos em média tensão. Essa flexibilidade e potencial economia destacam os benefícios e as oportunidades oferecidas pelo Mercado Livre de Energia aos participantes.

Com o surgimento do ambiente de contratação livre abriu espaço para a entrada de novos agentes comercializadores fomentando a competição no mercado financeiro. Além disto, o mercado livre de energia impulsionou o desenvolvimento de novas tecnologias e práticas de gestão que norteia o objetivo deste trabalho, “Em 1º de janeiro de 2024, todos os consumidores de energia elétrica atendidos em alta tensão segundo a Portaria nº 50 estarão aptos a participar do mercado livre de energia elétrica. Potencialmente, 106 mil consumidores a mais passam a se beneficiar deste direito” (CASADEI, 2023).

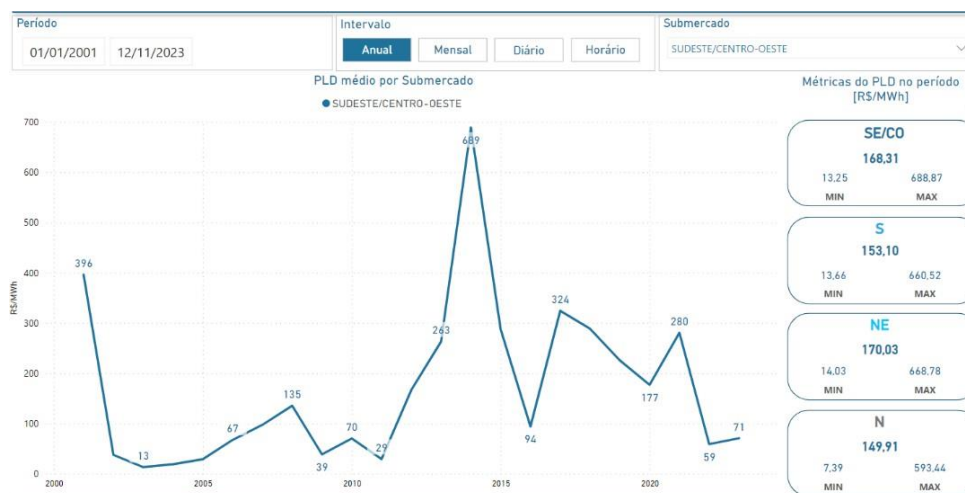
2.3.1 FUNCIONALISMO AMBIENTE CONTRATAÇÃO LIVRE.

No Ambiente de Contratação Livre (ACL), os consumidores têm a capacidade de estabelecer contratos para a aquisição de um determinado volume energético, medido em Mega Watt Médio (MWh) diretamente com os geradores ou comercializadoras de energia. Esses contratos podem ser realizados em diferentes configurações, conhecidas como Mercado de Curto Prazo (MCP), Mercado de Médio Prazo (MMP) e Mercado de Longo Prazo (MLP) (CCEE, 2020). A formalização desses contratos ocorre por meio do registro na Câmara de Comercialização de Energia Elétrica (CCEE), uma entidade encarregada de monitorar e registrar as operações realizadas no mercado livre. Além disso, a CCEE é responsável por conduzir a liquidação das diferenças, conhecida como "Preço de Liquidação das Diferenças" (PLD). Qualquer discrepância no volume energético ao final do mês é automaticamente negociada com base no valor do PLD (Figura 2), a menos que o consumidor opte por uma venda consciente a uma comercializadora.

Nesse contexto, a gestão de excedentes ou a aquisição de volume energético adicional pode representar um desafio significativo para as empresas, podendo resultar em prejuízos substanciais. Com base nessa perspectiva, a utilização de

Redes Neurais Artificiais (RNA) pode proporcionar estimativas mais precisas, oferecendo suporte às operações de compra de energia.

Figura 2. Variação PLD 2001 a 2023.



Fonte: Electra,2023.

Conforme destacado pela ("Cartilha Mercado Livre de Energia Elétrica", 2019), o registro na CCEE é fundamental para garantir a segurança e a transparência nas transações, conferindo aos consumidores o direito de receber o volume energético contratado.

A energia elétrica é distribuída através do Sistema Interligado Nacional (SIN) representado na Figura 3. A gestão do sistema de distribuição é de responsabilidade da concessionária da região. Ao firmar o contrato de compra do volume energético com a Câmara de Comercialização de Energia Elétrica (CCEE), torna-se imperativo o cumprimento desse contrato, garantindo a satisfação das demandas de distribuição necessárias.

O uso desse sistema de distribuição é refletido na fatura como a Tarifa de Uso do Sistema de Distribuição (TUSD), sendo o pagamento direcionado à distribuidora responsável. Esse processo estabelece uma conexão essencial entre o cumprimento dos contratos e a efetiva utilização do sistema de distribuição, reforçando a interdependência entre esses elementos no contexto do mercado elétrico (ANEEL,2022).

Figura 3. Sistema Interligado Nacional (SIN).



Fonte: Cartilha Mercado Livre de Energia Elétrica" (2019).

Na Figura 4, a ferramenta de análise aplicada ao método SWOT foi empregada para delinear e compreender o ambiente de contratação livre. Destaca-se que, nesse contexto, a gestão de riscos é identificada como uma fraqueza, refletindo a volatilidade dos preços e a necessidade crítica de gerenciamento de riscos. Essa vulnerabilidade é exemplificada pela possibilidade de prejuízos decorrentes da venda de um volume energético a valores do Preço de Liquidação das Diferenças (PLD), resultante de decisões inadequadas no momento da contratação do volume energético (MWh).

Figura 4. Análise SWOT ACL.


SWOT - Ambiente Contratação Livre ACL	
<p>Forças</p> <p>FLEXIBILIDADE CONTRATUAL</p> <p>COMPETIÇÃO E PREÇOS</p> <p>DIVERSIFICAÇÃO DE MATRIZ DE GERAÇÃO</p> <p>POTENCIAL ECONOMIA</p>	<p>Fraquezas</p> <p>COMPLEXIDADE CONTRATUAL</p> <p>GESTÃO DE RISCOS</p> <p>REQUISITOS TÉCNICOS</p> <p>DEPENDÊNCIA DE FATORES EXTERNOS</p>
<p>Oportunidades</p> <p>EXPANSÃO DO MERCADO</p> <p>DESENVOLVIMENTO DE ENERGIAS RENOVÁVEIS</p> <p>INCENTIVOS GOVERNAMENTAIS</p> <p>TECNOLOGIAS EMERGENTES</p>	<p>Ameaças</p> <p>VARIAÇÕES CLIMÁTICAS</p> <p>REGULAMENTAÇÃO</p> <p>VOLATILIDADE DE PREÇOS</p> <p>CONCORRÊNCIA COM FONTES CONVENCIONAIS</p>

Fonte: Autoria Própria, 2023.

