

APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA ANÁLISE DO EFEITO DO TIPO DA PINTURA DO ABSORVEDOR E DO TIPO DE CONTATO PLACA-TUBO NA PRODUÇÃO DE ENERGIA DE COLETORES SOLARES

Paulo José Schiavon Ara – pauloara@ipt.br

Instituto de Pesquisas Tecnológicas do Estado de São Paulo, Laboratório de Conforto Ambiental, Eficiência Energética e Instalações Prediais

Daniel Setrak Sowmy

Instituto de Pesquisas Tecnológicas do Estado de São Paulo, Laboratório de Conforto Ambiental, Eficiência Energética e Instalações Prediais

Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia de Construção Civil

Resumo. O uso da Inteligência artificial (IA) tem se expandido nos últimos anos, particularmente quando se trata do tema aprendizado de máquina. Nesse contexto, este trabalho propõe a aplicação do algoritmo de classificação Naïve Bayes (NB) treinado por um banco de dados de resultados de ensaios de eficiência energética em coletores solares planos, no âmbito do Programa Brasileiro de Etiquetagem (PBE Solar). O objetivo é propor um método para prever a probabilidade de que um coletor solar, que apresente a priori determinadas evidências construtivas: pintura especial ou comum na placa absorvedora e contato placa-tubo por solda ou encaixe mecânico, obtenha classificação “A” no PBE Solar. Na medida em que o banco de dados aumenta, o aprendizado do algoritmo NB é reforçado e a inferência se torna mais acurada. Os resultados, para um banco de dados de 40 coletores, mostraram que a observação de pintura especial e solda resulta na probabilidade de 88,7% de que o coletor obtenha classificação “A”. Quando, ao invés da solda, verifica-se encaixe mecânico (mantendo a pintura especial) a probabilidade se reduz para 43,3% e quando, ao invés da pintura especial, observa-se pintura comum (mantendo a solda) a probabilidade diminui para 35,2%. Por fim, obteve-se que se nem pintura especial tampouco solda são observadas, a probabilidade do evento alvo é de apenas 5%. Adicionalmente, aplicou-se o algoritmo para outros tamanhos de banco de dados, e não havendo variação significativa nos resultados, constatou-se que a quantidade de dados utilizada foi satisfatória. Como conclusão geral, o trabalho comprovou o grande impacto da pintura especial ou tratamento seletivo na superfície da placa, assim como a importância da soldagem dos tubos na placa, para a produção de energia do aquecedor. Trabalhos futuros poderão mensurar esse efeito em termos econômicos e também usar o algoritmo para avaliar outras características de projeto do coletor.

Palavras-chave: Inteligência Artificial, Produção de Energia, Projeto do Coletor Solar

1. INTRODUÇÃO

É perceptível, tanto no Brasil como no mundo, que o uso da Inteligência Artificial (IA) está se expandindo. Nesse contexto, não é difícil deduzir que também o setor de aquecimento solar de água será alvo de suas aplicações. De forma sucinta, a IA utiliza dispositivos ou métodos computacionais que atuam de forma similar a seres humanos (Sacomano *et al.*, 2018). Isso ocorre por meio de algoritmos que, combinados com bancos de dados, são capazes de resolver problemas e realizar tarefas com desempenho satisfatório.

Uma das aplicações da IA para sistemas de aquecimento solar (SAS) é o uso de algoritmos de detecção de falha, tal como o apresentado por Feierl *et al.* (2023), através dos quais, as falhas de um SAS podem ser detectadas sem a participação de especialista, mas exclusivamente pelo uso de algoritmos e dados de monitoramento.

Adicionalmente, observa-se o uso de redes neurais artificiais (ANN – Artificial neural networks) aplicado aos SAS. Caner *et al.* (2011), por exemplo, propuseram um modelo de ANNs para prever a eficiência térmica de coletores solares a ar usando algoritmos de aprendizagem e dados experimentais. Yaïci e Entchec (2014) investigaram um sistema de energia solar térmica para aquecimento de água e ar ambiente, propondo um modelo baseado em ANNs, de tal forma que, foi possível analisar, com boa acurácia e confiabilidade, parâmetros de desempenho do sistema, como por exemplo, a fração solar do sistema em operação.

Algoritmos de IA baseados em aprendizado de máquina também podem ser aplicados aos SAS. Bettoni *et al.* (2019) propuseram um controlador inovador aplicando a abordagem de aprendizado por reforço – um tópico da IA – e confirmaram seus benefícios em comparação com controladores usuais. De maneira semelhante, Correa-Jullian *et al.* (2020) estudaram a aplicação de inteligência artificial com aprendizagem de máquina para planejamento de operação de um SAS e identificaram vantagens – especialmente para os meses com baixa incidência de radiação solar – de planejar a operação do SAS com auxílio de IA frente a alternativas de planejamento tradicionais.

De maneira semelhante, a IA pode ser usada de forma eficaz para realizar previsões, que possam ser úteis para tomadas de decisões, também em SAS. De fato, conforme Taboada *et al.* (2023), que realizou uma revisão sistemática da

literatura sobre aplicações da IA, a função de “previsão” (*forecasting*) é tema que mais aparece nos trabalhos, seguido pelo tema “tomada de decisão” (*decision making*). Em relação aos SAS, pode-se encontrar aplicações de algoritmos de previsão para se obter informações sobre a energia térmica útil produzida pelos aquecedores solares, como por exemplo, proposto por Ahmad *et al.* (2018), que fez uso de modelos de aprendizagem de máquina para esse objetivo, comparando-os e avaliando sua aplicabilidade ao tema.

