

Uso de Modelo Híbrido de Aprendizado de Máquina e Otimização por Meta-heurística para Predição de Consumo de Energia Elétrica e Produtividade em Pintura Automotiva

Using a Hybrid Model of Machine Learning and Meta-heuristic Optimization to Predict Electricity Consumption and Productivity in Automotive Painting

Rafael Oliveira¹

 orcid.org/0009-0005-8841-763X

Roberto Célio Limão Oliveira¹

 orcid.org/0000-0002-6640-3182

Alexandre M. A. Maciel²

 orcid.org/0000-0003-4348-9291

¹Instituto de Tecnologia, Universidade de Federal do Pará, Pará, Brasil. E-mail: rafaelbarbosa.oliveira@upe.br

²Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife, Brasil.

DOI: [10.25286/rep.v9i3.2809](https://doi.org/10.25286/rep.v9i3.2809)

Esta obra apresenta Licença Creative Commons Atribuição-Não Comercial 4.0 Internacional.

Como citar este artigo pela NBR 6023/2018: Rafael Oliveira; Roberto Célio Limão Oliveira; Alexandre M. A. Maciel. Uso de Modelo Híbrido de Aprendizado de Máquina e Otimização por Meta-heurística para Predição de Consumo de Energia Elétrica e Produtividade em Pintura Automotiva. Revista de Engenharia e Pesquisa Aplicada, v.9, n. 3, p. 35-44, 2024.

RESUMO

Este artigo busca prever o consumo energético (CE) e maximizar a produtividade na pintura automotiva, utilizando uma abordagem que combina seleção de variáveis, modelos híbridos, hiperparâmetros destes modelos e otimização por meta-heurística em uma arquitetura com 3 *steps*. Os processos de pintura automotiva apresentam variáveis em forma de séries temporais que descrevem o histórico do CE. No *step 1*, escolhe-se o melhor modelo de aprendizado de máquina (RF, LSTM, XGBoost e GRU-LSTM) para prever séries temporais do CE em $t+1$. No *step 2*, avalia-se os modelos RF, XGBoost e RNA Densa para selecionar o melhor preditor de quantidade de veículos produzidos (ciclos). No *step 3*, seleciona-se a melhor meta-heurística entre GA, DE e PSO para otimizar o CE previsto pelo melhor modelo do *step 1*, usando como medida de fitness o melhor modelo do *step 2*. A arquitetura final reduz os valores utilizados como amostra para o CE em até 16,5% e aumenta o ciclo em 127%, usando os modelos GRU-LSTM no *step 1*, RNA Densa no *step 2* e DE no *step 3*. Os resultados ressaltam a oportunidade de uso da abordagem proposta para otimizar o CE e a produtividade na pintura automotiva.

PALAVRAS-CHAVE: Energia; Manufatura; Pintura Automotiva; Aprendizado de Máquina; Meta-heurística; Modelo Híbrido.

ABSTRACT

This article seeks to predict energy consumption (EC) and maximize productivity in automotive painting, using an approach that combines variable selection, hybrid models, hyperparameters of these models and meta-heuristic optimization in a 3-step architecture. Automotive painting processes have variables in the form of time series that describe the history of the EC. In step 1, the best machine learning model is chosen (RF, LSTM, XGBoost and GRU-LSTM) to predict EC time series at $t+1$. In step 2, the RF, XGBoost and Dense ANN models are evaluated to select the best predictor of the number of vehicles produced (cycles). In step 3, the best metaheuristic between GA, DE and PSO is selected to optimize the EC predicted by the best model from step 1, using the best model from step 2 as a fitness measure. The final architecture reduced the EC by up to 16,5% and increased the cycle by 127%, using the GRU-LSTM models in step 1, Dense ANN in step 2 and DE in step 3. The results highlight the opportunity to use the proposed approach to optimize EC and productivity in automotive painting.

KEYWORDS: Energy; Manufacturing; Automotive Painting; Machine Learning; Metaheuristic; Hybrid Model.

1 INTRODUÇÃO

Na indústria automotiva, onde a eficiência é crucial para a competitividade em um mercado em constante evolução, o consumo de energia emerge como uma preocupação estratégica de grande relevância. As oficinas de pintura representam uma parcela significativa do consumo de energia em fábricas automotivas, muitas vezes variando de 50% a 70% do consumo total de produção [1]. Especificamente, a eletricidade e o gás natural surgem como os principais vetores energéticos consumidos ao longo dos diversos estágios do processo de pintura, que incluem desde o pré-tratamento da superfície até a fase de secagem e cura do revestimento [2].

A otimização do consumo de energia na pintura automotiva é crucial para reduzir custos e o impacto ambiental, promovendo a sustentabilidade e competitividade do setor.

1.1 DESCRIÇÃO DO PROBLEMA

A previsão e gestão do consumo de energia em oficinas de pintura automotiva são impactadas pela complexidade dos processos e pela falta de dados precisos sobre os fatores que influenciam o consumo. Contudo, o crescente interesse no desenvolvimento de modelos de previsão de consumo de energia, utilizando métodos de Aprendizado de Máquina (do inglês *Machine Learning* - ML), Aprendizado Profundo (do inglês *Deep Learning* - DL) [3] e de algoritmos metaheurísticos para otimizar o resultado desses modelos oferece oportunidades para aprimorar a eficiência energética e operacional na indústria automotiva.