2.4 REDES NEURAIS ARTIFICIAIS

As redes neurais são modelos computacionais inspirados no funcionamento do cérebro humano que possui capacidade de aprendizado a partir de dados. Elas são compostas por unidades de processamento interconectadas, chamadas de neurônios artificiais (Figura 5), que operam em paralelo para realizar cálculos complexos, segundo (Cajál,1911) os neurônios humanos processam informações na base aproximada de 10⁻³s, já eventos ocorridos em portas lógicas de silício tem seu processamento aproximado de 10⁻⁹s. Apesar dos neurônios humanos terem seu processamento de informação mais lento em relação as referidas portas lógicas, o cérebro humano compensa com expressivas quantidades de neurônios interconectados entre si. (HAYKIN,2001). Essa capacidade de processamento paralelo e aprendizado permite que as redes neurais identifiquem padrões e relações em conjuntos de dados, tornando-as uma ferramenta poderosa para a análise, classificação e previsão (“Redes Neurais Artificiais; USP”,2016)

Figura 5. Constituintes da célula neuronal – Esquema




Fonte: Redes Neúais Aítificiais; USP (2016).

O processo de aprendizagem de uma rede neural é denominado algoritmo de aprendizagem. Em 1949, Donald Hebb fez grandes contribuições para área, ao assimilar que o processo de aprendizagem neural humano se dava através da relação entre neurônios mesmo que estes estivessem distantes entre si (“ORIGEM E CONCEITO NEUROPEDAGOGIA, [s.d.] este percebeu que se dois neurônios são ativos a relação sináptica entre eles é reforçada, esta relação sináptica é semelhante aos filtros adaptivos lineares (Haykin, 2001) desta analogia possibilitou-se grandes

avanços na área das redes neurais uma vez que esta otimiza o processo de aprendizado da rede.

A rede neural artificial é disposta de configuração simples, sua complexidade se dá conforme aumenta-se o tamanho da rede com isto aumenta-se também o processamento desta (“Redes Neurais Artificiais; USP”,2016). McCullock e Pitts em 1943 resumiram o funcionamento de uma rede neural artificial esta ficou disposta conforme apresentada, tal como ilustrado na Figura 6.

Figura 6. Esquema de unidade McCullock – Pitts.




Fonte: Redes Neurais Artificiais; USP, 2016.].

Em síntese, a topologia da Figura 6 é operacionalizada por meio de operações matemáticas, onde um vetor de entradas $x = [x_1, x_2, \dots, x_n]$ é multiplicado por um vetor peso $w = [w_1, w_2, \dots, w_n]$, então é realizada a operação $\sum^n x_i \cdot w_i$, que é um somatório do produto escalar do i -ésimo elemento do vetor de pesos e da i -ésima entrada, que na sequência passa por uma função de ativação que possa representar a saída y de forma adequada.

2.4.1 REDES NEURAIIS PERCEPTRON MULTICAMADAS

A Rede Perceptron de Múltiplas Camadas (PMC) representa um marco fundamental no campo de aprendizado de máquina e inteligência artificial. Introduzida como uma extensão do Perceptron simples, a PMC supera as limitações deste último, possibilitando a abordagem de tarefas mais complexas e não lineares. Composta por camadas de neurônios interconectados conforme representado pela Figura 7, a PMC destaca-se por sua capacidade intrínseca de aprender e generalizar padrões a partir de conjuntos de dados (Redes Neurais Artificiais; USP,2016).


Figura 7. Peícenton Multicamadas - PMC



Fonte: SILVA; SPATI; FLAUZINO (2010)

Uma abordagem de implementação de uma Rede Neural Artificial Perceptron Multicamadas (RNA – PMC) envolve a aplicação da regra delta. Esse método segundo (SIMON,2000), permite a implementação de um treinamento supervisionado do tipo 'feedforward', no qual se avalia o valor do 'Mean Square Error' (MSE), uma métrica que expressa a discrepância entre a saída prevista pela rede e o valor desejado. A partir do cálculo do MSE, obtém-se um valor delta, que, por sua vez, é utilizado no processo de retro propagação ('backward'). Durante essa etapa, o vetor de pesos é atualizado de maneira a minimizar o MSE, conforme ilustrado nas Figuras 8 e 9. Esse procedimento visa otimizar o desempenho da RNA PMC, ajustando seus pesos para se aproximar do resultado desejado. (SILVA,2010).


Figura 8. Regra delta.



Fonte: Redes Neurais Artificiais; USP , 2016].

A Figura 9, representa a modelagem esquemática de treino de uma RNA PMC. Nesta figura são inseridos dados de entrada previamente normalizados e armazenado na variável E (entrada de dados) e y representa a resposta de saída da RNA, ao passar pela função de ativação é comparada com o desejado e o valor de Δ atualiza o vetor de pesos da rede conduzindo-a aproximação do valor desejado.

Figura 9. Esquema de treinamento do Perceptron.



Fonte: Redes Neurais Artificiais; USP, 2016.

2.4.1.1 MÉTODO LEVENBERG – MAQUARDT

A metodologia de Levenberg-Marquardt (LMA) é considerada a mais rápida dos algoritmos de treinamento retro propagação de erro, segundo (GONCALVES et. al., 2010). Embora o método e LMA exija mais memória computacional do que outros algoritmos, este método possui características vantajosas. A metodologia de Levenberg-Marquardt se destaca por sua capacidade de convergir eficazmente em sistemas não lineares, segundo (ADERALDO; ADEMIR; RIBEIRO, [s.d.]). A robustez e eficiência desse método tornam-no uma excelente ferramenta para implementação da RNA proposta.

Em sua modelagem matemática, a introdução do parâmetro λ_k , conforme descrito na Equação 1.

$$(J^T(X_k)J(X_k) + \lambda_k I) d_k = (-J^T(X_k)R(X_k)) \quad (1)$$

permite a adaptação da direção e do tamanho do passo durante a otimização, garantindo que a rede neural possa explorar eficientemente o espaço de busca em diferentes cenários, inclusive em problemas não lineares.

A modelagem da matemática da Equação 1 , é descrita através das seguintes variáveis :

$JT(Xk)$: É a transposta da matriz Jacobiana no ponto Xk . A matriz Jacobiana é uma matriz que contém as derivadas parciais de um sistema de equações em relação às variáveis independentes. A transposta é obtida trocando as linhas pelas colunas.

$J(Xk)$: Representa a matriz Jacobiana no ponto Xk

λk parâmetro de Levenberg Marquadt (LMA) , Ele controla a quantidade de ajuste que é feito em cada iteração. Quando λk é grande, o método age mais como o método do Gradiente Descendente. Se λk é pequeno, o método se aproxima do método de Gauss-Newton.

I é a matriz identidade da equação.

$d k$,o vetor de incremento que é adicionado à estimativa atual Xk . Este vetor representa a direção na qual estamos ajustando os parâmetros.

$R(Xk)$ O vetor de resíduos no ponto Xk . Os resíduos são as diferenças entre as observações reais e as estimativas do modelo.

Tais variáveis que modelagem o algoritmo de treino de Levenberg Marquadt, faz deste método uma proposta robusta e eficiente por ser adaptável a diversos sistemas sejam eles lineares ou não.

2.4.1.2 GRADIENTE DESCENDENTE.

A metodologia do Gradiente Descendente é um dos algoritmos mais utilizada na literatura, por se tratar de um algoritmo primitivo, possuindo uma vasta aplicabilidade em problemas de 'machine learning' (UFPR,2019).