No presente trabalho propõe-se utilizar um modelo de previsão denominado classificador *Naïve Bayes*. Esse algoritmo, que pode ser utilizado em conjunto com a Inteligência Artificial, tem como objetivo a obtenção de uma afirmação probabilística sobre a ocorrência de um evento, com base nas evidências observadas *a priori*. Exemplos de aplicação podem ser identificadores de spam, classificadores de sentimentos a partir de análises de textos ou sistemas de recomendação que analisam determinada pessoa e sugerem algum conteúdo ou produto que possa interessar a elas. Essa abordagem é derivada da estatística bayesiana, com a simplificação de considerar que as variáveis que influenciam o evento são independentes. Tal simplificação (independência das variáveis) nem sempre reflete com precisão a realidade, de tal forma que, por esse motivo, recebe o adjetivo de *naïve* (ingênuo).

Um coletor solar para aquecimento de água para banho (*FPC – Flat plate collector*) possui características de projeto, que podem favorecer ou desfavorecer a conversão da radiação solar em energia térmica, o que reflete diretamente na produção de energia e viabilidade econômica do SAS. Nesse sentido, pode-se pensar em fazer uso de banco de dados históricos de resultados de ensaios laboratoriais de eficiência térmica de FPC, atrelados às informações de projeto dos equipamentos ensaiados, para “treinar” um algoritmo sobre o efeito da presença de determinadas características no coletor em sua capacidade de produzir calor ou energia térmica, quando submetido à radiação solar. Tal banco de dados pode estar em constante crescimento ao passar do tempo para reforçar o aprendizado do algoritmo, para que ele capture cada vez melhor a relação entre as variáveis e produza uma estimativa mais acurada.

O presente trabalho tem, portanto, o objetivo de propor a aplicação do classificador *Naïve Bayes* para estimar a probabilidade de que um coletor solar fechado – para aquecimento de água para banho – obtenha classificação energética “A” no Programa Brasileiro de Etiquetagem (PBE Solar) a partir da observação *a priori* de duas variáveis (evidências) qualitativas existentes no coletor solar. A primeira evidência ou atributo de projeto se refere ao tipo de pintura da placa absorvedora metálica e a segunda evidência ou atributo diz respeito ao tipo de contato entre a placa absorvedora e os tubos de elevação (*risers*) do coletor. O algoritmo é alimentado por um banco de dados composto por resultados de ensaios laboratoriais que contém ambas as informações: presença ou ausência das evidências e classificação energética obtida no ensaio conforme o PBE Solar.

Em resumo, a ferramenta de IA proposta, pretende responder a seguinte pergunta: “qual a probabilidade de que o coletor com determinadas características de projeto (tipo de pintura e tipo de contato placa-tubo) obtenha classificação “A” no PBE Solar, quando submetido ao ensaio laboratorial de eficiência térmica?”. Obviamente, a inferência não é exata, mas aproximada a nível probabilístico e terá maior confiabilidade na medida em que o algoritmo for “aprendendo por reforço” com dados mais recentes.

2. EVIDÊNCIAS OBSERVADAS NO COLETOR

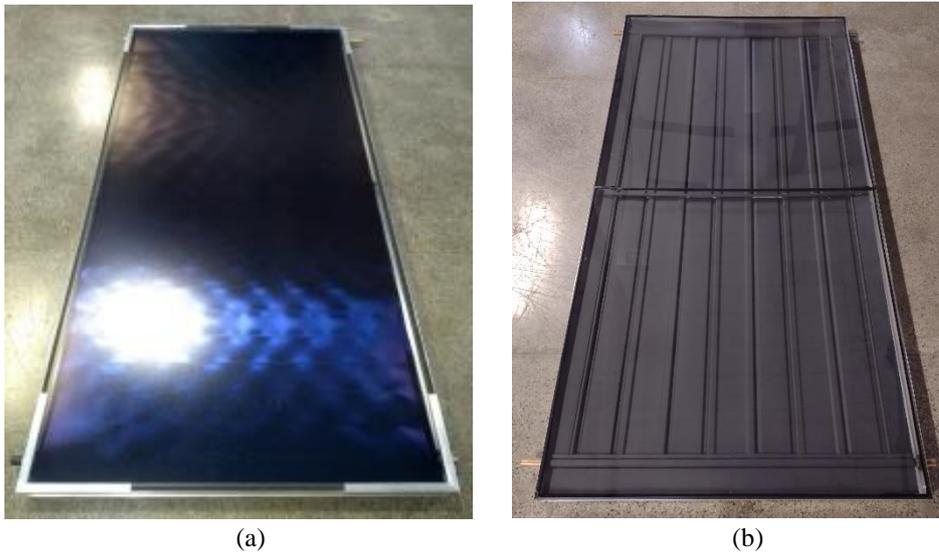
Conforme mencionado anteriormente, foram utilizadas, para compor o conjunto de evidências, duas variáveis correspondentes a características de projeto do coletor fechado. Neste trabalho, serão nomeadas X_1 e X_2 e são descritas nas seções 2.1 e 2.2, respectivamente. Como se trata de uma abordagem inicial sobre o tema, os autores optaram por estudar apenas duas variáveis, porém não haveria impedimento para a inserção de outras variáveis na análise, alternativa que é colocada para possíveis trabalhos futuros. Adicionalmente, ressalta-se que, na prática, as duas variáveis selecionadas não são estritamente binárias, embora essa hipótese ter sido adotada no trabalho. Isso se deu pela boa aproximação de X_1 e X_2 a um comportamento de variáveis binárias, somada à escassez de dados de mercado e de projeto que permitissem a consideração de um comportamento não binário para elas.