A utilização dos modelos de ML ou DL como *learning fitness functions* (aprendizado como função de aptidão) nos algoritmos metaheurísticos potencializa ainda mais a busca por soluções eficazes. [4].

Estudos têm aplicado técnicas como a Floresta Aleatória (do inglês *Random Forest* - RF) [5] e XGBoost [6] na previsão do consumo de energia na indústria. RF é uma técnica de ensemble que utiliza múltiplas árvores de decisão para realizar previsões mais robustas. O XGBoost, baseado em árvores de decisão, constrói iterativamente várias árvores para corrigir os erros das anteriores.

Em DL, modelos baseados em redes neurais recorrentes, como a rede neural Memória de longo prazo (do inglês *Long Short Term Memory* - LSTM),

têm sido amplamente utilizados devido à sua capacidade de capturar padrões temporais complexos nos dados de consumo de energia [7]. Além disso, abordagens híbridas que incluem o framework Prophet e Rede Neural Recorrente (do inglês *Recurrent Neural Network* - RNN) têm se mostrado promissoras em análises baseadas em séries temporais [8], resultando em previsões mais precisas e insights mais profundos sobre o comportamento do consumo de energia em oficinas de pintura [9].

1.2 JUSTIFICATIVA

A previsão do consumo energético na indústria automotiva permite otimizar processos, reduzir custos e programar operações de alta demanda, como a secagem em oficinas de pintura [10].

Os estudos sobre sustentabilidade na indústria automotiva destacam a crescente importância desse tema, revelando tanto desafios quanto oportunidades para as empresas do setor.

Szász et al. [11] e Lukin et al. [12] destacam a crescente importância da sustentabilidade na indústria automotiva e a busca por estratégias para cumprir os objetivos de desenvolvimento sustentável da ONU. Portanto, é necessário um estudo que otimize o consumo energético e ciclo de produção na indústria automotiva, visando eficiência energética, sustentabilidade e eficiência operacional.

1.3 OBJETIVOS

Este trabalho tem como objetivo prever o consumo energético e maximizar o ciclo de produção em um ambiente de pintura automotiva a partir de uma arquitetura de 3 *steps*, utilizando técnicas de ML, DL e algoritmos meta-heurísticos.

2 FUNDAMENTAÇÃO TEÓRICA

Esta fundamentação teórica fornece base sólida para identificar o estado da arte da análise do consumo energético em oficinas de pintura automotiva e apresentar as técnicas utilizadas na metodologia a partir de

2.1 TRABALHOS RELACIONADOS

Pesquisadores exploram técnicas como mineração de dados, ML e DL para otimizar o

consumo energético em oficinas de pintura automotiva. Cavalcante et al. [13] propôs uma metodologia para ajustar o modelo matemático capaz de prever o comportamento do processo de cura de tintas, determinando coeficientes de transferência de calor com base em dados industriais, com os resultados indicando o modelo como uma ferramenta promissora para desenvolver estratégias de otimização operacional, além de minimizar retrabalhos e custos de energia.

Lu et al. [9] traz uma abordagem baseada em ML híbrida, onde o modelo Prophet ajusta as características cíclicas e de tendência dos dados, o EEMD (*Ensemble Empirical Mode Decomposition*) decompõe os resíduos e melhora a sensibilidade do modelo, enquanto a LSTM captura as características temporais dos dados. Os resultados experimentais evidenciaram o alto desempenho preditivo do modelo Prophet-EEMD-LSTM, com valor médio de R^2 0,94006.

Hovgard [14] investigou a redução do uso de energia em estações robóticas em linhas de produção automotiva por meio de otimização estocástica, resultando em redução de até 23% do consumo de energia sem grande impacto na variação do tempo de ciclo de produção. Indo além da indústria automotiva, Ilbeigi et al. [15] propôs um método para otimizar o consumo de energia em edifícios por meio de uma abordagem que combina modelagem com o software EnergyPlus, uma rede neural artificial (RNA) e otimização com Algoritmo Genético (do inglês *Genetic Algorithm* - GA). Os resultados demonstram uma redução de cerca de 35% no consumo de energia após a otimização do sistema.

A maioria das pesquisas sobre previsão de consumo energético busca modelos preditivos para otimizar a relação entre oferta e demanda. Por outro lado, na otimização do consumo de energia, os estudos se concentram na resolução de problemas de otimização, buscando insumos ideais para melhorar a eficiência energética [16].

Essas abordagens inovadoras melhoram a eficiência energética e a sustentabilidade no setor. Esta pesquisa se diferencia por aplicar uma arquitetura de 3 etapas integrando ML, DL e algoritmos metaheurísticos para buscar ainda mais otimizar o consumo de energia.

2.2 MODELO HÍBRIDO GRU-LSTM

À medida que a complexidade da modelagem de sequências aumenta, surge a necessidade de abordagens mais eficazes. Entre as técnicas exploradas estão as RNNs, e suas variantes Unidade Recorrente Fechada (do inglês *Gated Recurrent Unit* - GRU) e LSTM. Embora eficazes em dados sequenciais, GRUs e LSTMs apresentam limitações: GRUs oferecem maior eficiência computacional, mas podem ter dificuldade em capturar dependências de longo prazo, enquanto LSTMs, apesar de mais poderosas nesse aspecto, demandam maior custo computacional. [17][18].

A integração de GRU e LSTM visa criar um modelo eficiente e capaz de capturar informações relevantes. A GRU filtra informações capturando padrões de curto prazo, que são passadas para a LSTM as integrar ao contexto histórico para modelagem precisa de sequências complexas.

No contexto da previsão de consumo de energia em oficinas de pintura automotiva, uma arquitetura híbrida com GRU e LSTM, assim como em outras produções científicas semelhantes, pode ajudar a capturar tanto os padrões de consumo de curto prazo, relacionados a flutuações diárias ou semanais, quanto as tendências de longo prazo, associadas a mudanças sazonais ou de produção [19][20].

2.2.1 Memória de Longo Prazo

A LSTM foi introduzida pela primeira vez por Sepp Hochreiter e Jurgen Schmidhuber em 1997 [21]. É um tipo especializado de RNN desenvolvida para lidar com sequências de dados e capturar dependências temporais de longo prazo. Em comparação com redes neurais tradicionais, as LSTMs possuem uma arquitetura mais complexa, incorporando unidades de memória interna chamadas de células. Essas células são capazes de armazenar informações ao longo do tempo e controlar o fluxo de informações na rede, permitindo que as LSTMs mantenham e atualizem estados de memória por longos períodos.

Uma célula LSTM os seguintes componentes: uma porta de entrada i_t , porta de esquecimento f_t , porta de saída o_t , estado de célula candidata \hat{c}_t , estado de célula c_t e um estado oculto h_t , dado pelas Equações (1), (2), (3), (4), (5) e (6), respectivamente. A função da porta de entrada é determinar quais informações devem ser armazenadas no estado de célula atual, enquanto

a porta de esquecimento identifica as informações que devem ser descartadas. Por fim, a porta de saída determina quais informações serão transmitidas para o estado oculto atual.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (1)$$

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3)$$

$$\hat{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$c_t = f_t * c_{t-1} + i_t * \hat{c}_t \quad (5)$$

$$h_t = o_t * \tanh(c_t) \quad (6)$$

Onde W_x e b_x representam a matriz de pesos e o vetor de *bias* de cada equação, respectivamente.

2.2.2 Unidade Recorrente Fechada

GRU é uma arquitetura que pertence à família das RNNs. Assim como a LSTM, a GRU é projetada para lidar com problemas de sequência, onde a entrada ou saída é uma sequência de dados, como em tradução de texto, previsão de séries temporais, entre outros. A GRU possui duas portas principais: update gate e reset gate. A update gate controla quanto do estado anterior deve ser mantido e quanto do novo estado proposto deve ser adicionado. Enquanto isso, a reset gate decide quanto do estado anterior deve ser esquecido.

Essas portas permitem que a GRU aprenda a memorizar informações importantes de maneira mais eficiente do que as RNNs tradicionais. Além disso, as GRUs tendem a ser mais fáceis de treinar e mais eficientes computacionalmente, pois possuem menos parâmetros.

2.3 ALGORITMOS META-HEURÍSTICOS

Meta-heurísticas são abordagens de resolução de problemas de otimização que não garantem a solução ótima, mas buscam encontrar boas soluções em um tempo computacionalmente viável. Essas técnicas exploram o espaço de busca de forma genérica e adaptativa, sendo aplicáveis a uma variedade de problemas complexos [22].

2.3.1 Otimização por Enxame de Partículas

A Otimização por Enxame de Partículas (do inglês *Particle Swarm Optimization* - PSO) é uma

técnica de otimização computacional baseada em simulação de enxame, inspirada no comportamento de pássaros e cardumes de peixes. A ideia central do PSO é simular o comportamento de um grupo de partículas, cada uma representando uma solução candidata para o problema de otimização. Cada partícula se move pelo espaço de busca, ajustando sua posição e velocidade de acordo com seu próprio histórico de desempenho e o desempenho do grupo como um todo [23].

A atualização da velocidade $v_{id}(t+1)$ de uma partícula i de dimensão d , na iteração $t+1$ é calculada pela equação 9 e sua posição $x_{id}(t+1)$ é dada pela equação 10.

$$L(t) = c_1 \cdot r_1 \cdot (p_{id} - x_{id}(t)) \quad (7)$$

$$G(t) = c_2 \cdot r_2 \cdot (p_{gd} - x_{id}(t)) \quad (8)$$

$$v_{id}(t+1) = w \cdot v_{id}(t) + L(t) + G(t) \quad (9)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (10)$$

Onde w é o coeficiente de inércia, c_1 e c_2 são os coeficientes que controlam a influência do melhor valor pessoal e global, respectivamente, r_1 e r_2 são números aleatórios entre 0 e 1, p_{id} e p_{gd} são as melhores posições já alcançadas pela partícula i e pelo enxame até o momento, respectivamente. $v_{id}(t)$ e $x_{id}(t)$ descrevem a velocidade e a posição da partícula i na dimensão d na iteração atual t , respectivamente.

2.3.2 Evolução Diferencial

O algoritmo Evolução Diferencial (do inglês *Differential Evolution* - DE) é um método de otimização baseado em população, inspirado no processo de evolução natural. Opera em uma população de vetores, onde cada vetor representa uma solução candidata para o problema de otimização em questão [24].