O método do gradiente descendente é uma técnica iterativa para otimizar funções. Ele ajusta os parâmetros da função de maneira a minimizar gradativamente o valor da função objetivo. A cada iteração, o método calcula o gradiente da função no ponto atual e dá um passo na direção oposta para encontrar um mínimo local. A regularização com um termo de penalidade auxilia na estabilidade do processo. Isso é feito até que a convergência seja alcançada, proporcionando uma solução eficiente para problemas de otimização (UFPR, [s.d]). A formulação matemática do método do gradiente descendente é descrita através da Equação 2.


$$\beta^{(k+1)} = \arg \min_{\beta} J(\beta^{(k)}) + \nabla J(\beta^{(k)}) (\beta - \beta^{(k)}) + \frac{1}{2a} \|\beta - \beta^{(k)}\|^2. \quad (2)$$

Processo de aproximação se dá ao substituir o termo $12a$ por $\nabla^2 J(\beta^{(k)})$ ao derivamos em função de β e igualando a equação a zero, obtém-se temos a Equação 3 que convergirá necessariamente a um mínimo local devido a primeira derivada.

$$\beta^{(k+1)} = \beta^{(k)} - a \nabla J(\beta^{(k)}). \quad (3)$$

Através desta modelagem matemática é possível realizar uma aproximação a a partir de um ponto inicial P_0 representado pela Figura 10.

Figura 10. Modelo Aproximador – Gradiente Descendente.



Fonte: UFPR,[s.d] - Laboratório Estatística.

2.4.1.3 BFGS Broyden–Fletcher–Goldfarb Shanno Quasi – Newton

O método Broyden-Fletcher-Goldfarb-Shanno (BFGS) é um algoritmo de otimização utilizado para encontrar o mínimo (ou máximo) de uma função diferenciável. Ele pertence à categoria de métodos Quasi-Newton, que são métodos iterativos de otimização que não exigem o cálculo direto da matriz Hessiana (segundas derivadas parciais) da função (MUKHERJEE; ROUTROY, 2012).

Este método é fundamentado pela Equação 4, onde $W(t + 1)$ representa os parâmetros atualizados após a iteração e $W(t)$ os parâmetros atuais antes da iteração, αt delimita o tamanho do passo de busca da RNA na direção desejada. Já o $\nabla J(W(t))$ é o radiente da função objetivo $J(W)$ em relação aos parâmetros do ponto $W(t)$ indicando a direção na qual a função mais cresce, o último parâmetro da equação explica menção feita por (MUKHERJEE; ROUTROY, 2012), onde $\nabla^2 J(W(t))^{-1}$

é a inversa da matriz Hessiana que é uma aproximação da segunda derivada de $J(W)$. Esta matriz é usada para ajustar a direção do passo e controlar a curvatura da função.

$$W(t + 1) = W(t) - a_t \cdot [\nabla^2 J(W(t))]^{-1} \cdot \nabla J(W(t)) \quad (4)$$

A equação geralmente é derivada usando técnicas de otimização e cálculo matricial. Em resumo, ela indica que, para encontrar os parâmetros otimizados $W(t + 1)$, você ajusta os parâmetros atuais $W(t)$ na direção oposta ao gradiente da função, ponderado pela inversa da matriz Hessiana.

3 METODOLOGIA

Nesta seção são abordados os conceitos e procedimentos necessários para a implementação da Perceptron Multicamadas (PMC) para estimativa de demanda energética. Esta abordagem tem como foco estimativa de demanda por meio da análise do perfil de consumo de energia, que se baseia nas variáveis de entrada, que são as áreas construídas de cada estabelecimento e meses, bem como a variável de saída que é a demanda energética de cada estabelecimento. A área construída está diretamente relacionada com a demanda energética e o mês está relacionado com sazonalidade, que também reflete na demanda energética.

As variáveis de entrada possuem valores absolutos e grandezas diferentes, por exemplo, a área e sua unidade em m², o mês em unidade unidimensional, e consumo energético e a sua unidade kWh. Estas diferentes intensidades e grandezas das variáveis precisam ser normalizadas em escalas similares e unidades equivalentes, para evitarem o domínio da intensidade de maior valor. Por esta razão, adota-se a normalização por unidade (PU - 'per unit'), para uma garantia de escalas similares entre as diferentes variáveis de entrada e de saída. As bases para cada uma das variáveis são pré-determinadas pelos valores máximos destas, de cada uma das unidades (BICHELS,2018).

A análise de relevância das variáveis de entrada para a estimativa da demanda energética é avaliada por meio da correlação de Pearson. A correlação de Pearson é um método estático, consolidado na literatura (LIRA,2004), que permite estimar o quão correlacionadas estão as variáveis de entrada e de saída. A máxima correlação

diretamente proporcional entre duas variáveis é encontrada quando a correlação de Pearson entre uma das variáveis de entrada e a saída é igual 1, enquanto a máxima correlação inversamente proporcional entre duas variáveis é encontrada quando a correlação de Pearson entre uma das variáveis de entrada e a saída é igual a - 1, e não há correlação entre duas variáveis quando a correlação de Pearson entre duas variáveis é zero.

A rede PMC é avaliada em diferentes topologias, que são configuradas com diferentes métodos de otimização, dentre eles, o método de otimização Levenberg-Marquardt, Gradiente Descendente, Gradiente Descendente e Broyden-Fletcher-Goldfarb Shanno Quasi – Newton (BFGS), e diferente quantidade de neurônios. Em cada topologia se analisa o erro quadrático médio, para então determinar aquela que retorna a melhor estimativa de demanda energética.

A seguir, as etapas metodológicas desta seção são discutidas em detalhes: a Subseção 3.1., discute sobre os dados de entrada e saída e a suas respectivas normalizações em PU; na subseção 3.2, trata sobre análise de relevância de variáveis por meio da correlação de Pearson; e por fim, a subseção 3.3, discute sobre as topologias consideradas para a rede neural PMC.

3.1 DADOS DE ENTRADA E SAÍDA


Os dados de entrada e saída desempenham papel importante na rede neural artificial PMC para a estimativa da demanda energética. As duas variáveis de entrada assumidas, a área (m^2) e o mês, se relacionam com a carga energética consumida de cada um dos estabelecimentos e a sazonalidades, respectivamente.

A área possui uma relação direta com a demanda energética de cada um dos estabelecimentos, que se dá principalmente pela carga de iluminação, de climatização, de refrigeração, dos computadores, dos fornos industriais, das estufas, dentre outras. Esta conexão entre os dados não apenas sustenta academicamente este trabalho, mas também constitui a base essencial para uma compreensão aprofundada das dinâmicas energéticas inerentes a cada setor.

Já o mês em particular, ao considerar o impacto sazonal, torna-se evidente que a demanda energética varia ao longo do ano. O mês específico pode desempenhar um papel crucial nessa dinâmica, influenciando diretamente a intensidade do consumo

em diferentes setores. Por exemplo, meses mais quentes podem aumentar a necessidade de climatização e refrigeração, enquanto períodos de demanda sazonal específica, como festas de final de ano, podem impactar o consumo de energia em setores relacionados a fornos industriais e iluminação decorativa.

Figura 11. Estrutura RNN PMC – Dados Entada e Saída.