2.1 Pintura da placa absorvedora (X_1)

O tipo de pintura da placa absorvedora é uma variável qualitativa e pode assumir dois valores: pintura comercial comum ou pintura com algum tratamento especial (tratamento físico-químico, revestimento seletivo, etc.). Por hipótese, neste trabalho, a pintura da placa pode somente assumir apenas um desses dois atributos, isto é, não há pintura de placa que assuma ambos os atributos simultaneamente e também toda placa, necessariamente, assume um dos atributos.

Sabe-se, por experiência dos autores, que o tratamento especial da placa proporciona ao coletor solar um ganho na absorção da radiação solar, o que reflete em uma melhora na eficiência térmica do equipamento. A questão que se coloca é justamente avaliar o “peso” (em forma de probabilidade) dessa decisão de projeto, isto é, utilizar tratamento especial, na função alvo de que o coletor atinja classificação “A”.

A Fig. 1(a) mostra um coletor solar fechado para aquecimento de água para banho, cuja superfície da placa absorvedora foi alvo de tratamento especial (nesse caso se diz que o coletor possui pintura especial). A Fig. 1(b) mostra outro coletor solar fechado para aquecimento de água para banho, porém sem tratamento especial na placa absorvedora (nesse caso se diz que o coletor possui pintura comum).



(a) (b)
Figura 1 - Coletores solares com diferentes pinturas da placa absorvedora: (a) especial; (b) comum.

2.2 Tipo de contato-placa-tubo (X_2)

A fluxo de calor em um coletor se inicia pela absorção da radiação solar na placa absorvedora. O calor é então transferido por condução térmica pela placa absorvedora paralelamente aos tubos de elevação dentro dos quais circula o fluido de trabalho a ser aquecido (Duffie e Beckman, 2013). Sendo assim, para potencializar o aporte de energia térmica ao fluido, é muito importante o tipo de contato entre a placa e os tubos.

A prática mostra que existem duas possibilidades para realizar o contato placa-tubo: o contato por encaixe mecânico e o contato com solda por ultrassom. Ambos são mostrados na Fig. 2. A Fig. 2(a) mostra um detalhe de um coletor com tubos de elevação encaixados mecanicamente na placa absorvedora e a Fig. 2(b) mostra um detalhe de um tubo de elevação de cobre (em um coletor desmontado) e os sinais do contato por soldagem ultrassom com a parte inferior da placa absorvedora metálica (mostrada dobrada na Fig. 2(b)). Por hipótese, neste trabalho, o tipo de contato pode assumir apenas esses dois atributos, isto é, ou encaixe mecânico ou solda.



(a) (b)
Figura 2 - Coletores solares com diferentes tipos de contato tubo-placa: (a) por encaixe; (b) por solda.

Da mesma forma que para a variável de pintura da placa (X_1), com relação à variável tipo de contato placa-tubo (X_2), a função do algoritmo proposto é de estimar a probabilidade de que o coletor atinja classificação “A”, ao se utilizar contato por solda ao invés de contato por encaixe mecânico.

A Fig. 3 mostra um resumo das evidências estudadas e valores para X_1 e X_2 . A lógica do algoritmo demanda, portanto, o valor do par $\{X_1, X_2\}$, como dado de entrada, podendo esse assumir 4 condições distintas: $\{1,1\}$, $\{1,0\}$, $\{0,1\}$ ou $\{0,0\}$.

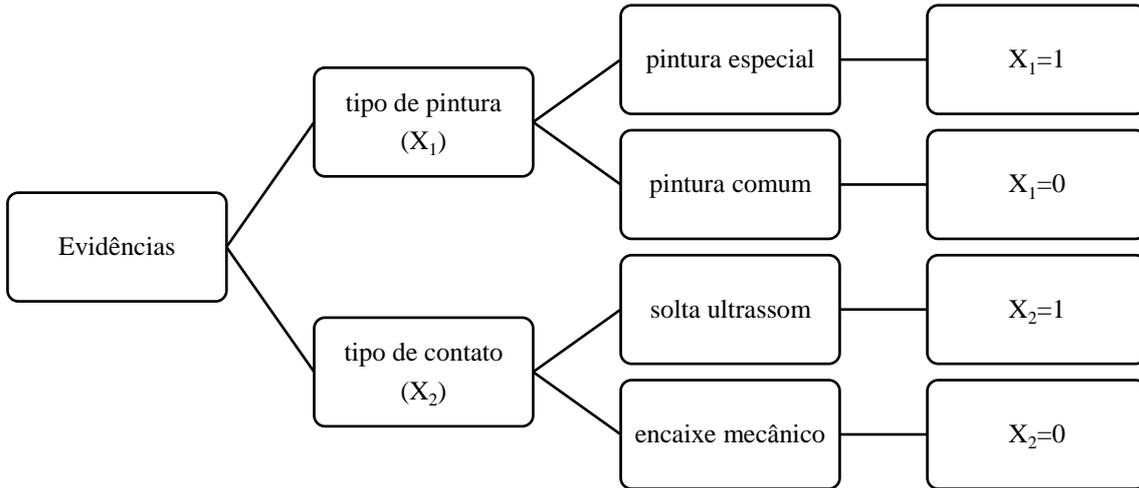


Figura 3 - Evidências estudadas e valores atribuídos.

3. CLASSIFICAÇÃO NO PROGRAMA BRASILEIRO DE ETIQUETAGEM

O Programa Brasileiro de Etiquetagem para Equipamentos de Aquecimento Solar de Água (PBE Solar) é atualmente compulsório e regulamentado pela Portaria nº 420/21 do INMETRO, publicada em 04 de outubro de 2021. Coletores solares fechados, entre outros equipamentos destinados ao uso para aquecimento solar, devem cumprir os requisitos apresentados pelo Regulamento Técnico anexo à Portaria nº 420/21 e por ela aprovados (INMETRO, 2021). No que diz respeito à classificação energética dos coletores solares, deve-se submetê-los ao ensaio de eficiência térmica em laboratório, conforme as referências normativas apresentadas no Regulamento.

O ensaio laboratorial determina para o coletor solar submetido ao teste, sua curva de eficiência conforme a Eq. (1):

$$\eta = \eta_0 - a_1 T_m^* - a_2 G (T_m^*)^2 \quad (1)$$

onde η é a eficiência térmica instantânea do coletor, η_0 , a_1 e a_2 são constantes da equação de 2º grau, G é a irradiância normal incidente sobre o coletor, em W/m^2 e T_m^* é a temperatura média reduzida em $^{\circ}C \cdot m^2/W$, na qual o coletor está operando.

A temperatura média reduzida, para determinado instante de operação, pode ser calculada pela Eq. (2):

$$T_m^* = (T_m - T_a) / G \quad (2)$$

onde T_m é a média entre as temperaturas da água na entrada e saída do coletor, T_a é a temperatura ambiente e G a irradiância incidente, em W/m^2 .

O regulamento Técnico do INMETRO estabelece que a classificação de eficiência energética do coletor solar (“A”, “B”, “C”, “D” ou “E”) é função do valor da sua Produção Mensal Específica de Energia (PMEE), em $kWh/(m^2 \cdot \text{mês})$, dada pela Eq. (3):

$$PMEE = PME / A_e \quad (3)$$

onde PME é a Produção Mensal de Energia do coletor, em $kWh/mês$ e A_e é a área externa (*gross area*) do coletor em m^2 .

Para o cálculo da PME , utiliza-se a Eq. (4):

$$PME = 8,33 \times \eta_m \times \bar{H} \times K_{\theta,25^{\circ}} \times A_t \quad (4)$$

onde \bar{H} é a irradiação diária de referência em média anual, correspondente à $17,6 MJ/m^2$, A_t é a área transparente (*aperture area*) do coletor em m^2 , $K_{\theta,25^{\circ}}$ o fator de correção para o ângulo de incidência para a condição de ângulo de incidência de 25° , e η_m é a eficiência térmica média do coletor, calculada pela Eq. (5), valendo-se da curva de eficiência $\eta(T_m^*)$ no formato da Eq. (1), determinada no teste experimental:

$$\eta_m = \int_0^{0,044} \eta(T_m^*) dT_m^* / 0,044 \quad (5)$$

De posse dessas grandezas, pode-se determinar a Produção Mensal Específica de Energia (PMEE) do coletor, expressa pela Eq. (3).

Por fim, o Regulamento Técnico do INMETRO estabelece faixas de classificação dos produtos nas classes A até E, em relação à eficiência energética. Por exemplo, coletores que obtiveram PMEE maior ou igual a $80,3 \text{ kWh}/(\text{m}^2 \cdot \text{mês})$ são considerados classe “A” e podem declarar essa informação em sua Etiqueta Nacional de Conservação de Energia (ENCE) e também na comercialização do produto. Isso confere um atrativo ao modelo de coletor em questão, pois, sob condições de referência, ele fornece mensalmente ao usuário, uma quantidade maior de energia (kWh), em forma de água quente, para cada metro quadrado de área instalada de coletor solar. Em consequência o SAS necessitará de menor área coletora (ou quantidade de módulos) para atender uma determinada demanda de energia térmica, resultando em benefícios econômicos para o usuário.

4. CLASSIFICADOR NAÏVE BAYES

O conceito no qual se baseia o algoritmo de classificação Naïve Bayes (NB), que neste trabalho está associado à Inteligência Artificial, no tema aprendizado por reforço, é o da probabilidade condicional. Segundo Ara *et al.* (2003), sendo A e B dois eventos em um espaço amostral, com $P(A)$ e $P(B)$ não nulos, onde $P(A)$ é a probabilidade de ocorrência do evento A , $P(B)$ a probabilidade de ocorrência do evento B , $P(B|A)$ a probabilidade condicional de ocorrência do evento B , tendo ocorrido o evento A e $P(A|B)$ é a probabilidade condicional de ocorrência do evento A , tendo ocorrido o evento B , a probabilidade $P(B|A)$ é calculada pela Eq. (6):

$$P(B|A) = \frac{P(A \cap B)}{P(A)} \quad (6)$$

onde $P(A \cap B)$ é a probabilidade da ocorrência simultânea de A e B .

Da mesma forma, $P(A|B)$ é calculada pela Eq. (7):

$$P(A|B) = \frac{P(B \cap A)}{P(B)} \quad (7)$$

Como $P(A \cap B) = P(B \cap A)$, das Eq. (6) e Eq. (7), obtém-se:

$$P(A|B) \times P(B) = P(B|A) \times P(A) \quad (8)$$

Dividindo ambos os membros por $P(B)$, obtém-se:

$$P(A|B) = \frac{P(B|A) \times P(A)}{P(B)} \quad (9)$$

A Eq. (9) é a base do algoritmo NB. $P(A)$ é a probabilidade de ocorrência do evento alvo ou objetivo (que o coletor obtenha classificação “A” quando submetido a ensaio do PBE Solar), porém antes de verificar as evidências X_1 (tipo de pintura da placa) e X_2 (tipo de contato placa-tubo), e é denominada probabilidade *a priori*. $P(A)$ pode ser calculada a partir do banco de dados de resultados de ensaios, computando-se frequências relativas.

O evento B corresponde às evidências X_1 e X_2 , portanto, $P(B|A)$ é a probabilidade de ocorrência das evidências, tendo ocorrido a classificação “A” e, da mesma forma, pode ser calculada computando-se as frequências relativas observadas no banco de dados dos ensaios. O objetivo do algoritmo é estimar $P(A|B)$, denominada probabilidade *a posteriori*, ou seja, fazer uma inferência sobre a chance de a classificação de eficiência energética ser “A”, dado que foram observadas as evidências $B = \{X_1, X_2\}$.

Como X_1 e X_2 são, por hipótese, variáveis independentes, pode-se reescrever a Eq. (9) conforme a Eq. (10):

$$P(A|B) = \frac{P(X_1|A) \times P(X_2|A) \times P(A)}{P(B)} \quad (10)$$

Para não requerer o cálculo de $P(B)$ pode-se introduzir o evento $\neg A$, onde o símbolo “ \neg ” corresponde à negação ou não ocorrência do evento A . Analogamente ao que foi deduzido para $P(A|B)$ pela Eq. (10), a probabilidade $P(\neg A|B)$ pode ser calculada pela Eq. (11):

$$P(\neg A|B) = \frac{P(X_1|\neg A) \times P(X_2|\neg A) \times P(\neg A)}{P(B)} \quad (11)$$

Como A e $\neg A$ são eventos complementares, tem-se que $P(A) + P(\neg A) = 1$ e das Eq. (10) e (11) pode-se deduzir a Eq. (12) que é utilizada no algoritmo NB, sendo $B = \{X_1, X_2\}$:

$$P(A|B) = \frac{\mu}{\mu + \mu'} \quad (12)$$

onde $\mu = P(X_1|A) \times P(X_2|A) \times P(A)$ e $\mu' = P(X_1|\neg A) \times P(X_2|\neg A) \times P(\neg A)$.

Como se pode observar pela Eq. (12), não se faz necessário o cálculo de $P(B)$. As grandezas μ e μ' podem assumir valores de 0 a 1 e são computadas a partir dos resultados dos ensaios, sendo continuamente refinadas com o crescimento do banco de dados, caracterizando o aprendizado por reforço do algoritmo.

5. OBTENÇÃO DOS DADOS EXPERIMENTAIS

Os dados experimentais foram obtidos tabelando-se os resultados de ensaios realizados em laboratório, conforme o Regulamento Técnico anexo à Portaria nº 420/21 do INMETRO, em coletores fechados planos. Não foram incluídos na análise coletores horizontais, nem coletores com tubos a vácuo. Também foram desconsiderados coletores cujas tubulações sejam de aço inox e cuja placa absorvedora não seja de alumínio. Também coletores abertos cuja aplicação é o aquecimento de piscinas não foram incorporados na análise.

A forma do banco de dados é exemplificada na Tab. 1:

Tabela 1 - Modelo do banco de dados utilizado para alimentar o algoritmo.

COLETOR	PINTURA DA PLACA (X_1)	CONTATO PLACA-TUBO (X_2)	OBTEVE CLASSE "A"?
1	especial ou comum	solda ou encaixe mecânico	Sim / Não
2	especial ou comum	solda ou encaixe mecânico	Sim / Não
(...)	(...)	(...)	(...)
N	especial ou comum	solda ou encaixe mecânico	Sim / Não

O banco de dados foi composto por 40 resultados de ensaio (N=40) para uma inferência aproximada sobre a probabilidade de obtenção de classificação "A" dadas as evidências X_1 e X_2 . Como foi dito, o algoritmo pode "aprender das observações" conforme aumenta a massa de dados.

Adicionalmente, para testar o algoritmo, foi realizada a mesma análise para diferentes tamanhos de banco de dados (seção 6.3), a fim de verificar sua sensibilidade ao tamanho da amostra. Como a quantidade de dados disponível era de 40 ensaios, não mais, os autores optaram por fazer essa análise eliminando dados aleatoriamente, isto é, não com o aumento, mas com a redução do tamanho da amostra.

6. RESULTADOS

6.1 Estatísticas sobre o banco de dados

Após a aplicação do algoritmo NB aos dados experimentais computados conforme descrito na seção anterior, foi estimada a probabilidade de que o coletor solar obtenha classificação "A" tendo-se verificado as evidências apresentadas na seção 2. Antes, porém, de apresentar o resultado da estimativa, alguns dados estatísticos sobre o banco de dados são mostrados nas Fig. 4, Fig. 5 e Fig. 6:

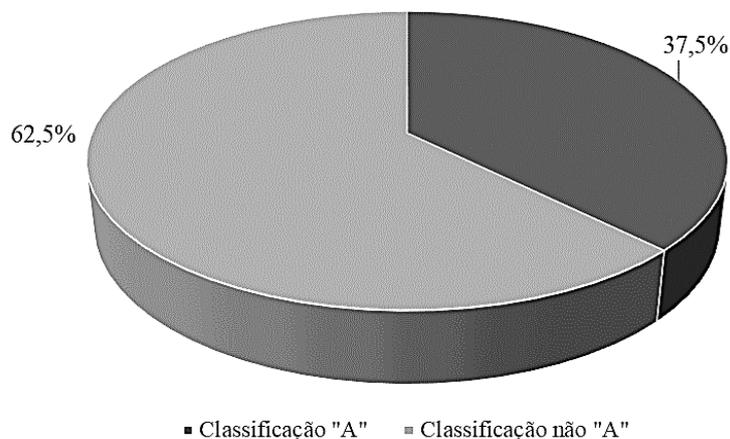


Figura 4 - Porcentagem de coletores que obtiveram e não obtiveram classificação "A" nos ensaios.

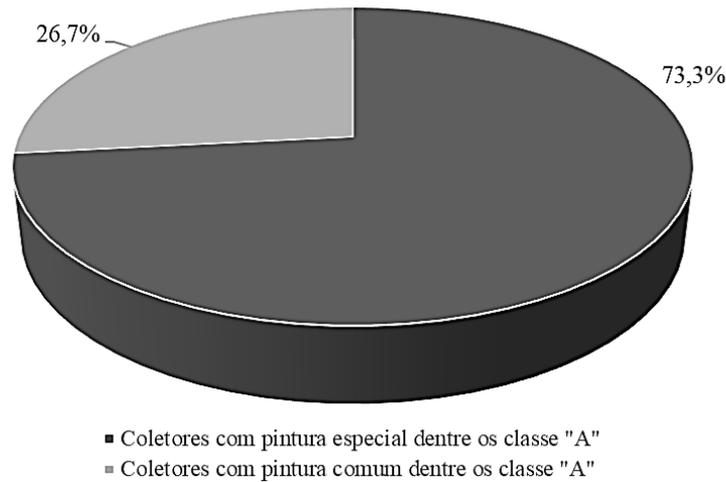


Figura 5 - Distribuição dos coletores com e sem pintura especial dentre os classe "A".

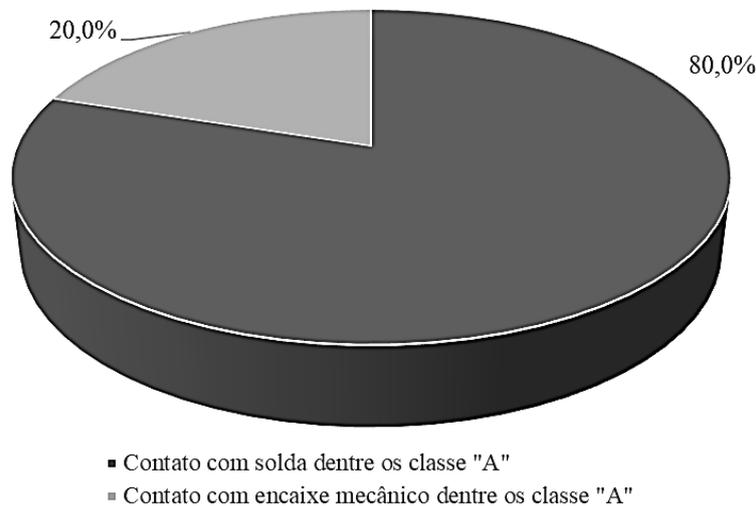


Figura 6 - Distribuição dos coletores com e sem solda dentre os classe "A".

Da Fig. 4, pode-se constatar que, dos 40 coletores solares do banco de dados, pouco mais de um terço deles, obtiveram classificação "A". Os demais (62,5%) obtiveram classificações "B", "C", "D" ou "E". Essa informação expressa a probabilidade *a priori* de que o coletor seja classe "A" com base no histórico de dados e sem nenhuma afirmação sobre as evidências.

Pela Fig. 5 deduz-se que a pintura especial da placa absorvedora favorece a produção de energia específica (PMEE) do coletor e, portanto, sua classificação, em detrimento da ausência de algum tratamento físico-químico ou seletivo no absorvedor.

De forma semelhante, da Fig. 6 conclui-se que o uso de solda por ultrassom para estabelecer o contato entre absorvedor e tubulação é também favorável à eficiência energética, quando comparado com estratégias de contato apenas por encaixe mecânico. Vale lembrar, que as distribuições da Fig. 5 e Fig. 6 se referem apenas ao espaço amostral dos coletores "A", correspondente à 37,5% dos coletores do banco de dados original, conforme mostrado pela Fig. 4. As probabilidades 73,3% e 80,0%, respectivamente da Fig. 5 e Fig. 6 são também chamadas de *verossimilhanças*.

6.2 Probabilidades de obtenção de classificação "A"

Ao final, obteve-se as probabilidades *a posteriori* de obtenção de classificação "A", tendo-se já observado as características construtivas do aquecedor solar. A Fig. 7 mostra a probabilidade estimada para as 4 combinações possíveis de evidências X_1 e X_2 :

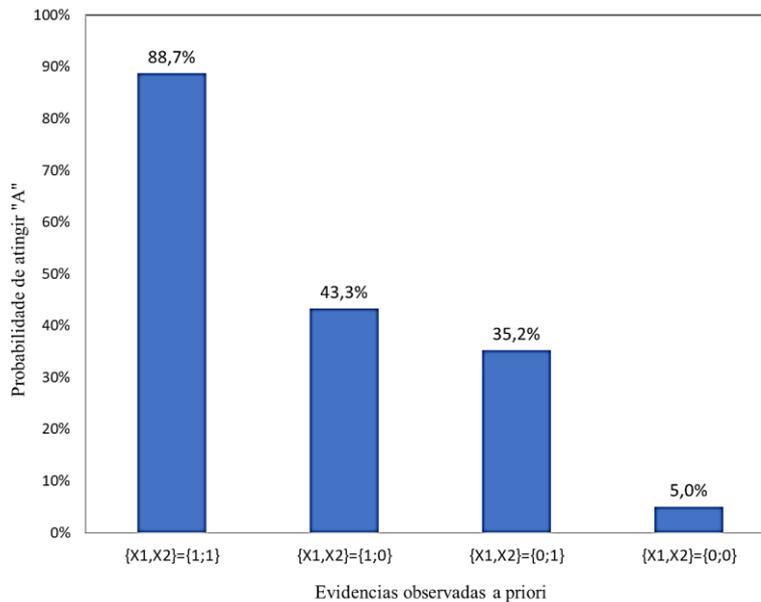


Figura 7 - Probabilidades de ocorrência do evento objetivo em função da ocorrência das evidências.

Analisando a Fig. 7, verifica-se, primeiramente, que observados no coletor a presença de pintura com tratamento especial e contato por solda, ou seja, $\{X_1, X_2\} = \{1, 1\}$, a probabilidade que esse coletor obtenha classificação “A” é de quase 89%. Quando se observa a existência do contato placa-tubo por encaixe mecânico (ao invés da solda), mesmo mantendo-se o tratamento especial no absorvedor, ou seja, $\{X_1, X_2\} = \{1, 0\}$, a probabilidade estimada cai para cerca de 43%. Analogamente, quando se observa pintura comercial comum no absorvedor ao invés do tratamento especial, mantendo-se, porém, o contato placa-tubo por solda ultrassom, ou seja, $\{X_1, X_2\} = \{0, 1\}$, a probabilidade se reduz para cerca de 35%. Por fim, quando não se observam nem tratamento especial na placa absorvedora nem solda entre tubo e placa, a chance estimada do coletor atingir classificação “A” é de apenas 5%.

No que diz respeito ao tratamento da superfície da placa absorvedora por meio de alguma pintura seletiva ou algum tratamento físico-químico especial, pode-se afirmar que resulta na melhora da absorção de radiação solar pela placa e, portanto, maior ganho energético, quando comparado ao caso do coletor que dispõe apenas de uma pintura comercial comum. Isso ocorre mesmo sabendo-se que a pintura comercial comumente utilizada pelos fabricantes de aquecedores solares confere à superfície da placa uma elevada absorvidade térmica (cor escura). De fato, conforme estudado por Ara (2022), a seletividade da superfície da placa absorvedora assume as principais posições no “ranking” de importância dentre os parâmetros de projeto do coletor solar que exercem influência em sua eficiência térmica.

Com relação ao contato placa-tubo, quando se utiliza encaixe mecânico em detrimento da soldagem, o maior problema deriva das imperfeições no contato físico entre os tubos (em geral, de cobre) e a placa (em geral, de alumínio), criando espaços de ar e prejudicando a transferência de calor entre os elementos. Entretanto, tendo-se como referência um coletor com tratamento especial no absorvedor e solda por ultrassom, ou seja, $\{X_1, X_2\} = \{1, 1\}$, pode-se observar comparando-se as duas colunas centrais da Fig. 7, que a não utilização da pintura especial causa maior prejuízo à produção de energia do aquecedor do que a não utilização de solda por ultrassom.

6.3 Influência do tamanho do banco de dados

A fim de avaliar a confiabilidade do método, as mesmas estimativas apresentadas na Fig. 7 foram recalculadas para banco de dados com número de coletores inferior ao original ($N < 40$). O motivo para a redução e não o aumento do banco de dados para a realização desta análise foi apresentado na seção 5. Sendo assim, dados do mesmo banco já utilizado foram eliminados aleatoriamente até atingir-se a quantidade de dados desejada. O cálculo foi realizado para bancos de dados de 35, 30 e 25 coletores.

Nomeando de P_{max} a probabilidade de o coletor obter classificação “A” dadas as evidências $\{X_1, X_2\} = \{1, 1\}$ e chamando de P_{min} a probabilidade de o coletor obter classificação “A” dadas as evidências $\{X_1, X_2\} = \{0, 0\}$, plota-se na Fig. 8 os valores de P_{max} e P_{min} conforme o tamanho do banco de dados (eixo x).

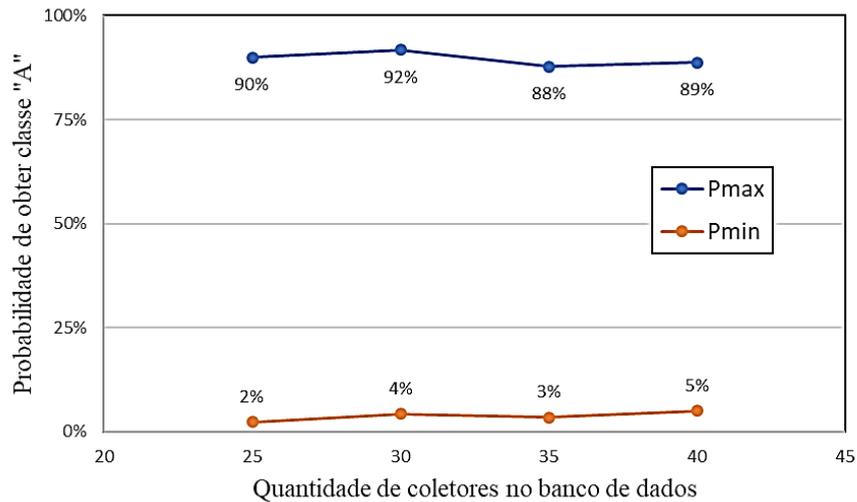


Figura 8 – Influência do tamanho do banco de dados no resultado das inferências.

Da Fig. 8, nota-se que para o tamanho da amostra de 40 ensaios, os valores de P_{max} e P_{min} correspondem às colunas da extrema esquerda e da extrema direita da Fig. 7. Nota-se também que as previsões se alteraram muito pouco com a variação do tamanho do banco de dados. De fato, dentre os 4 cenários de banco de dados utilizados (N=25; N=30; N=35; N=40), as probabilidades estimadas variaram, na pior das hipóteses, 4% e 3% para P_{max} e P_{min} , respectivamente.

7. CONCLUSÕES

O presente trabalho propôs a aplicação de uma técnica de inteligência artificial do tipo aprendizado por reforço para treinar um algoritmo de classificação Naïve Bayes no contexto da análise do efeito, na produção energética de coletores fechados planos, do tipo de pintura da placa absorvedora e do tipo de contato placa-tubo. O banco de dados foi composto por 40 resultados de ensaios laboratoriais de eficiência energética, conforme o Programa Brasileiro de Etiquetagem do INMETRO, realizados em coletores com pintura especial ou comum, na placa absorvedora, e com solda por ultrassom ou encaixe mecânico no contato entre placa e tubo.

Para o espaço amostral estudado, 37,5% dos coletores apresentaram classificação “A” de eficiência energética e 62,5% classificações “B”, “C”, “D” ou “E”. Dentre os classificados como “A” as probabilidades de verificação das evidências - pintura especial e solda - foram de 73,3% e 80,0%, respectivamente. Como resultado da aplicação do algoritmo, conclui-se que a observação dos atributos pintura especial e solda em um determinado coletor resulta que o mesmo possui 88,7% de probabilidade de atingir classificação “A”, a observação dos atributos pintura especial e encaixe mecânico resulta em 43,3% de probabilidade de atingir classificação “A”, a verificação *a priori* de pintura comum e solda por ultrassom traduz-se em uma estimativa de probabilidade de 35,2% de obter classe “A” e, por fim, dado que se verificou pintura comum e encaixe mecânico no equipamento, a chance de que o coletor, quando submetido ao ensaio, obtenha classificação “A” é de apenas 5%.

Adicionalmente, para testar a influência do tamanho do banco de dados na qualidade da estimativa, repetiu-se a aplicação do algoritmo em mais 3 cenários (25, 30 e 35 coletores) e constatou-se que a variação dos resultados foi pequena, da ordem de 3 a 4%, mostrando que o tamanho do banco de dados utilizado é satisfatório.

Como conclusão geral, o trabalho comprovou o grande impacto da pintura especial ou tratamento seletivo na superfície da placa, assim como a importância da soldagem dos tubos na placa, para a produção de energia do aquecedor. Trabalhos futuros poderão mensurar esse efeito em termos econômicos e usar o algoritmo para avaliar outras características ou variáveis de projeto do coletor.

Agradecimentos

Os autores agradecem ao Laboratório de Conforto Ambiental, Eficiência Energética e Instalações Prediais do Instituto de Pesquisas Tecnológicas de São Paulo, por possibilitarem a obtenção dos dados históricos experimentais de resultados de ensaios do PBE Solar.

REFERÊNCIAS

Ahmad, M., Reynolds, J., Rezgui, Y. 2018. Predictive modelling for solar thermal energy systems: A comparison of support vector regression, random forest, extra trees and regression trees, Journal of Cleaner Production, vol. 203, pp. 810-821.

- Ara, A. B., Musetti, A. V., Schneiderman, B. 2003. Introdução à Estatística, Editora Edgard Blücher Ltda.
- Ara, P. J. S. 2022. Influência relativa dos parâmetros de projeto na eficiência térmica de coletores solares planos utilizando simulações em Fluidodinâmica Computacional, Tese de Doutorado, Escola Politécnica da Universidade de São Paulo, São Paulo.
- Bettoni, D., Soppelsa, A., Fedrizzi, R., Matamoros, R. 2019. Analysis and Adaptation of Q-Learning Algorithm to Expert Controls of a Solar Domestic Hot Water System, