

Aplicação Híbrida com Redes Neurais Profundas e Algoritmo Genético para Previsão de Séries Temporais do Sistema de Energia Elétrica Brasileira

1st Thiago Nicolau Magalhães de Souza Conte
Programa de Pós-Graduação em Engenharia Elétrica
Universidade Federal do Pará
Belém, Brasil
thiagonconte@gmail.com

2nd Bruno Nicolau Magalhães de Souza Conte
Programa de Pós-Graduação em Engenharia Elétrica
Universidade Federal do Pará
Belém, Brasil
brunonicolau.conte@gmail.com

3rd Roberto Célio Limão e Oliveira
Programa de Pós-Graduação em Engenharia Elétrica
Universidade Federal do Pará
Belém, Brasil
limao@ufpa.

Abstract— O cenário da energia elétrica no Brasil é influenciado por fatores complexos, além de possuir relações não lineares, o que dificulta sua previsibilidade. Para superar esse problema, propomos uma adaptação baseada na combinação de Redes Neurais Artificiais Profundas e Algoritmo Genético – AG para uso na previsão de algumas séries temporais do setor de energia elétrica brasileira. O AG usa um genótipo binário, de 53 bits, que busca o melhor número de camadas intermediárias, melhor número de células e modificações por Dropout para projetar a estrutura do *Long Short Term Memory* – LSTM e assim aprimorar a previsão. Simulações foram realizadas para verificar o desempenho do método proposto em conjuntos de dados do mundo real: Preço de Liquidação das Diferenças - PLD e Velocidade do Vento de aerogeradores do Nordeste do Brasil. Verificou-se que a combinação do AG e LSTM tem melhores previsões, em comparação com modelo *Perceptron Multicamadas* – MLP. Esses resultados mostram que, a abordagem é de grande utilidade para aprimorar e consolidar práticas voltadas para regulação de setor elétrico com o uso do PLD, e também para conversão da energia eólica para energia elétrica.

Keywords—Deep Learning, prediction, generic algorithm, hybrid algorithm, lstm

I. INTRODUÇÃO

A liberalização do mercado de energia elétrica no mundo tornou este mercado extremamente competitivo [1] e conjuntamente com os avanços, a modernização e melhora da qualidade de vida da sociedade, também há ascensão de forma significativa com os problemas ambientais como Efeito Estufa, Mudanças Climáticas, Poluição do ar, Poluição da água, deflorestação e outros. Devido a este contexto todos os participantes deste mercado tem como desafios e um conjunto de iniciativas articuladas para incrementar a prática de adoção e intervenção de ações harmônica e de forma sustentável. Tendo em vista a realidade da competitividade com o mínimo ou sem impacto sobre a natureza, devemos considerar, até mesmo, como uma das tarefas mais importante a previsão do preço da eletricidade com alta precisão para formular estratégias que lhes permitam licitar e vender energia com o menor risco possível [2]. Tomando-se como ponto de partida a empresa geradora de energia, a concessionária pode formular um plano de licitação preciso, prevendo o preço da eletricidade, de forma a obter maiores lucros; em seguida, após a concessionária, os usuários podem controlar os custos de compra de energia ajustando o consumo de eletricidade por meio da previsão do preço da eletricidade; da perspectiva dos reguladores do mercado, a previsão do preço da eletricidade pode fornecer uma base científica para tornar estável o

mercado [3]. Portanto, o benefício da previsão no contexto energia elétrica algo vital no mercado de eletricidade.

Mais ainda, em vários países ao redor do mundo, tem-se um aumento no uso de energias renováveis com a diminuição gradual das fontes de energia tradicionais. Este recuo se deve principalmente aos efeitos danosos ao ambiente, em muitos casos irreversíveis, e em uma escala sem precedentes na história da humanidade causados pelos combustíveis fósseis e nucleares e também pela redução contínua dos custos das tecnologias renováveis [4]. Uma das principais fontes de energias renováveis é a energia eólica, que vem sendo uma alternativa atrativa no mercado de eletricidade em termos de custos e baixo impacto ambiental [5]. No entanto, a integração da energia eólica aos sistemas elétricos apresenta vários desafios devido à sua incerteza e variabilidade, visto que sua geração depende do vento que tem um comportamento estocástico [6]. Por exemplo, a programação de geração de curto prazo de um sistema elétrico deve fornecer estimativas confiáveis de quanta energia eólica será produzida para obter a seleção ideal de unidades despachadas e os níveis ideais de geração de unidades convencionais [7]. Portanto, ferramentas de previsão que consigam prever o comportamento da geração de energia eólica são críticas para manter o fornecimento de eletricidade economicamente viável e confiável.

Observando-se as organizações mundiais multilaterais como a Organização das Nações Unidas – ONU que lançou estudos com vários objetivos de desenvolvimento sustentável, dentre eles “Assegurar o acesso confiável, sustentável, moderno e a preço acessível à energia para todos” [8], se vê percebe-se que a tarefa de previsão do preço de eletricidade e da geração de energia eólica esta alinhada com este objetivo global.

No Brasil, o cenário do mercado de eletricidade é parecido com o mundial [9], sendo basicamente privado [10], exceto pelas grandes gerações hidráulicas de energia elétrica e suas longas linhas de transmissão [11][12]. Também há um aumento no uso de geração eólica [13], com a região Nordeste do país sendo a grande fonte de energia primária. Dentro deste cenário, também para o mercado brasileiro é importante ter ferramentas de previsão do preço de eletricidade e de energia eólica.

Nos modelos de séries temporais utilizados para previsão deste tipo de informações, diversas pesquisas apontam as técnicas de Rede Neural Artificial Direta e aquelas do tipo *Autoregressive integrated Moving Average* – ARIMA a fim de prever o valor futuro do preço da eletricidade no mercado

brasileiro [14] e a geração eólica [15]. Adicionalmente tem-se poucos trabalhos que usam as Redes Neurais Recorrentes [16].

Os artigos de revisão sobre análise e previsão de séries temporais apontam que a utilização de técnicas de Aprendizagem de Máquina, com uma certa prevalência das *Deep Learning*, é uma das metodologias mais utilizadas [17-18].

Também existe uma tendência na literatura mundial de combinar modelos para conseguir previsões mais precisas [19-20]. Uma destas estratégias é ter um Algoritmo Genético para otimizar a estrutura de uma rede neural profunda feedforward, como por exemplo para prever o consumo de energia de edifícios [21].

Embora existam vários trabalhos na literatura com o uso de Rede Neural e Algoritmo Genético, diferentes formas de utilizar os algoritmos existentes e adaptações de algoritmos são continuamente propostos. Além disso, no mercado brasileiro o uso de um modelo híbrido utilizando Algoritmo Genético e mais Long Short Term Memory (AG+LSTM), que é o modelo proposto nesse trabalho, não é comum na previsão de preços e ventos.

Fundamentado nessas atribuições, este artigo apresenta métodos de previsão do Preço de Liquidação das Diferenças da eletricidade brasileira (PLD, Valor semanal) e da velocidade do Vento em uma região do país (diária). A abordagem é baseada na otimização da estrutura da Rede Neural do tipo *Long Short Term Memory (LSTM)* usando um Algoritmo Genético.

Este artigo esta organizado da seguinte forma: a seção II um breve mapeamento a produção de conhecimento científico sobre o tema do artigo. A seção III descreve a metodologia proposta. Na seção IV apresenta-se os resultados das *baselines*. Na seção V estão os resultados obtidos com a nova abordagem proposta para previsão de series temporais da energia brasileira e, por fim, a seção VI trata das considerações finais.

II. ESTADO DA ARTE

Quanto às abordagens práticas de Machine Learning em séries temporais da energia elétrica brasileira, e em outros países, podem ser citados trabalhos no que concerne a modelagem do Preço de Liquidação das Diferenças e Velocidade do Vento como apresentados a seguir.

Filho, Affonso e Oliveira [14], combinam o método *Autoregressive Integrated Moving Average (ARIMA)* com Redes Neurais Artificiais na previsão dos preços de energia no Mercado brasileiro.

Gokgöz e Filiz [22], apresentam modelos de redes neurais artificiais para o mercado de eletricidade diário na Turquia usando o gradiente descendente, o gradiente descendente com impulso, Broydan, Fletcher, Goldfarb e Shanno (BFGS) e o algoritmo *Levenberg-Marquardt* com número diferente de neurônios e funções de transferência.

Makwana e Gandhi [23], utilizam as Redes Neurais Artificiais do tipo feedforward e algoritmo de ajustes dos pesos igual ao *Levenberg-Marquardt* para previsão de energia eólica. Os resultados da sua modelagem mostram uma melhor previsão do que outros algoritmos de treinamento.

Segundo Dumitru e Gligor [24], as Redes Neurais possibilitam a previsão da energia eólica na zona sudeste da Europa.

Na estratégia de usar algoritmos evolutivos para otimizar a arquitetura da rede neural na tarefa de previsão no mercado de eletricidade, existem trabalhos com redes neurais profundas *feedforward* [25] e com redes neurais profundas recorrentes [15,26]. Entretanto, estas estratégias ainda não foram utilizadas para o mercado brasileiro.

Mais precisamente, a partir da análise do estado da arte em [15][26][17,18] e [21], não existe na literatura um modelo que combine o método *Long Short Term Memory – LSTM* e Algoritmo Genético na tarefa de previsão da geração da energia eólica do Nordeste do Brasil e do preço da eletricidade brasileira.

O diferencial desse trabalho é combinar os pontos fortes das técnicas de aprendizagem de máquina como o Algoritmo Genético, especialmente na representação ou codificação do problema, para encontrar de forma automática um modelo da Rede *Long Short Term Memory (LSTM)* capaz de capturar a natureza não-linear de complexas séries temporais, produzindo previsões mais precisas no mercado de eletricidade do Brasil.

III. METODOLOGIA

O modelo híbrido proposto combina a capacidade do modelo Algoritmo Genético com uma Rede Neural Profunda para previsão do Preço de Liquidação de Diferenças e Velocidade do Vento em até 12 passos à frente, utilizando variáveis explanatórias. A metodologia proposta apresenta duas fases. A fase I (interação do AG), utiliza o Algoritmo Genético para criar/encontrar o modelo neural com condições mais favorável de capacidade de generalização para previsão das séries temporais estudadas. Na fase II (cálculo da Função Fitness), o AG fornece à Rede Neural Artificial Profunda, LSTM, os valores decodificados do cromossomo binário para os hiperparâmetros da rede de forma que seja realizado o processo de aprendizagem. O resultado do aprendizado, após algumas iterações, é devolvido para o AG no valor da Função Fitness. Esse processo, fase I + fase II, perdura até a convergência do AG, que encontra uma configuração ótima para os hiperparâmetros da LSTM. Na Fig.1, mostra-se o esquema de como foi realizado a construção do modelo.

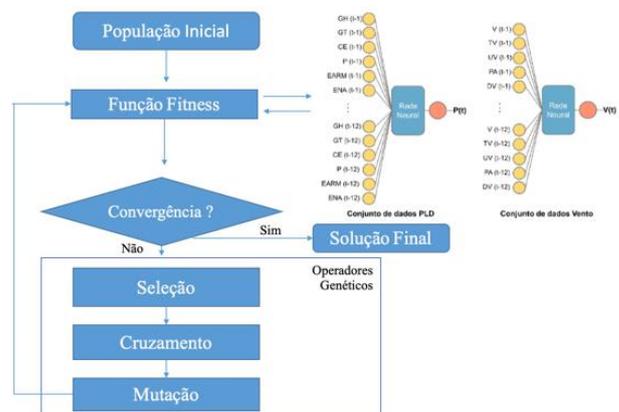


Fig. 1. Combinando Algoritmo Genético e Redes Neurais.

A fase I inicia-se com os indivíduos (genótipos) aleatórios (ver Figura 2), e com todos os valores dos parâmetros

descritos abaixo (seção A). A fase II se dá quando a RNA atinge o menor erro médio quadrático, ou quando é alcançado a quantidade máxima de épocas estabelecidas. Após o treinamento do modelo, faz-se necessário retornar a fase I, o erro que representa a função de avaliação do indivíduo. Essa fase é importante para obter acurácia da série temporal escolhida.

No modelo da série temporal LSTM + AG, a previsão de valores futuros (1, 3, 8 e 12 passos à frente) do sistema elétrico brasileira é estimado. No caso do PLD são estimados média semanal e para velocidade do vento o valor diário. Os resultados obtidos para os dois estudos é realizado com 12 medidas atrasadas das variáveis de entrada e faz a predição k passos à frente da variável de saída.

A. Fase I: Iteração do Algoritmo Genético

O AG utilizado nesse trabalho é o canônico com as características de Elitismo e seleção por Torneio, pois são importantes para o entendimento de propostas de solução baseadas em conceitos evolutivos, bem como para o desenvolvimento de novos Algoritmos Evolutivos [27]. A seguir são apresentados os parâmetros para simulação com o AG utilizados neste trabalho:

- População com 80 indivíduos
- Elitismo: São escolhidos os n melhores indivíduos da população anterior (com n=1).
- Probabilidade de cruzamento: 75% (com dois pontos de corte)
- Mutação: Os genes dos indivíduos podem mudar com uma probabilidade de 1%.
- Seleção: Torneio.
- Indivíduos: são representados genotípicamente por vetores binários totalizando 53 bits, onde o primeiro grupo de três genes determina o número de camadas do modelo neural artificial LSTM e a cada grupo de 10 bits seguintes a estrutura da camada, sendo os primeiros 6 bits para indicar a quantidade de células, variando de 1 à 64, e os 4 bits restantes para definir o *Dropout*, balanceando de 1 à 16%, conforme a Fig. 2.

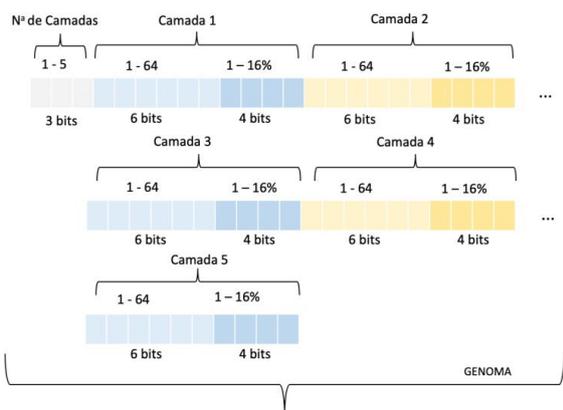


Fig. 2. Indivíduo da população.

B. Fase II: Cálculo da Função Fitness (erro de predição da Long/Short Term Memory – LSTM)

Para calcular o erro da função de avaliação – Fitness, usa-se o Erro Médio Quadrático –MSE de predição do modelo

neural preditor, que neste trabalho é a LSTM. A LSTM é utilizada em virtude de possuir um conjunto especial de características como o estado de célula que funciona como uma correia transportadora onde cuidadosamente as informações fluem [24].

C. Base de Dados e Pré-Processamento

Neste trabalho foram utilizados dois bancos de dados reais: a base de dados do Preço de Liquidação das Diferenças - PLD, do Sistema Nacional Brasileiro, com registros das regiões do Norte, Nordeste, Sul e Sudeste no período de 2001 a 2009, fornecendo um conjunto de 440 amostras semanais para cada Região [28]; e a base de dados de Energia eólica, com informações de dois locais diferentes na região nordeste do Brasil: Macau (latitude 5 ° 9'3.726 "no sul, longitude 36 ° 34 '23.3112" no oeste), e Petrolina (latitude 09 ° 04 '08 "no sul, longitude 40 ° 19' 11" no oeste) no período 01 De junho de 2016 a 31 de maio de 2017 [29], totalizando 4900 amostra cada.

Para a predição do PLD utilizou-se as variáveis: Geração Hidráulica (GH) e Térmica (GT), Carga de Energia (CE), Preço do PLD (P) e Reservatórios EARM e ENA com base na técnica de ranqueamento de variáveis explanatória que avalia o poder preditivo de uma variável individualmente com base em uma função critério. Maiores detalhes sobre a seleção das variáveis são encontradas em Filho et. [14] que descreve e apresenta a seleção das variáveis explanatórias a partir do teste F ANOVA (Análise de Variância).

Para a velocidade do vento de Aerogeradores do Nordeste do Brasil as variáveis são: Velocidade (V), Temperatura do Ar (TA), Umidade do Ar (UA), Pressão Atmosférica (PA) e Direção do Vento (DV). Neste trabalho as séries históricas meteorológicas utilizadas foram inspirado em Alencar [15] onde são obtidas no banco de dados disponibilizado pelo sistema de organização nacional de dados ambientais (SONDA) e o processo de validação dos dados obtidos pela estação SONDA baseia-se na estratégia de controle de qualidade de dados adotada pela Baseline Surface Radiation Network (BSRN) e os dados complementares foram disponibilizados diretamente com técnicos da estação.

As variáveis de entradas utilizadas no treinamento e teste do preditor, para que todos os modelos venham a performar melhor, receberam o pré-processamento da normalização [30], colocando os dados na escala comum de 0 a 1, sem distorcer as diferenças nos intervalos de valores.

Vale ressaltar que em função da preponderância das condições hidrológicas, na demanda de energia, nos preços de combustível, no custo de déficit e na disponibilidade de equipamentos de geração e transmissão no parque de geração brasileiro as variáveis usadas neste artigo têm sido mais comumente examinadas em estudos de previsão [24].

D. Viés de Representação

Sobre a atualização dos pesos das redes neurais, o algoritmo de treinamento utiliza a taxa de aprendizagem adaptativa com o *RMSProp* [31].

Esse otimizador é definido como:

$$E [g^2]_t = 0.9 \cdot E [g^2]_{t-1} + 0.1 \cdot g_t^2, \quad (1)$$

Onde g é o gradiente da função de custo, g_t é o gradiente da função de custo no tempo t , e $E[g^2]_t$, é a média móvel dos

quadrados dos gradientes no tempo x . A atualização dos vetores de parâmetro é dada pela equação:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t, \quad (2)$$

Onde η é a taxa de aprendizagem (valor inicial 0,001), g_t é o gradiente da função de custo no tempo t , $E[g^2]_t$ é a média móvel dos quadrados dos gradientes no tempo t e ϵ é o termo que serve para evitar a divisão por zero.

IV. RESULTADOS BASELINES

Como ponto de referência de modelos estabelecidos e aprovados, as *baselines* mostram o caminho pelo qual a nova abordagem deverá seguir. Dessa forma, as simulações para as *baselines* foram realizadas considerando a Rede Neural Perceptron Multicamadas e Redes Neurais *Long Short Term Memory* com os parâmetros fundamentados em inúmeras pesquisas [17, 20 e 22] que determine a configuração ideal de uma rede neural e seus hiperparâmetros (Ver Tab.I). Além disso, todos os experimentos reportados foram executados em um computador com um processador Intel Core I5, 8 GB de memória RAM e armazenamento SSD de 128 GB e utilizou-se a linguagem de programação Python devido vários motivos, entre eles, de permitir trabalhar com Data Science e Machine Learning. Esta linguagem contém uma biblioteca de rede neural artificial (Keras), onde encontra-se disponíveis as arquiteturas de RNAs e várias métricas para julgar o desempenho do seu modelo. Adicionalmente, o tempo de execução das *baselines* foram em média de uma semana e os híbridos de uma semana e meia.

TABELA I. CONFIGURAÇÕES

Configuração	MLP	LSTM
Atualização dos pesos	Otimizador RMSProp	Otimizador RMSProp
A primeira camada escondida	30 neurônios e método Dropout com 5%;	30 neurônios e método Dropout com 5%;
A segunda camada escondida	25 neurônios e método Dropout com 0%	com 25 neurônios e método Dropout com 0%
A terceira camada escondida com	25 neurônios e método Dropout com 5%	25 neurônios e método Dropout com 5%
A camada de saída	1 neurônio	1 neurônio
Definição manual - épocas para o treinamento	100	100
Função de ativação não-linear em todas as camadas escondidas	“relu”	“relu”
Função de ativação na camada de saída	Linear	Linear

Para validar modelos Neurais, são utilizadas medidas de desempenho estatísticas que mostram o comportamento do modelo em relação aos dados modelados. As medidas utilizadas são Erro Médio Absoluto-MAE, Erro Médio Quadrático -MSE e Raiz do Erro Médio Quadrático-RMSE, pois elas apresentam de forma sólida o comportamento do preditor em torno da média do seu erro de predição, essas funções são definidas como:

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=0}^{n-1} |y_i - \hat{y}_i| \quad (3)$$

$$MSE(y, \hat{y}) = \frac{1}{n} \sum_{i=0}^{n-1} (y_i - \hat{y}_i)^2 \quad (4)$$

$$RMSE(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} (y_i - \hat{y}_i)^2} \quad (5)$$

Onde y_i é o valor de saída correspondente, \hat{y}_i é o valor previsto e n é o número de amostras apresentados aos modelos de Redes Neurais.

Embora existam outras medidas de desempenho, o MSE é considerado mais adequado para problemas de regressão [13].

A. Resultados Baselines para o PLD

A Tab. II reúne os resultados da diferença entre a estimativa das *baselines* e o valor desejado (erro mínimo).

TABELA II. RESULTADOS PARA O PLD

Rede Neural	Nordeste	Norte	Sudeste	Sul
MLP	0.00522	0.00242	0.00278	0.00271
LSTM	0.00725	0.00268	0.00190	0.00847

Como observado na Tab. II, os resultados são satisfatórios e com base nos valores do MSE do PLD por região, quem apresentou melhores resultados foi a rede MLP, exceto na região Sudeste.

Nas Fig. 3.a e 3.b, observam-se a convergência e a previsão do modelo que alcançou o menor MSE geral de predição, apresentado nas Tab. II.

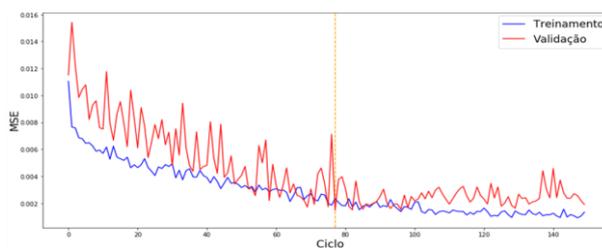


Fig. 3.a. PLD: Convergência da Rede LSTM para a Região Sudeste (eixo x =Ciclo da rede neural; eixo y = MSE; linha tracejada vertical amarela= indica em qual ciclo foi encontrado o melhor modelo de rede neural da validação)

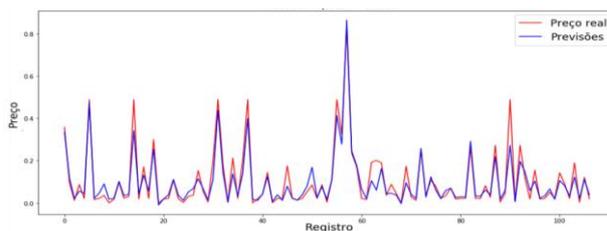


Fig. 3.b. PLD: Previsão da rede LSTM para Região Sudeste (eixo x = Registro; eixo y = Preço)

Na Fig. 3.a fica claro que o erro entre os dados reais (azul) e as previsões (vermelho) tem valores baixos. A fim de obter um bom desempenho usamos o hiperparâmetro *Early Stopping* (“Parada Antecipada” com “min_delta” de $1e-10$), isto é, no final de cada ciclo, calculamos o erro da classificação nos dados de treinamento. Quando a taxa de erro for maior do que o “min_delta” continuamente por um determinado tempo (15 ciclos) interrompemos o treinamento. Por fim a linha tracejada vertical em amarela indica em qual ciclo foi encontrado o melhor modelo de rede neural da validação. Após esse ponto o modelo passa a ter um maior erro de generalização.

B. Resultados Baselines para Velocidade do Vento

A Tab. III reúne os resultados de erro mínimo.

TABELA III. RESULTADOS PARA VELOCIDADE DO VENTO

Rede Neural	Macau	Petrolina
MPL	0.01476	0.00861
LSTM	0.01844	0.00840

Para velocidade do vento a MLP foi melhor na previsão da cidade de Macau e a LSTM foi um pouco melhor na cidade de Petrolina.

V. RESULTADOS DA ABORDAGEM PROPOSTA

A seguir apresenta-se os resultados do desenvolvimento do modelo combinando AG + LSTM. Para fins de comparação com a abordagem proposta foi acrescentado resultados da combinação do AG + MLP.

A. Resultados da Combinação para o PLD

Os resultados da combinação estão especificados na Tab. IV.

TABELA IV. RESULTADOS DA COMBINAÇÃO AG + REDE NEURAL PARA O PLD

Rede Neural + AG	Nordeste	Norte	Sudeste	Sul
MLP + AG	0.00267	0.00183	0.001024	0.00137
LSTM + AG	0.00260	0.001012	0.001015	0.00108

Ao se comparar os resultados da proposição do artigo verifica-se que o modelo com a rede LSTM + AG foram satisfatórios com melhores resultados para o PLD nas quatro regiões.

O resultado da evolução do LSTM + AG para a região Norte é apresentado na Fig. 4 (cor vermelha: curva do melhor indivíduo; cor azul: aptidão média de população por geração).

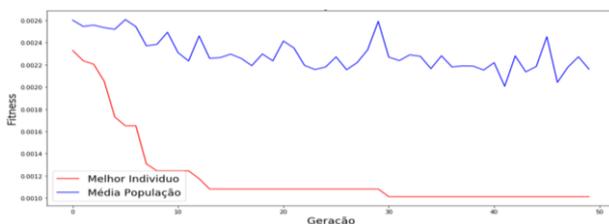


Fig. 4 Configurações ótimas da LSTM para a previsão do PLD da região Norte

Na Fig. 4, pode-se observar que a aptidão da melhor configuração da LSTM melhora rapidamente (o erro de

predição cai rapidamente) e a partir da geração 10 se inicia a convergência do AG para um ponto ótimo do espaço de busca das melhores configurações para a LSTM.

As principais características do melhor modelo ilustrado pela Fig. 4 são resumidas na transcrição do genoma abaixo:

- Transcrição Genoma: [4, 46, 0.01, 57, 0.0, 2, 0.11, 8, 0.03, 0.0010129106749233148].

A melhor solução foi obtida com arquitetura neural das quais 4 camadas escondidas, com 46, 57, 2 e 8 neurônios e com Dropout de 0.01, 0.0, 0.11 e 0.03 respectivamente, correspondendo a um erro previsão de 0.00101.

Com base nos resultados obtidos nos experimentos. A Fig. 5 mostra todos os modelos com os seus erros mínimos mensurados referente ao PLD.

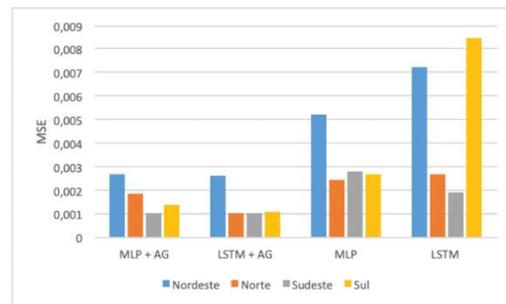


Fig.5 Gráfico do MSE para a Predição do PLD

B. Resultados da Combinação para Velocidade do Vento

Na Tab. V, pode-se observar os resultados do experimento para base de dados velocidade do vento.

TABELA V. RESULTADOS DA COMBINAÇÃO AG + REDE NEURAL PARA A VELOCIDADE DO VENTO

Rede Neural + AG	Macau	Petrolina
MLP + AG	0.01429	0.00808
LSTM + AG	0.01306	0.00815

Para a velocidade do vento, a LSTM + AG também apresentou melhor resultado para a cidade de Macau e tendo um MSE um pouco menor do que a MLP + AG.

A estratégia de utilizar o MLP + AG também apresentou resultados satisfatórios tendo valores de MSE um pouco menor do que a LSTM + AG em Petrolina.

O resultado da evolução do LSTM + AG para a cidade de Macau é apresentado na Fig. 6.

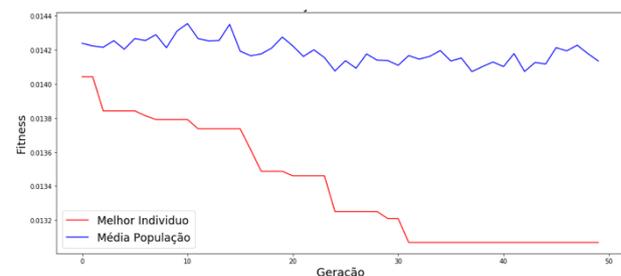


Fig. 6 Configurações ótimas da LSTM + AG para a previsão da Velocidade do Vento - Parque eólico da cidade de Macau.

Pode-se observar na Fig. 6 que desde as primeiras gerações a evolução das melhores configurações para a LSTM é pequena, com a convergência acontecendo um pouco depois da geração 30.

As principais características do melhor modelo ilustrada pela Figura 6 são resumidas na transcrição do genoma abaixo:

- Transcrição Genoma: [5, 5, 0.03, 45, 0.09, 36, 0.14, 63, 0.04, 2, 0.02, 0.01306963224846767]

A melhor solução foi obtida com arquitetura neural das quais 5 camadas escondidas, com 5, 45, 36, 63 e 2 neurônios e com Dropout de 0.03, 0.09, 0.14, 0.04 e 0.02 respectivamente, correspondendo a um erro previsão de 0.01306.

A Fig. 7 apresenta os resultados obtidos (erro mínimo) dos modelos para Velocidade do Vento respectivamente.

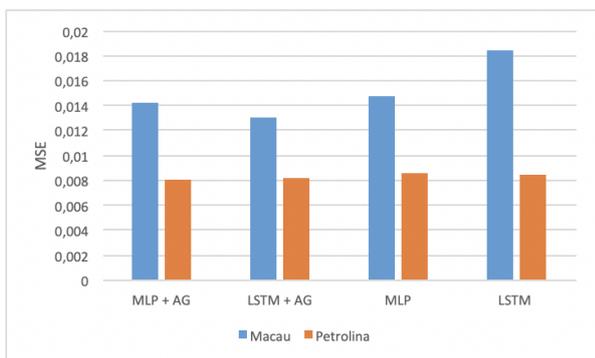


Fig. 7 Gráfico do MSE para a previsão da Velocidade do Vento

C. Resultados da Combinação em até 12 passos a frente

Os resultados obtidos com os modelos híbridos são precisos para 1 passo à frente, isto é, para o PLD previsão de 1 semana e para a velocidade do vento de 1 dia.

As análises dos resultados demonstram que os modelos combinados são alternativas mais eficientes que os preditores atuando de maneira isolada.

De modo a auxiliar na avaliação da capacidade de previsão e seguindo as diretrizes da Agência Nacional de Energia Elétrica (ANEEL) em que as distribuidoras são autorizadas a estimarem valores por até 3 meses consecutivos ou permitir a comparação dos diferentes horizontes (passos) de previsão e assim possibilitar verificar qual horizonte tem melhor resposta para cada modelo proposto.

A seguir são apresentados os resultados em até 12 passos à frente.

1) PLD:12 passos a frente

A Tabela VI apresenta os resultados do modelo AG + LSTM quanto ao critério do erro médio quadrático- MSE para região Norte.

TABELA VI. MSE PARA ATÉ 12 PASSOS A FRENTE DE PREDIÇÕES DA REGIÃO NORTE

Região Norte	1 passo	3 passos	8 passos	12 passos
AG+ LSTM	0.00101	0.00217	0.00165	0.00174
AG + MLP	0.00183	0.00229	0.00160	0.00199

Os resultados mostram que o modelo híbrido proposto apresenta menor erro para os 1, 3 e 12 passos. Além disso, o desempenho dos modelos comparados se deteriora conforme o horizonte temporal de previsão aumenta. No entanto, o horizonte de tempo de 12 semanas está à frente mais apropriado para arriscar práticas de gestão no mercado brasileiro.

2) Velocidade do Vento: 12 passos a frente

A Tabela VII apresenta os resultados obtidos com o modelo AG + LSTM para a base de dados Macau.

TABELA VII. MSE PARA ATÉ 12 PASSOS A FRENTE DE PREDIÇÕES DA CIDADE MACAU

Cidade Macau	1 passo	3 passos	8 passos	12 passos
AG + LSTM	0.01306	0.02402	0.02209	0.02305
AG + MLP	0.01429	0.02606	0.02301	0.02520

O comportamento do modelo híbrido também foi testado em horizontes temporais superiores para cidade de Macau. Os resultados mostram que a técnica híbrida proposta é o melhor modelo para todos os passos.

VI. CONSIDERAÇÕES FINAIS

Este trabalho apresentou uma análise experimental dos modelos híbrido AG + LSTM como proposta de solução para previsão de séries temporais do sistema energia elétrica brasileiro, especificamente o preço de liquidação das diferenças e velocidade do vento de aerogeradores do Nordeste, de modo a oferecer um método alternativo e eficiente para o mercado do Brasil.

No estudo definiu-se uma previsão por MLP como a *baseline* para fins de comparação inicial do desempenho dos modelos utilizados.

Em caráter complementar, analisou-se o uso da previsão de 3, 8 e 12 passos à frente com objetivo de se criar cenários em até 3 meses à frente, permitindo a elaboração de uma estratégia de compra/venda de energia no mercado brasileiro e a previsão da velocidade do vento para semanas também é importante para decisões como panejamento da manutenção, gestão da operação e outros.

Utilizou-se da técnica de otimização evolutiva, no caso o Algoritmo Genético, para definir a melhor topologia das redes neurais artificiais utilizadas. Também utilizou-se a técnicas de validação cruzada com método *Holdout* e critério de parada antecipada com a funcionalidade *Early Stopping* na fase de treinamento das redes neurais.

Os resultados obtidos com a metodologia proposta são comparados com técnicas como MLP, LSTM e MLP + AG e o método proposto superam essas técnicas.

A abordagem com o Algoritmo Genético para encontrar os melhores hiperparâmetros da rede *Long Short Term Memory* apresentou bons resultados para previsão de series temporais do mercado de energia brasileira.

Finalmente, a definição dos parâmetros do Algoritmo Genético (Taxa de mutação, Taxa de cruzamento, tamanho da população, número máximo de gerações, etc) foi baseada na

revisão bibliográfica realizada e em alguns testes de tentativa e erro.

Da revisão bibliográfica do estado da arte da formação de preços no mercado de energia elétrica no Brasil, constatou-se que existem poucos estudos sobre mercado brasileiro, que abrangem modelos de LSTM + AG que avalie as variáveis preditivas para previsão de preços de energia elétrica.

REFERENCES

- [1] N. Francesco, V. Francesco, Energy market liberalization and renewable energy policies in OECD countries. *Energy Policy*, vol. 128(C), pp. 853-867, 2019. (<https://doi.org/10.1016/j.enpol.2019.01.018>).
- [2] G. Huerta Iranzo, Analysis and Prediction of the Negative Prices on the German Spot Power Market. Master's Thesis, UNIVERSIDAD PONTIFICIA COMILLAS Madrid, 2019.
- [3] J. Contreras (Ed.), *Forecasting Models of Electricity Prices*. Mdpi AG, 2017. (<https://doi.org/10.3390/books978-3-03842-414-7>).
- [4] W. Y. Chang, A Literature Review of Wind Forecasting Methods. *Journal of Power and Energy Engineering*, vol. 2, pp. 161-168, 2014. (<http://dx.doi.org/10.4236/jpee.2014.24023>).
- [5] T. S. Schmidt, R. Born and M. Schneider. Assessing the costs of photovoltaic and wind power in six developing countries. *Nature Climate Change*, vol. 2, pp. 548-553, 2012. (<https://doi.org/10.1038/nclimate1490>).
- [6] D. Gielenac, F. Boshell, D. Saygin, M. Bazilian, N. Wagner and R. Gorini, The role of renewable energy in the global energy transformation. *Energy Strategy Reviews*, vol. 24, pp. 38-50, 2019. (<https://doi.org/10.1016/j.esr.2019.01.006>).
- [7] Y. Xie, C. Liu, Q. Wu, K. Li, Q. Zhou and M. Yin, Optimized dispatch of wind farms with power control capability for power system restoration. *Journal of Modern Power Systems and Clean Energy*, vol. 5, pp. 908-916, 2017. (<https://doi.org/10.1007/s40565-017-0341-9>).
- [8] ONU Homepage, <https://nacoesunidas.org/onu-e-parceiros-lancam-estudo-sobre-progressos-no-setor-de-energia>, last accessed 2020/05/06.
- [9] L. Rosa, N. Silva, M. Pereira and L. Losekann, The Evolution of Brazilian Electricity Market, Evolution of Global Electricity Markets New Paradigms, New Challenges, New Approaches (Fereidoon P. Sioshansi, Ed.), pp. 435-459, 2013. (<https://doi.org/10.1016/B978-0-12-397891-2.00015-8>).
- [10] A. Campos, N. Silva, M. Pereira and R. Siman, Deregulation, flexibilization and privatization: historical and critical perspective of the brazilian electric sector. *The Electricity Journal*, vol. 22, pp.106-796, 2020. (<https://doi.org/10.1016/j.tej.2020.106796>).
- [11] E. Kayo, R. Martelanc, E. Brunaldi and W. Silva, Capital asset pricing model, beta stability, and the pricing puzzle of electricity transmission in Brazil. *Energy Policy*, vol. 142, pp. 111-485, 2020. (<https://doi.org/10.1016/j.enpol.2020.111485>).
- [12] D. Romero, E. Almeida and L. Losekann, Systemic value of electricity sources – What we can learn from the Brazilian experience?. *Energy Policy*, vol. 138, pp. 111-247, 2020. (<https://doi.org/10.1016/j.enpol.2020.111247>).
- [13] A. L. Bradshaw. *Electricity Market Reforms and Renewable Energy: The Case of Wind and Solar in Brazil*. PhD Thesis, Columbia University, USA, 2018.
- [14] J. Filho, C. Affonso and R. Oliveira, Energy price prediction multi-step ahead using hybrid model in the Brazilian market. *Electric Power Systems Research*. vol. 117, pp. 115-122, 2014.
- [15] D. Alencar, Modelo Híbrido Baseado em Séries Temporais e Redes Neurais para Previsão da Geração de Energia Eólica. In: Programa em Pós-Graduação em Engenharia Elétrica, pp. 20-24. Universidade Federal do Pará, Belém (2018).
- [16] F. Junior, Redes Neurais Diretas e Recorrentes na Previsão de Energia Elétrica de Curto Prazo no Mercado Brasileiro. In: Programa em Pós-Graduação em Engenharia Elétrica, pp. 17-18. Universidade Federal do Pará, Belém (2016).
- [17] A. Ozcanli, F. Yaprakdal and M. Baysal, Deep learning methods and applications for electrical power systems: A comprehensive review, vol. 44, pp. 7136-7157, 2020. (<https://doi.org/ez3.periodicos.capes.gov.br/10.1002/er.5331>).
- [18] T. Hong, P. Pinson, Y. Wang, R. Weron, D. Yang and H. Zareipour, Energy Forecasting: A Review and Outlook, *IEEE Open Access Journal of Power and Energy*, Early Access Article, 2020. (DOI: 10.1109/OAJPE.2020.3029979)
- [19] O. Abedinia, M. Lotfi, M. Bagheri, B. Sobhani, M. Shafie-khah and J. Catalão, Improved EMD-Based Complex Prediction Model for Wind Power Forecasting. *IEEE Transactions on Sustainable Energy*, vol. 11, pp. 2790-2802, 2020. (DOI 10.1109/TSTE.2020.2976038)
- [20] A. Heydari, M. Nezhad, E. Pirshayan, D. Garcia, F. Keynia and L. De Santoli, Short-term electricity price and load forecasting in isolated power grids based on composite neural network and gravitational search optimization algorithm, *Applied Energy*, vol. 277, pp. 115-503, 2020. (<https://doi.org/10.1016/j.apenergy.2020.115503>).
- [21] X. Luo, L. Oyedele, A. Ajayi, O. Akinade, J. Delgado, H. Owolabi and A. Ahmed, Genetic algorithm-determined deep feedforward neural network architecture for predicting electricity consumption in real buildings. *Energy and AI*, vol. 2, 2020. (<https://doi.org/10.1016/j.egyai.2020.100015>).
- [22] F. Gokgoz and F. Filiz, Electricity price forecasting in Turkey with artificial neural network models. *Investment Management and Financial Innovation*. vol. 13, pp. 150-158. 2016.
- [23] A. Makwana and P. Gandhi, Day-Ahead Wind Energy Forecasting Using Feed Forward Neural Network. *Proceedings of the International Conference on Intelligent Systems and Signal Processing*, 2018, Springer, pp. 221-233.
- [24] C. Dumitru and A. Gligor, Daily Average Wind Energy Forecasting Using Artificial Neural Networks. *Procedia Engineering*, vol. 181, pp. 829-836, 2017. (ISSN 1877-7058)
- [25] X. Luo, L. Oyedele, A. Ajayi, O. Akinade and J. Delgado, Hakeem A. Owolabi, Ashraf Ahmed, Genetic algorithm-determined deep feedforward neural network architecture for predicting electricity consumption in real buildings. *Energy and AI*, vol. 2, 2020. (<https://doi.org/10.1016/j.egyai.2020.100015>).
- [26] C. Sweeney, R. Bessa, J. Browell and P. Pinson, The future of forecasting for renewable energy. *WIREs Energy and Environment*, vol. 9, 2020. (<https://doi.org/10.1002/wene.365>).
- [27] X. Yang, *Nature-Inspired Optimization Algorithms*, 2nd Edition (Paperback), Academic Press, 2021.
- [28] CCEE Homepage, <https://www.ccee.org.br>, last accessed 2020/05/06.
- [29] SONDA Homepage, <http://sonda.ccst.inpe.br/basedados/>, last accessed 2020/05/06.
- [30] M. Puheim and L. Madarász, Normalization of inputs and outputs of neural network based robotic arm controller in role of inverse kinematic model. *IEEE 12th International Symposium on Applied Machine Intelligence and Informatics (SAMII)*, January, Herl'any, Slovakia, 2014. (DOI: 10.1109/SAMI.2014.6822439)
- [31] Z. Fangyu, L. Shen, Z. Jie, W. Zhang and W. Liu. A Sufficient Condition for Convergences of Adam and RMSProp. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, June, Long Beach, CA, USA, 2019. (DOI: 10.1109/CVPR.2019.01