Fonte: Autoria Própria (2023).

Dados de saída caracterizam os volumes de energia consumidos no período de 2021 à 2023 e estão dispostos de 462 dados para treinamento e validação da RNA.

3.1.1 TRATAMENTO DE DADOS

Dada a diversidade de dados, se torna essencial o tratamento de todas a informações manipuladas na rede neural. Esse processo assume dois tópicos principais, a elaboração da estrutura na qual os dados serão inseridos e a normalização deste para evitar propagação de erro, que será detalhada na Seção

3.1.2. Essa etapa desempenha um papel crucial no desempenho da Rede Neural Artificial (RNA), pois a falta de validação nessa fase comprometeria o desenvolvimento da rede.

Os dados de entrada e de saída utilizados neste trabalho foram estruturados de maneira linear, em que cada coluna é representa por uma entrada ou saída da rede neural, assim como a quantidade de linhas representa a quantidade de amostras, se configurando como assim uma matriz de dados. Tal organização proporciona uma disposição eficiente para a entrada na RNA, contribuindo para a eficácia do treinamento e da posterior análise dos resultados de estimativa de demanda energética.

3.1.2 NORMALIZAÇÃO DE DADOS

Para que a rede seja eficiente em seu processo de aprendizado (MATOS, 2023) refere-se a importância da normalização dos dados. Este procedimento, é essencial para garantir o máximo desempenho da RNA, pois evita que variáveis com diferentes escalas dominem o processo de treinamento, o que poderia impactar negativamente o desempenho da rede.

A normalização dos dados foi realizada por meio do método PU ("Per Unity"), o qual representa um valor percentual do maior valor da matriz. (BICHELS, 2018) Essa abordagem permite que os valores sejam dispostos em uma escala entre 0 e 1 para as variáveis de Volume Energético, Mês e Área Construída.

Realizar a normalização dos dados é um procedimento fundamental que tem como objetivo reescalar as variáveis de entrada, garantindo que todas estejam no mesmo 'range' de valores. A não normalização dos dados em escalas equivalentes pode acarretar em problemas como convergência lenta, estagnação da otimização ou falhas no aprendizado. Assim, a normalização dos dados se configura como uma etapa crítica para o sucesso do projeto.(MATOS,2023).

3.1.3 CORRELAÇÃO DE PEARSON

Para validação dos dados foi utilizado método de Pearson para análise de interação entre estes dados . A matriz de Pearson é uma ferramenta estatística extremamente relevante que nos permite avaliar as relações lineares entre variáveis, fornecendo "insights" valiosos sobre a conexão dessas variáveis. Neste estudo, estamos trabalhando com três variáveis fundamentais: mês, área e consumo (MWh).

De acordo com (Cohen,1988), podemos categorizar as relações entre os dados em três níveis com base em intervalos estabelecidos Tabela 1:


Tabela 1 – Correlação de Pearson

0,10 a 0,29	Baixa Correlação
0,30 a 0,49	Média Correlação
0,50 a 1,00	Alta Correlação

Fonte: Autoria Própria

Na Tabela 1, a relação entre os dados é definida por Pearson em uma escala que varia de -1 a 1. Valores positivos indicam uma correlação direta e valores negativos sugerem uma correlação inversa.

Figura 12. Exemplos de Associação linear



Fonte : LARSON, 2010, Pg. 395

A equação (5) representa a correlação de Pearson e mede a variação compartilhada entre duas variáveis.

$$r = \frac{1}{n-1} \sum \frac{x_i - \bar{x}}{\sigma_x} * \frac{y_i - \bar{y}}{\sigma_y} \quad (5)$$

Com o auxílio de ferramentas de análise estatística de dados, se utilizou o software “Jamovi” com o objetivo de aplicar a metodologia Pearson. Isto permitiu-nos realizar uma análise meticulosa da matriz de dados com a qual trabalhamos, com o objetivo de validar a força da interação entre os dados. Conforme ilustrado na Tabela 2, observamos que a matriz “Consumo” contendo 462 dados de consumo (MWh) e a matriz “Área” (m²), também com 462 dados, são classificadas como “Alta Correlação” segundo a Tabela 1, e as variáveis “Consumo” e “Mês” são classificadas com baixa correlação , o fato de possuir uma correlação viabiliza a implementação da


Tabela 2. Correlação de Pearson Dados Entrada.

Correlação de Pearson	
Consumo	
Área	0.741
Mês	0.182

Fonte: Autoria Própria, 2023.

A Figura 13 representa pontos físicos a qual estão situados estabelecimentos cujos dados farão parte do treinamento da rede neural artificial

Figura 13. Visão Geral Satélite




Fonte: Autoria Própria,2023.

3.3 PERCENTRON MULTICAMADAS

As redes neurais artificiais Perceptron de Múltiplas Camadas se distinguem pela inclusão de, no mínimo, uma camada intermediária composta por ‘ n ’ neurônios representada pela Figura 14. (KAZUO,2023). Foram adotadas algumas topologias de treino para a RNA PMC com objetivo de trazer métricas de comparação da resposta da rede. Tais métricas serão discutidas na seção 3.3.1.1, os métodos de “Levenberg - Marquardt”, “Gradient Descent” e “BFGS Quasi-Newton” respectivamente serão discutidos nas subseções 3.3.1.2 a 3.3.1.3.

Figura 14. Perceptron Multicamadas - PMC.



Fonte: Autoria Própria,2023.

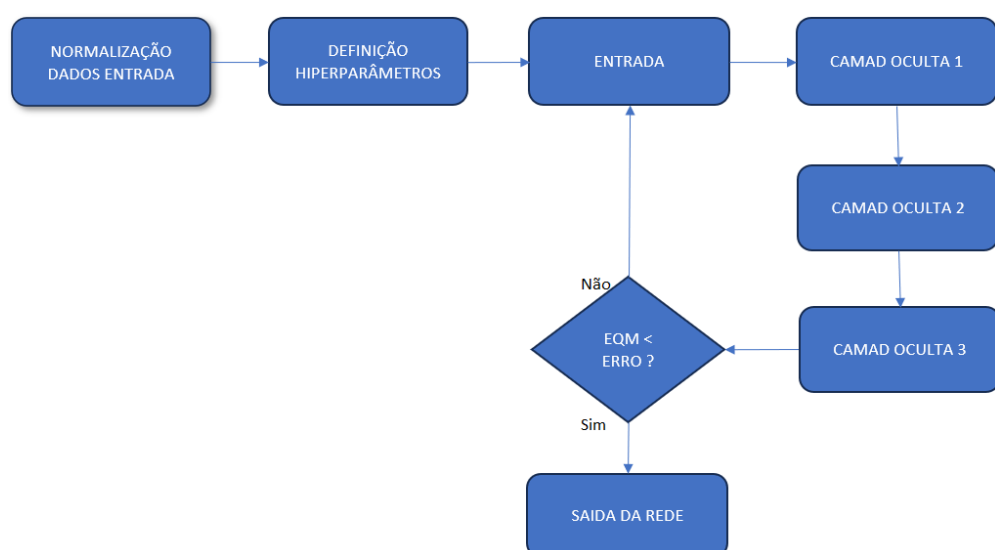
Na Tabela 3, foi estabelecido pseudocódigo com objetivo de representar as etapas constituintes da RNA e serão utilizadas para implementação da rede neural artificial.

Tabela 3. Pseudocódigo - Implementação RNA.

<p>1) NORMALIZAR DADOS</p> <p>2) DEFINIR HIPERPARÂMETROS</p> <ul style="list-style-type: none"> a. Número de épocas. b. Taxa de aprendizagem. c. Número de neurônios. d. O erro. <p>3) TREINAMENTO DA RNA</p> <ul style="list-style-type: none"> a. Definir o método de treino. b. Inserir as entradas da RNA (área e mês) c. Inserir os valores desejados para cada conjunto de entradas. d. Realizar o treinamento da RNA. e. <p>4) VALIDAÇÃO</p> <ul style="list-style-type: none"> a. Plota as saídas da RNA e compara com os valores desejados. b. Cálculo de desempenho da rede (EQM) c. Saída da RNA (estimativa de demanda energética). <p>Fim do Pseudocódigo de Implementação RNA.</p>
--

Fonte: Autoria Própria,2023.

Figura 15. Fluxograma Rede Perceptron MultiCamadas.



Fonte: Autoria Própria,2023.

3.3.1 MÉTODOS DE TREINAMENTO DA RNA

A rede será treinada e avaliada em diversas configurações com objetivo de obter a melhor resposta possível, estas configurações (ou topologias) são descritas a seguir na Tabela 4, sendo os principais elementos desta Tabela: o método de treinamento, a quantidade de neurónicos nas camadas (oculta 01, 02 e 03) e ID do método.

Tabela 4. Configurações das Redes Neurais.

ID MÉTODO	MÉTODOS DE TREINO	QUANTIDADE DE NEURÔNIOS POR CAMADA.		
		CAMADA OCULTA 1	CAMADA OCULTA 2	CAMADA OCULTA 3
LMA1	Levenbeg Maquardt	1	1	1
LMA2	Levenbeg Maquardt	2	2	2
LMA3	Levenbeg Maquardt	3	3	3
.	Levenbeg Maquardt	.	.	.
.	Levenbeg Maquardt	.	.	.
.	Levenbeg Maquardt	.	.	.
LMA30	Levenbeg Maquardt	30	30	30
GD1	Gradiente Descendente	1	1	1
GD2	Gradiente Descendente	2	2	2
GD3	Gradiente Descendente	3	3	3
.	Gradiente Descendente	.	.	.
.	Gradiente Descendente	.	.	.
.	Gradiente Descendente	.	.	.
GD30	Gradiente Descendente	30	30	30
BFGS1	Broyden Fletcher	1	1	1
BFGS2	Broyden Fletcher	2	2	2
BFGS3	Broyden Fletcher	3	3	3
.	Broyden Fletcher	.	.	.
.	Broyden Fletcher	.	.	.

BFGS30	Broyden Fletcher	30	30	30
--------	------------------	----	----	----

Fonte: Autoria Própria,2023.


3.3.1.1 MÉTODO LEVENBERG - MAQUARDT MÉTRICAS

Para análise de desempenho da RNA será avaliado as seguintes componentes: MSE ('Mean Square Error' ou Erro Quadrático Médio) que representa a performance da rede e é modelado pela equação 6.

$$MSE = \frac{1}{N} \sum_{k=1}^N [y(x_k) - d_k]^2 \quad (6)$$

Onde N representa a quantidades de entradas e saídas da RNA, $y(x_k)$ consiste na resposta de saída da RNA e d_k representa o valor desejado como resposta da rede. Para treinamento desta rede, foi realizada diversos treinamentos alterando o número de neurônios da RNA foram defiidas fixas 3 camadas para o treino .Com o objetivo de identificar a melhor configuração para estimativa do volume energético (MWh) , calculada com base no menor MSE.Na Figura 18 serão apresentadas as respostas da RNA PMC – topologia “Levenberg - Marquardt”.


Figura 16. Convergência RNA PMC – Levenberg - Marquardt.



Fonte: Autoria Própria,2023.

Na Figura 16, é possível observar a resposta de convergência da RNA, foram utilizados 60% dos dados para treino, 20% para validação e 10% para testes da RNA, os testes realizados serão apresentados na Figura 17.

Figura 17. Saída RNA PMC – Levenberg - Marquardt.




Fonte: Autoria Própria, 2023.

Na figura 17 pode-se observar a resposta da rede neural artificial representada, para diferentes números de neurônios expresso pelo eixo x. O desempenho da rede é mensurado através do MSE, este será apresentado na Figura 18.


A rede com a topologia de treino “Levenberg-Marquadt” (LMA10) apresentou um excelente resultado, nota-se que o menor MSE foi com a modelagem representada pela Figura 19.

Figura 18. Mean Square Error – Levenberg - Marquardt.



Fonte: Autoria Própria,2023.


Figura 19. Modelagem RNA PMC – Levenberg - Marquardt.



Fonte: Autoria Própria,2023.

Através da Figura 20, podemos observar a taxa de acerto e aproximação dos dados em relação a saída da rede.

Figura 20. Taxa de Acerto – Levenberg - Marquardt.




Fonte: Autoria Própria, 2023.

3.3.1.2 GRADIENTE DESCENDENTE MÉTRICA.

A avaliação será embasada em métricas extraídas do treinamento da RNA. Obtivemos várias saídas da RNA aumentando o número de neurônios do processo de aprendizado até um total de 30 neurônios e 3 camadas fixas. Com o objetivo de identificar a melhor configuração para estimativa do volume energético (MWh) dos estabelecimentos para atuação no ACL, podemos observar comportamento de convergência da “Rede Neural Artificial – Perceptron Multi Camadas - Método Gradiente Descendente”, na Figura 21.


Figura 21. Convergência RNA PMC – Gradiente Descendente.



Fonte: Autoria Própria, 2023.

Na Figura 21, é possível observar a resposta de convergência da RNA, foram utilizados 60% dos dados para treino, 10% para validação e 10% para testes da RNA, os testes realizados serão apresentados na Figura 22.


Figura 22. Saída RNA PMC – Gradiente Descendente.



Fonte: Autoria Própria, 2023.

Na Figura 22 pode-se observar a resposta da rede neural artificial representada, para diferentes números de neurônios expresso pelo eixo x. O desempenho da rede é mensurado através do MSE, este será apresentado na Figura 23.

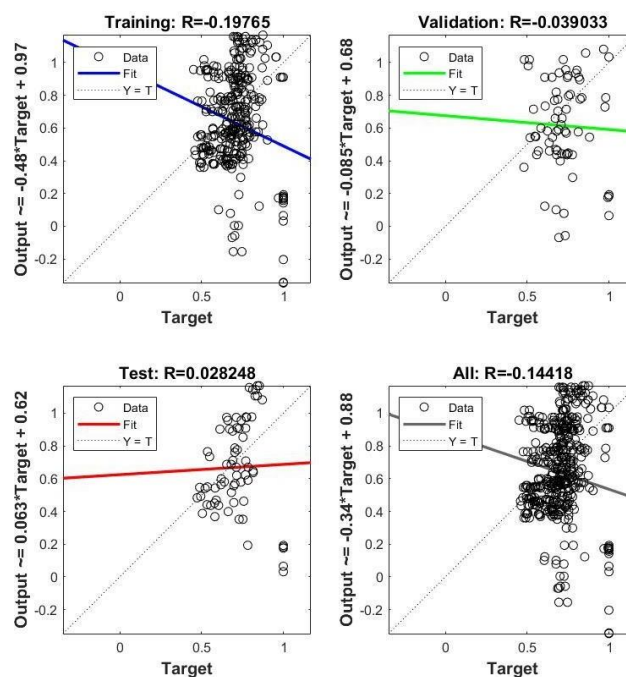
Figura 23. Mean Square Error – Gradiente Descendente.



Fonte: Autoria Própria, 2023.

A rede com topologia de treino “Gradiente Descendente” apresentou um resultado relevante, porém essa modelagem segundo (UFPR, [s.d]) tende a ser uma simplificadora de função sendo indicada uma segunda implementação através do “Método de Newton” ou “Método do Gradiente Conjugado”, isto fica evidente ao observar a Figura 24 .Nota-se que a apesar da convergência a RNA possui uma taxa de acerto muito baixa aproximando-se de uma classificadora linear.


Figura 24. Taxa de Acerto – Gradiente Descendente



Fonte: Autoria Própria, 2023.

A RNA teve seu melhor desempenho apresentando o menor MSE através da modelagem representada pela Figura 25.

Figura 25. Modelagem RNA PMC – Gradiente Descendente.




Fonte: Autoria Própria,2023.

3.3.1.3 BFGS Broyden–Fletcher–Goldfarb Shanno Quasi – Newton - Métricas

A análise será fundamentada em métricas derivadas do processo de treinamento da RNA. Foi explorada diferentes configurações, variando o número de neurônios até um máximo de 30, mantendo constantes as 3 camadas. Durante este processo, buscamos identificar a configuração adequada para a estimativa do volume energético (MWh) dos estabelecimentos no Ambiente de Contratação Livre (ACL). Será destacado, na Figura 26, a trajetória de convergência da Rede Neural Artificial - Perceptron de Múltiplas Camadas - Método Broyden–Fletcher–Goldfarb–Shanno Quasi–Newton.


Figura 26. Convergência RNA PMC – Método BFGS.



Fonte: Autoria Própria,2023.

Na Figura 26, é possível observar a resposta de convergência da RNA, foram utilizados 55% dos dados para treino, 35% para validação e 10% para testes da RNA, os testes realizados serão apresentados na Figura 27.

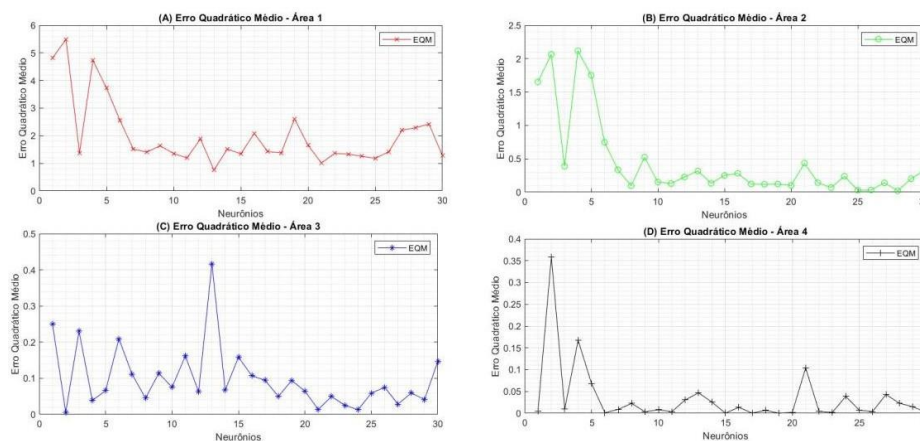
Figura 27. Saída RNA PMC – Método BFGS.



Fonte: Autoria Própria,2023.

Na figura 27 podemos observar o comportamento da rede neural artificial expresso pelo eixo y (Volume Energia MWh), após a mesma ser submetida a diversas configurações de treino aumentando número de neurônios por camada expressa pelo eixo x (Neurônios. O desempenho da rede é mensurado através do MSE, este será apresentado na Figura 28.


Figura 28. Mean Square Error – Método BFGS.



Fonte: Autoria Própria,2023.

Ao analisarmos as métricas de MSE extraídas da rede com o aumento de neurônios por camada, observou-se uma excelente resposta ao atingir a topologia representada pela Figura 29 (BFGS15).

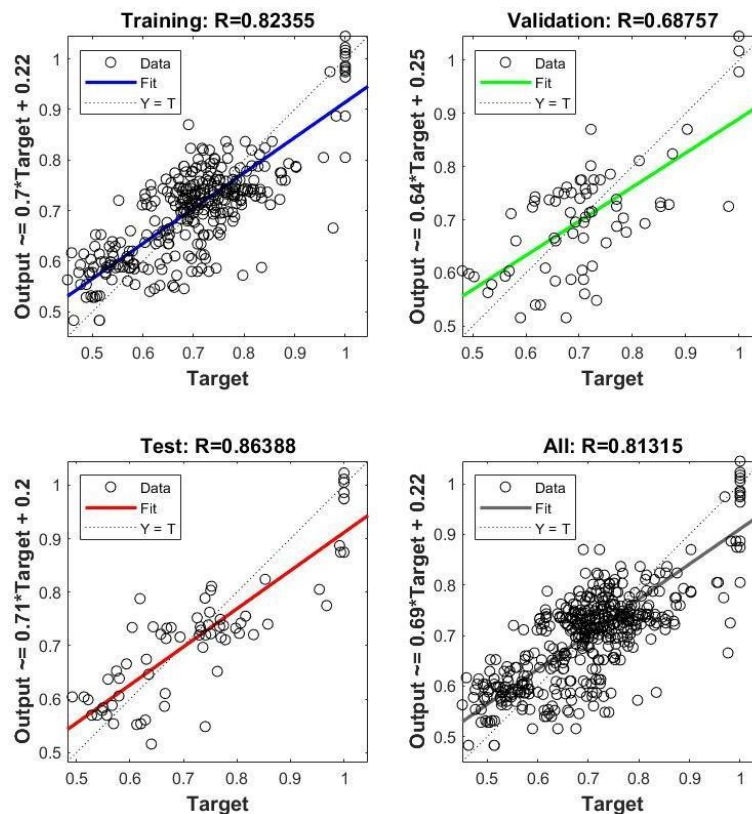
Figura 29. Modelagem RNA PMC – Método BFGS.



Fonte: Autoria Própria,2023.

Através da Figura 30, podemos observar a taxa de acerto e aproximação dos dados em relação a saída da rede.

Figura 30. Taxa de Acerto – Método BFGS.



Fonte: Autoria Própria,2023.

4 CONCLUSÃO E DISCUSSÃO DE RESULTADOS

Com base nas discussões apresentadas ao longo deste trabalho, torna-se possível analisar o desempenho das Redes Neurais Artificiais Perceptron de Múltiplas Camadas (RNA PMC) em diferentes configurações de treinamento. As métricas extraídas nos fundamenta a proferir algumas considerações sobre o desenvolvimento deste estudo.


A RNA PMC, configurada com 3 camadas intermediárias e 10 neurônios ID LMA10, utilizando o método de treinamento "Levenberg-Marquardt", apresentou resultados notáveis, conforme detalhado na seção 3.3.1.1. Os resultados revelaram uma excelente taxa de validação dos dados 89%. Esta performance sugere que essa configuração de rede neural pode ser uma escolha eficaz para a implementação de estratégias de estimativa de volume energético para operação de energia elétrica nos Mercados de Curto Prazo (MCP), Médio Prazo (MMP) e Longo Prazo (MLP).

Já a RNA PMC, também configurada com 3 camadas intermediárias e 10 neurônios, treinada por meio do método do Gradiente Descendente, demonstrou convergência. No entanto, sua propensão à linearização e classificação dos dados impediu a obtenção de valores coerentes para seus pesos, resultando em uma taxa de validação menos atrativa, atingindo 39%. Essa abordagem revelou-se ineficaz para a estimativa do volume energético (MWh) nos estabelecimentos em questão.

A RNA PMC configurada com 3 camadas intermediárias e 15 neurônios treinada através do método de Broyden-Fletcher-Goldfarb-Shanno (BFGS), obteve resultados interessantes, este método atingiu o índice de 79% de acerto, mostrando - se uma bom método para comparitivo com estratégia existente.

Por fim, a RNA PMC configurada com 3 camadas intermediárias e 15 neurônios, treinada utilizando o método de Broyden-Fletcher-Goldfarb-Shanno (BFGS), apresentou resultados interessantes, alcançando uma taxa de acerto de 79%. Esse método se mostrou uma alternativa viável e eficaz, proporcionando um bom ponto de comparação com as estratégias existentes. Essa descoberta sugere que o BFGS pode ser considerado como uma abordagem promissora para a configuração de redes neurais destinadas a problemas similares.

Figura 31. Comparativo Métodos LMA – GD – BFGS - Média.



Fonte: Autoria Própria, 2023.

A Figura 31 representa o desempenho das diversas configurações e topologias de treinos da rede neural artificial, neste gráfico é possível analisar o desempenho de acerto das RNA's submetidas.


A topologia treinada através do método de Levenberg Marquardt obteve a melhor resposta em relação aos outros métodos, vale ressaltar que este método apresentou eficácia de 39% superior em relação ao método cálculo médio tradicionalmente utilizado para a tomada de decisão no ambiente de contratação livre e está eficácia possui relação direta com as métricas financeiras que serão abordadas na seção 4.1

4.1 - MÉTODO TRADICIONAL DE ANÁLISE DE VOLUME ENERGÉTICO.

Através da análise de resposta das RNA's, foi possível notar um excelente desempenho, caracterizando um cenário interessante para contratação de um volume energético (MWh) neste ambiente volátil como pode-se observar na Figura 32.

Nesta seção serão abordadas métricas financeiras inerente ao nosso objetivo principal, com intuito de analisar a eficácia desta topologia de rede neural artificial aproximadora comparada com métodos tradicionais empíricos utilizando-se da média em sua tomada de decisão.

Figura 32. Variação PLD 2001 a 2023.



Fonte: Electra,2023.

No “Ambiente de Contratação Livre ACL”, a melhor tomada de decisão é o menor erro possível na compra do volume energético estimado em relação ao real consumido, esta falha submete ao consumidor a cenários catastróficos em prejuízos financeiros, isto ocorre pois as legislações vigentes a modelo contratuais obriga que o consumidor estime corretamente o volume de energia a ser comprado e esta transação é celebrada através do contrato de compra de energia homologado junto a CCEE, caso o consumidor chegue ao fim do contrato e não tenha utilizado todo o seu volume energético (MWh), este é liquidado pela câmara de comercialização ao Preço do PLD que é representado pela Figura 34, podendo acarretar enormes prejuízos financeiros.

Um outro ponto é quando o consumidor utiliza todo seu volume de energia antes do término do seu contrato, obrigando-o a comprar energia no mercado de curto prazo, este cenário também pode ser prejudicial pois assim estará sujeito a volatilidade do PLD e a taxa SPREAD que representa estratégia comerciais para venda de energia de cada agente comercializador do mercado livre, este está ligado ao poder de negociação destes agentes. Ambos cenários são desfavoráveis pois estão passivos de grandes prejuízos financeiros, na Figura 33 pode-se observar valores (R\$) bases para compra de energia no mercado livre de energia.

Na Figura 35 é possível identificar as topologias as quais o consumidor pode fazer sua operação de compra de volume energético, sendo caracterizada em duas configurações “Produto Incentivada I5” e “Produto Convencional”, estas topologias possuem diferentes valores unitários (R\$) para compra do volume energético (MWh)

para diferentes configurações como contratos de curto prazo MCP , mercado de médio prazo MMP e mercado de longo prazo MLP, além disto estas são representadas por duas vertentes “I5 Icentivada” onde nesta configuração o consumidor possui desconto de 50% do seus custos com a taxa TUSD (Tarifa Uso do Sistema de Distribuição) , as incentivadas são caracterizadas por serem energia comercializadas por Usinas Fotovoltaicas (UFV) , Usina Eólicas (EU) , Biomassa , Pequenas Centrais Hidrelétricas (PCH’s) , para estes são celebrados “Contratos de Compra de Energia Elétrica Incentivada Especial (CCEEIE). (CCEE,2012).

Figura 33. Indicativo Preço Volume Energético (MWh).

Indicativo de preços

Preço FLAT – Válido até 14/11/23

*Produto Incentivada - I5							
2023	2024	2025	2026	2027	2028	2029	2030
120							
119	125						
118	124	134					
117	123	133	144				
116	122	132	143	151			
115	121	131	142	150	156		
115	121	131	142	150	156	159	
114	120	130	141	149	155	158	162

*Produto Convencional							
2023	2024	2025	2026	2027	2028	2029	2030
90							
89	91						
88	90	104					
87	89	103	113				
86	88	102	112	121			
85	87	101	111	120	126		
85	87	101	111	120	126	131	
84	86	100	110	119	125	130	134

**Produto Varejista							
2023	2024	2025	2026	2027	2028	2029	2030
157	167	178	177	193	197	200	217

Fonte: CEMIG,2023.

Já o nicho convencional remete-se a compra do volume energético de Grandes Usinas Hidrelétricas, este modelo não garante desconto na tarifa (TUSD), estes cenários garantem ao consumidor estratégias de gestão e eficiência energética e fomenta o mercado competitivo.

Para um modelo de negócio de compra de energia neste ambiente, foi adotado a configuração I5 no período de de um ano, onde este representa o Mercado de Médio Prazo, através desta configuração serão comparadas as métricas extraídas das saídas estimadas das RNA's que apresentaram relevância em seu resultado com

intuito de validar o objetivo deste trabalho. Na Figura 34 e apresentado cotação do PLD para efeitos de cálculo e discussão das métricas financeiras.


Figura 34. PLD - 14/11/2023.



Fonte: Electra,2023.

A partir deste cenário será comparado através da Figura 35 o comportamento e desempenho financeiros das estratégias abordadas com intuito de validação deste trabalho.

Figura 35. Comparação Métricas Financeiras.



Fonte: Autoria Própria,2023.

A Figura 35, representa o desempenho financeiro do cenário abordado. Esta figura nos traz resultados positivos e viabiliza a utilização da Rede Neural Artificial – Perceptron Multicamadas configurada na topologia 3 camadas e 10 Neurônios treinada e validada pelo método de treino de Levenberg Marquardt como uma excelente ferramenta para estimativa de volume energético e contratação de energia elétrica no mercado livre de energia (ACL).

5 CONCLUSÃO.

A análise do desempenho das Redes Neurais Artificiais Perceptron Multicamadas (RNA PMC) em configurações diversas revelou resultados promissores, especialmente ao considerar o contexto volátil do Mercado Livre de Energia (ACL). A utilização destas redes proporcionou um cenário favorável para a contratação de volume energético (MWh).

Ao adentrar na análise financeira, este trabalho focalizou a tomada de decisões no ACL, enfatizando a necessidade de estratégias eficazes para mitigar prejuízos significativos. O ambiente competitivo e dinâmico do mercado livre implica desafios, dentre eles, este estudo destacou que a melhor tomada de decisão reside em garantir o menor erro possível na compra do volume energético (MWh) estimado, em relação ao real consumido. Tanto em cenários de venda de excedente de energia (ter estimado mais energia do que consumido) quanto em situações de compra de um volume energético faltante (ter estimado menos energia do que o realizado), o consumidor se expõe a riscos financeiros devido à volatilidade nos preços deste cenário.

Os cenários de potenciais prejuízos financeiros foram detalhadamente abordados, considerando a falha na estimativa do volume de energia, o que pode resultar em transações desvantajosas, influenciadas pelo Preço de Liquidação das Diferenças (PLD) e a taxa SPREAD. As estratégias comerciais foram representadas por topologias específicas, como "Produto Incentivada I5" e "Produto Convencional", cada uma com suas peculiaridades em termos de descontos e vantagens.

A comparação das métricas financeiras, conforme demonstrado nas Figuras 35, 36 e 37, forneceu uma visão abrangente do comportamento e desempenho das

estratégias analisadas. Notavelmente, a topologia de RNA PMC configurada com 3 camadas e 10 neurônios, treinada pelo método de Levenberg Marquardt, mostrou-se como uma ferramenta eficiente para a estimativa de volume energético e a contratação de energia elétrica no ACL.

Diante dos resultados obtidos, este trabalho não apenas valida a eficácia da abordagem proposta, mas também destaca a importância da implementação de estratégias precisas e adaptáveis para o sucesso operacional em um ambiente tão dinâmico quanto o Mercado Livre de Energia.

REFERÊNCIAS

MACHADO, M. História do Mercado Livre de Energia no Brasil. Disponível em:

<<https://copelmercadolivre.com/historia-do-mercado-livre-de-energia-no-brasil/>>.

Acesso em: 11 jun. 2023.

CASADEI, J. O direito de escolher o fornecedor de energia vale bilhões ABRACEEL.

Disponível em: <<https://abraceel.com.br/biblioteca/artigos/2023/03/o-direito-de-escolher-o-fornecedor-de-energia-vale-bilhoes/>>. Acesso em: 11 jun. 2023.

CARTILHA MERCADO LIVRE DE ENERGIA ELÉTRICA. [s.l: s.n.]. Disponível em:

<https://abraceel.com.br/wp-content/uploads/2019/05/ABRACEEL_process_230519.pdf>.

ZANCHETTIN, C.; LUDERMIR, T. B. Sistemas neurais híbridos para reconhecimento de padrões em narizes artificiais. Sba: Controle & Automação Sociedade Brasileira de Automatica, v. 16, n. 2, p. 159–172, jun. 2005.

Redes Neurais Artificiais. Disponível em:

<https://sites.icmc.usp.br/andre/research/neural/>, set. 2016.

ESKADA | Cursos Abertos da UEMA. Disponível em:

<<https://eskadauema.com/mod/book/tool/print/index.php?id=1651>>. Acesso em: 11 jun. 2023.

MATOS, D. Normalização em Machine Learning. Disponível em:

<<https://www.cienciaedados.com/normalizacao-em-machine-learning/>>. Acesso em: 30 out. 2023.

LARSON, RON. e FARBER, BETSY. Estatística Aplicada. Editora Pearson, 4ed. São Paulo, 2009.

ADERALDO, K.; ADEMIR, B.; RIBEIRO, A. O Método de Levenberg-Marquardt para o Problema de Quadrados Mínimos não Linear. [s.l: s.n.]. Disponível em:

<<https://eventos.ufpr.br/smne/SMNE2017/paper/viewFile/548/230>>.

Gonçalves, L. M. G., Gonçalves, W. N., & Silva, L. A. F. (2010). "Uma análise comparativa entre métodos de treinamento de redes neurais artificiais para previsão de séries temporais." Simpósio Brasileiro de Redes Neurais.

FPR, 2019. Disponível em: <<http://cursos.leg.ufpr.br/ML4all/apoio/Gradiente.html>>.

MUKHERJEE, I.; ROUTHROY, S. Comparing the performance of neural networks developed by using Levenberg–Marquardt and Quasi-Newton with the gradient descent algorithm for modelling a multiple response grinding process. Expert Systems with Applications, v.39, p.2397–2407, 2012.

HARRIS, Chris - Electricity markets : pricing, structures and economics. Chichester : John Wiley & Sons, 2006. COTA: 620.9 HAR.

FIRJAN. Disponível em:<<https://www.firjan.com.br/firjan/peq/temas/energia.htm>>.

Acesso em: 12 nov. 2023.

ENGIE. Disponível em:

<https://www.alemdaenergia.engie.com.br/angela-oliveira-mercado-livre-de-energia/#:~:text=Desde%20janeiro%20de%202023%2C%20com,a%20demanda%20de%20500%20kW>.

ANEEL.Regras de Comercialização. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/mercado>>.

Nikola Tesla. Disponível em: <<https://mundoeducacao.uol.com.br/fisica/nikola-tesla.htm#:~:text=Iniciou%20o%20curso%20de%20Engenharia>>. Acesso m: 12 nov. 2023.

SILVA.2020 Disponível em <https://abraceel.com.br/blog/2020/01/quando-surgiu-o-mercado-livre-de-energia-no-brasil/>

FALCÃO, C. I. S. Estudo do mercado livre de energia elétrica. Revista Científica Multidisciplinar Núcleo do Conhecimento, v. 04, n. 08, p. 35–65, 20 ago. 2020.

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

SIMON, H. Redes Neurais Artificiais princípios e prática. 2ed. São Paulo: Bookman, 2000.

BICHELS, Arley. (2018). Sistemas Elétricos de Potência. Métodos de Análise e Solução. Editora da Universidade Tecnológica Federal do Paraná

CCEE. (2012). Cartilha Energia Incentivada Especial Compra e Venda de Energia Elétrica Treinamento Geração Hidráulica.

LIRA Saschiko A. (2004). Análise de Correlação Abordagem Teórica e Construção dos Coeficientes com Aplicações. UTFPR 2004.