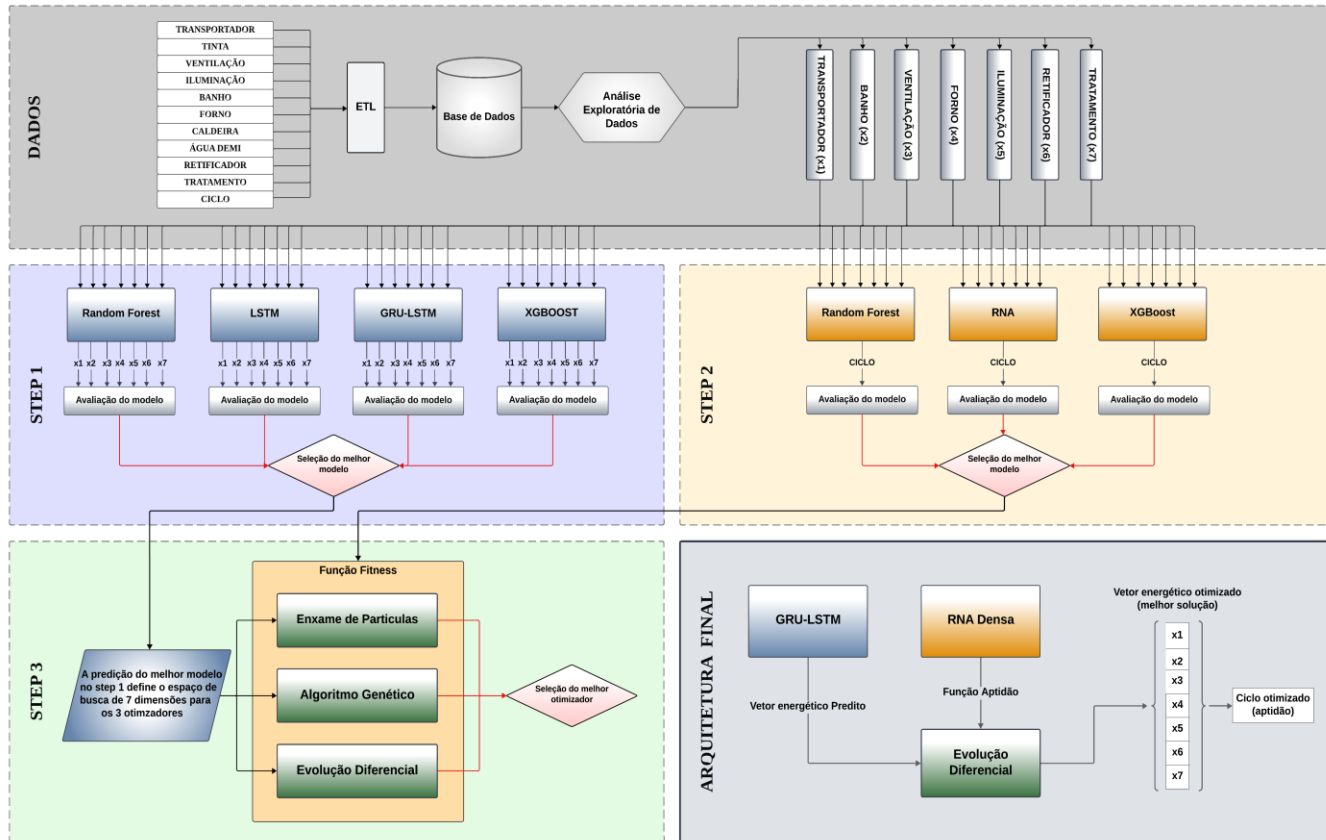
O algoritmo começa gerando aleatoriamente uma população inicial de soluções (vetores) candidatas dentro do espaço de busca. Cada vetor passa por uma mutação diferencial, onde um vetor mutante é gerado combinando diferenças ponderadas entre três vetores selecionados aleatoriamente da população. A mutação é realizada pela seguinte equação:

$$v_i = x_{r1} + F \cdot (x_{r2} - x_{r3}) \quad (11)$$

Onde v_i é o novo vetor mutante gerado para o indivíduo i na geração g , x_{r1} , x_{r2} e x_{r3} são três

3.1 BASE DE DADOS E PRÉ-PROCESSAMENTO

Figura 1 - Arquitetura de três steps



Fonte Autores

vetores distintos selecionados aleatoriamente da população atual, exceto o próprio indivíduo i . F é um parâmetro de controle chamado de fator de escala, que controla o grau de perturbação aplicado à diferença entre os vetores selecionados.

Na etapa de cruzamento, vetores mutantes são combinados com os vetores originais. Em seguida, na seleção, os novos vetores resultantes são avaliados em relação aos originais. Se um vetor mutante for melhor, substitui o original na próxima geração, caso contrário, o vetor original é mantido. O DE segue os passos de mutação, cruzamento e seleção por várias gerações até que um critério de parada seja atingido.

3 MATERIAL E MÉTODOS

As especificações dos modelos, dados e métricas utilizados na pesquisa estão descritos a seguir.

O *dataset* desta pesquisa é o mesmo utilizado no estudo de Oliveira et al. [25] e suas características são:

- Extração, Transformação e Carga (do inglês *Extract, Transform and Load* - ETL) de bases de dados - Dados de energia e de produção de veículos.
- As variáveis de entrada nos modelos deste estudo são os processos da oficina de pintura, contendo dados de kWh.
- As variáveis de saída do *step 1* são as 7 variáveis de entrada em $t+1$ e para os modelos do *step 2* é o ciclo (produtividade de veículos na oficina de pintura).
- As amostras foram registradas com intervalos de 15 minutos.
- Período dos dados coletados para treino e teste é de janeiro a setembro de 2023.
- Os valores ausentes na variável "ciclos", foram interpretados e substituídos por zero,

conforme orientação do stakeholder.

Para a seleção de variáveis, optou-se por remover as três variáveis do banco de dados após a Análise Exploratória de Dados (do inglês *Exploratory Data Analysis* - EDA) (Figura 1) que possuem os valores de menor correlação, com base na correlação de Pearson. Assim, foram removidas as variáveis caldeira, água demi e tinta. Todas as análises realizadas neste estudo foram conduzidas com o conjunto de dados contendo sete variáveis de kWh e uma variável de ciclos.

3.2 METODOLOGIA PROPOSTA

Propõe-se uma arquitetura de três *steps* para prever o consumo energético e maximizar o ciclo de produção em um instante de tempo $t+1$, utilizando técnicas de ML, DL e algoritmos meta-heurísticos de otimização. A abordagem deste trabalho propõe a avaliação de pelo menos três modelos em cada *step*, aquele que apresentar o melhor desempenho irá compor a arquitetura. A Figura 1 apresenta a arquitetura que implementa os três *steps* e seus respectivos modelos [25].

Os Steps 1 e 2, embora façam parte de uma sequência lógica, podem ser vistos como duas previsões independentes. Isso significa que, na prática, eles podem ocorrer simultaneamente ou em qualquer ordem, sem comprometer a eficácia da arquitetura proposta. Essa flexibilidade permite otimizar o tempo de processamento e adaptar a abordagem às necessidades específicas de cada aplicação. Os modelos RF, LSTM, XGBoost e GA utilizados nestes trabalhos foram replicados conforme estado a arte e os experimentos realizados por Oliveira et al. [24].

3.2.1 Step 1 - Predição do consumo energético


Este *step* consiste em prever o consumo de energia em determinado período a partir dos dados históricos, utilizando técnicas de análise de séries temporais, além dos modelos implementados por Oliveira et al. [25], utilizou-se o modelo híbrido GRU-LSTM como nova proposta de implementação tendo como fundamentação os resultados promissores obtidos em estudos referenciados neste trabalho. A arquitetura do modelo GRU-LSTM conta com uma camada GRU, uma camada LSTM e duas camadas RNA Densas, definidas a partir de experimentações e ajustes em busca de melhores resultados e custo computacional otimizado.

Os modelos são treinados com os dados do

consumo energético de cada processo e têm como alvo $t+1$, portanto, o objetivo é estabelecer uma previsão precisa do consumo energético para o próximo ciclo de produção. Cada amostra do *dataset* é um vetor de sete valores de kWh(X) correspondentes aos sete processos do setor de pintura em um dado tempo t , os quais são as variáveis utilizadas neste estudo. Tanto a GRU como a LSTM têm como entrada um conjunto de d amostras do *dataset*, onde d é o valor do *lag*.

Assim, se desejamos utilizar 3 amostras ($lag=3$) para prever a quarta, temos: como entrada no modelo $[X_{t-2}, X_{t-1}, X_{t-0}]$ e $[X_{t+1}]$ como saída. O valor do *lag* foi otimizado em função do modelo híbrido GRU-LSTM com auxílio da função *ParameterGrid* da biblioteca *scikit-learn* a fim de buscar valores para o *lag* que pudessem gerar os melhores resultados para o modelo híbrido implementado neste *step* 1 da arquitetura proposta. Na Figura 2 são apresentados os *MAEs* obtidos para cada *lag* em [3, 5, 6, 7, 8, 9, 10, 12, 16, 20, 30, 40, 60]. O *lag* igual a 7 apresentou o melhor valor de *MAE* para o modelo híbrido, portanto, são 49 valores de kWh distribuídos em 7 vetores utilizados como entrada tanto na GRU como na LSTM.

Figura 2 - Variação do erro em função dos *lag*'s.



Fonte Autores

Os hiperparâmetros utilizados no modelo híbrido GRU-LSTM para este experimento estão descritos na Tabela 1. A utilização de múltiplas rodadas de experimentos, consideram apenas a variação dos hiperparâmetros e da configuração de divisão do *dataset* para treino:teste que é de 80:20, 75:25 e 70:30, sendo esta última a versão final utilizada no experimento realizado.

3.2.2 Step 2 - Predição Do Ciclo De Produção

No segundo *step*, segue-se a arquitetura proposta para os modelos RF, RNA Densa e GXBoost. Utilizou-se a mesma base de dados do *step* 1 deste trabalho para treinamento dos

modelos que preveem o ciclo de produção de uma pintura automotiva. Os hiperparâmetros de cada modelo estão descritos na Tabela 1.

3.2.3 Step 3 - Otimização Utilizando Algoritmos Evolutivos

No último *step*, são empregados algoritmos evolutivos GA, PSO e DE para maximizar o ciclo de produção a partir do consumo energético previsto pelo melhor modelo do *step* 1. Os otimizadores utilizam como função de aptidão (do inglês *fitness*) o melhor modelo do *step* 2. O espaço de busca dos algoritmos é definido a partir do vetor de consumo energético previsto pelo melhor modelo do *step* 1.

Os limites superiores do espaço de busca são definidos pelo vetor predito no *step* 1, enquanto os limites inferiores são definidos por uma redução percentual de 20% (definido pelas estratégias de negócio) do mesmo vetor.

Cada otimizador inicializa um conjunto de indivíduos de forma aleatória (entrada do modelo), onde cada indivíduo representa um vetor de consumo energético e uma possível solução do problema, cuja aptidão é o número de ciclos de produção. O otimizador que, ao final de *i* gerações, apresentar a melhor solução (saída do modelo), será escolhido como resultado do terceiro *step*.

Tabela 1 - Hiperparâmetros dos modelos e otimizadores.

Modelo	Principais Parâmetros
RF	estimators= 50; min_samples_leaf=6
XGBoost	max_depth=6; learning_rate=0,3
GRU-LSTM	Units=32; loss=mse; optimizer=adam; epoch=400; batch_size=16
DL	activation (hidden layers) = sigmoid; activation (output layer)=relu
GA	mutation_probability=0.01; elitism=0.1; crossover_probability=0.7
DE	crossover_probability=0.7; F=0.6
PSO	w=0.1; c ₁ =0.1; c ₂ =0.2

Fonte Autores

Os três otimizadores foram definidos com população de 50 indivíduos e otimizados em 100 gerações. Outros parâmetros, específicos de cada otimizador, foram definidos a partir de diferentes

experimentações e são apresentados na Tabela 1.

3.3 AVALIAÇÃO DO DESEMPENHO DOS MODELOS

Para avaliação de desempenho dos modelos preditores foram utilizadas as seguintes métricas: Erro Médio Absoluto (do inglês *Mean Absolute Error* - MAE), Pontuação de Variância Explicada (do inglês *Explained Variance Score* - EVS) e Erro percentual médio absoluto (do inglês *Mean Absolute Percentual Error* - MAPE). A métrica MAE é a diferença média absoluta entre os valores reais e os valores previstos (Equação 12). EVS explica a dispersão dos erros (Equação 13) e a métrica MAPE mostra o erro (%) em relação aos valores reais (Equação 14).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

$$EVS = 1 - \frac{Var(y-\hat{y})}{Var(y)} \quad (13)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\hat{y}_i} \quad (14)$$

Onde *n* é o número de amostras, *y* é o valor verdadeiro, \hat{y} é o valor predito e \bar{y} é a média dos valores verdadeiros.

4 RESULTADOS E DISCUSSÃO

Nesta seção são apresentados os resultados dos modelos e otimizadores de cada *step*, discussão dos resultados e arquitetura final.

4.1 RESULTADOS DO STEP 1


Neste *step*, os 4 modelos foram avaliados a partir das métricas MAPE e EVS.

Tabela 2 - Avaliação dos modelos no *step* 1.

Modelo	MAPE	EVS
RF	10,1%	0,85
LSTM	8,2%	0,91
XGBoost	7,9%	0,88
GRU-LSTM	7,8%	0,90

Fonte Autores

Figura 3 - Previsão da variável ventilação do GRU-LSTM



Fonte Autores

Optou-se por utilizar o MAPE para melhor compreensão do erro dos valores preditos de consumo energético em $t+1$. A LSTM apresentou os melhores valores para EVS (0,91) e a GRU-LSTM apresentou o melhor resultado para o MAPE e o segundo melhor para EVS (0,90). Escolheu-se a GRU-LSTM como melhor modelo para o step 1, pois o seu MAPE é 0,4% menor e o EVS é apenas 0,01% maior quando comparado com a LSTM, conforme a Tabela 2. A Figura 3 mostra a previsão do modelo GRU-LSTM para a variável ventilação.

4.2 RESULTADOS DO STEP 2


Para avaliação dos modelos do *step 2*, o MAE foi preferível pela possibilidade de observar erro absoluto dos modelos para a quantidade de carros produzidos, melhorando a análise dos resultados pelos stakeholders envolvidos no processo. O EVS foi utilizado novamente neste *step*.

Tabela 3 - Avaliação dos modelos no step 2

Modelo	MAE	EVS
RF	1,62	0,84
RNA Densa	1,59	0,85
XGBoost	1,66	0,84

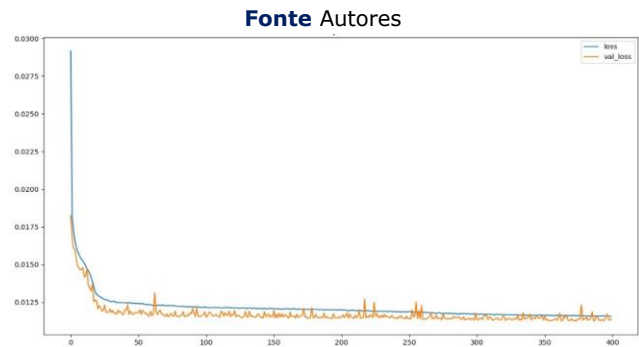
Fonte Autores

Figura 4 - Predição do ciclo de produção utilizando o modelo RNA Densa.



Fonte Autores

Figura 5 - Curvas de convergência: modelo RNA Densa.



Na Tabela 3, o modelo RNA Densa se destaca como melhor modelo na predição dos ciclos de produção ao alcançar os melhores resultados para MAE (1,59) e EVS (0,85). A Figura 4 apresenta a predição de ciclos do modelo RNA Densa e a Figura 5 mostra a curva de convergência de treino e validação após 400 épocas de treinamento.

4.3 RESULTADOS DO STEP 3

O *step 3* depende dos resultados dos steps anteriores, uma vez que o melhor modelo do step 1 é responsável por prever o vetor de consumo energético que define o espaço de busca e o melhor modelo do step 2 é definido como função *fitness* dos 3 otimizadores. Portanto, no step 3, a arquitetura já se encontra definida com a GRU-LSTM para o step 1 e RNA Densa para o step 2.

A previsão do modelo produzido no *step 1* resultou no vetor de consumo energético, cujo consumo total foi de 1818,0 KWh e ciclo produtivo igual a 5,58 - ciclo previsto no step 2, tomando como vetor de entrada o vetor predito no *step 1*.

O vetor predito foi definido como o limite superior do espaço de busca, enquanto o limite inferior foi definido aplicando uma redução de 20% em relação ao limite superior. Todas as possíveis soluções de cada otimizador percorreram um espaço de busca que reflete de 80% a 100% do consumo máximo previsto no *step 1*.

Tabela 4 - Desempenho dos otimizadores

Otimizador	Total kWh	Redução kWh	Ciclo (fitness)
GA	1527,01	290,99	10,58
DE	1517,15	300,80	10,66
PSO	1668,88	149,12	12,70

Fonte Autores

A Tabela 4 mostra os resultados da melhor solução de cada otimizador após 100 gerações. O DE foi o que apresentou o melhor resultado em otimização do vetor energético de 1818,0 KWh (step 1) para 1517,15 kWh, reduzindo consumo em

16,5%. Para ciclo de produção, a melhor otimização é realizada pelo PSO, maximizando o valor do ciclo predito no step 2 (5,58 ciclos) para 12,70 ciclos, resultando em otimização de 127%.

Os valores encontrados ressaltam a importância de selecionar o algoritmo de otimização mais adequado para o objetivo de negócio na organização estudada. Apesar do PSO apresentar melhor otimização de ciclos de produção, a integração do DE na arquitetura final do step 3 representa uma decisão estratégica, a partir de alinhamentos com o stakeholder, baseada na busca por eficiência energética. Portanto, a arquitetura final foi composta pelos modelos GRU-LSTM, DL e DE nos *steps* 1, 2 e 3, respectivamente.

4.4 DISCUSSÃO

A arquitetura final é composta pelos modelos GRU-LSTM, RNA Densa e DE nos steps 1, 2 e 3, respectivamente, conforme o fluxograma de execução das atividades realizadas e sua consolidação proposta como objetivo para o presente estudo, observado no campo "Arquitetura Final" da Figura 1. Essa estrutura é resultado de análises e de modelagens de ML e DL, com cada etapa sendo relevante para os resultados.

Os resultados refletem não apenas os métodos convencionais de experimentação, mas também as estratégias de negócios definidas pelos stakeholders, que vão desde o processamento dos dados até a fase final da arquitetura de steps. Os resultados obtidos nos steps 1, 2 e 3 demonstram melhorias em relação a trabalhos anteriores [25] que foram alcançadas tanto pela introdução de novos modelos e otimizadores, como também pela mudança na análise dados na fase de pré-processamento, que implicaram na remoção das variáveis com baixa correlação de Pearson.

Como neste estudo, os trabalhos de Hong et al. [26], Zafar et al. [20] e Kervanci et al. [27], os modelos híbridos GRU-LSTM propostos por eles se destacam em relação aos demais modelos analisados. Esse ganho se deve ao fato de o modelo híbrido conseguir capturar relações temporais complexas e de curto e longo prazo. Embora os modelos RF e XGBoost não possuam uma arquitetura projetada para capturar explicitamente relações temporais como as RNNs, são capazes de obter resultados próximos à LSTM-GRU e DL devido suas arquiteturas ensemble e flexibilidade em lidar com diferentes padrões de dados.

5 CONCLUSÃO

A nova abordagem composta pela arquitetura de 3 steps se mostrou promissora na previsão e otimização do consumo energético em oficinas de pintura automotiva. A arquitetura final foi capaz de prever e minimizar o consumo energético em até 16% e maximizar o ciclo produtivo a partir dos modelos GRU-LSTM, DL e DE. Os resultados evidenciaram o potencial significativo dessa abordagem integrada de técnicas de ML, DL, abordagens híbridas e algoritmos evolutivos para promover uma gestão mais inteligente e sustentável do consumo energético em ambientes industriais, como as oficinas de pintura automotiva.

Para trabalhos futuros, é possível explorar outras oportunidades não abordadas neste estudo. Isso pode incluir a incorporação de outros modelos nos steps 1 e 2 da arquitetura e a exploração de outros modelos híbridos, visando uma análise mais abrangente e precisa dos dados. Além disso, a consideração de diferentes restrições no espaço de busca, alinhadas com as estratégias ou regras de negócio e validação cruzada na base de dados podem levar a soluções ainda mais otimizadas. A interpretabilidade e a explicabilidade de *datasets* e modelos podem ser considerados como novos testes para compreensão dos resultados.

REFERÊNCIAS

- [1] OKTAVIANDRI, M.; SAFIEE, A. S. B. Modelling Electrical Energy Consumption in Automotive Paint Shop. In: IOP Conference Series: Materials Science and Engineering. IOP Publishing, 2018. p. 012060.
- [2] GIAMPIERI, A. et al. A review of the current automotive manufacturing practice from an energy perspective. Applied Energy, v. 261, p. 114074, 2020.
- [3] ĐAKOVIĆ, D. et al. Review of Energy-Related Machine Learning Applications in Drying Processes. Energies, v. 17, n. 1, p. 224, 2023.
- [4] Mandal, S., Anderson, T.A., Turek, J.S., Gottschlich, J., Zhou, S., Muzahid, A.: Learning fitness functions for machine programming (2021)
- [5] WANG, Z. et al. Random Forest based hourly building energy prediction. Energy and Buildings, v. 171, p. 11-25, 2018.
- [6] FATAHI, R. et al. Modeling of energy consumption factors for an industrial cement

vertical roller mill by SHAP-XGBoost: a "conscious lab" approach. *Scientific Reports*, v. 12, n. 1, p. 7543, 2022.

[7] JIANG, P. et al. Energy consumption prediction and optimization of industrial robots based on LSTM. *Journal of Manufacturing Systems*, v. 70, p. 137-148, 2023.

[8] BASHIR, T. et al. Short term electricity load forecasting using hybrid prophet-LSTM model optimized by BPNN. *Energy reports*, v. 8, p. 1678-1686, 2022.

[9] LU, Y. et al. Prophet-EEMD-LSTM based method for predicting energy consumption in the paint workshop. *Applied Soft Computing*, v. 143, p. 110447, 2023.

[10] MA, S.; JIANG, Z.; LIU, W. Modeling drying-energy consumption in automotive painting line based on ANN and MLR for real-time prediction. *International Journal of Precision Engineering and Manufacturing-Green Technology*, v. 6, p. 241-254, 2019.

[11] SZÁSZ, L.; CSÍKI, O.; RÁCZ, B. Sustainability management in the global automotive industry: A theoretical model and survey study. *International Journal of Production Economics*, v. 235, p. 108085, 2021.

[12] LUKIN, E.; KRAJNOVIĆ, A.; BOSNA, J. Sustainability strategies and achieving SDGs: A comparative analysis of leading companies in the automotive industry. *Sustainability*, v. 14, n. 7, p. 4000, 2022.

[13] CAVALCANTE, E. S. et al. Automotive painting process: Minimizing energy consumption by using adjusted convective heat transfer coefficients. *Progress in Organic Coatings*, v. 140, p. 105479, 2020.

[14] HOVGARD, M.; LENNARTSON, B.; BENGTTSSON, K. Energy-Optimal Timing of Stochastic Robot Stations in Automotive Production Lines. In: 2022 IEEE 27th International Conference on Emerging Technologies and Factory Automation (ETFA). IEEE, 2022. p. 1-7.

[15] ILBEIGI, M.; GHOMEISHI, M.; DEHGHANBANADAKI, Ali. Prediction and optimization of energy consumption in an office building using artificial neural network and a genetic algorithm. *Sustainable Cities and Society*, v. 61, p. 102325, 2020.

[16] NARCISO, D. A.; MARTINS, F. G. Application of machine learning tools for energy efficiency in

industry: A review. *Energy Reports*, v. 6, p. 1181-1199, 2020.

[17] YANG, S.; YU, X.; ZHOU, Y. Lstm and gru neural network performance comparison study: Taking yelp review dataset as an example. In: 2020 International workshop on electronic communication and artificial intelligence (IWECAI). IEEE, 2020. p. 98-101.

[18] CAHUANTZI, R.; CHEN, X.; GÜTTEL, S. A comparison of LSTM and GRU networks for learning symbolic sequences. In: Science and Information Conference. Cham: Springer Nature Switzerland, 2023. p. 771-785.

[19] HONG, J. et al. Multi-forward-step state of charge prediction for real-world electric vehicles battery systems using a novel LSTM-GRU hybrid neural network. *eTransportation*, p. 100322, 2024.

[20] ZAFAR, N. et al. Applying hybrid LSTM-GRU model based on heterogeneous data sources for traffic speed prediction in urban areas. *Sensors*, v. 22, n. 9, p. 3348, 2022.

[21] HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, v. 9, n. 8, p. 1735-1780, 1997.

[22] ABDEL-BASSET, M.; ABDEL-FATAH, L.; SANGAIAH, A. K. Metaheuristic algorithms: A comprehensive review. *Computational intelligence for multimedia big data on the cloud with engineering applications*, p. 185-231, 2018.

[23] WANG, D.; TAN, D.; LIU, L. Particle swarm optimization algorithm: an overview. *Soft computing*, v. 22, p. 387-408, 2018.

[24] OPARA, K. R.; ARABAS, J. Differential Evolution: A survey of theoretical analyses. *Swarm and evolutionary computation*, v. 44, p. 546-558, 2019.

[25] DE OLIVEIRA, R. B. et al. Análise de Consumo de Energia Elétrica de Equipamentos em Oficina de Pintura Automotiva. *Revista de Engenharia e Pesquisa Aplicada*, v. 9, n. 1, p. 69-78, 2024.

[26] HONG, Jichao et al. Multi-forward-step state of charge prediction for real-world electric vehicles battery systems using a novel LSTM-GRU hybrid neural network. *eTransportation*, p. 100322, 2024.

[27] KERVANCI, I. S.; AKAY, M. F.; ÖZCEYLAN, E. Bitcoin price prediction using LSTM, GRU and hybrid LSTM-GRU with bayesian optimization, random search, and grid search for the next days. *Journal Industrial and Management Optimization*, v. 20, n. 2, p. 570-588, 2024.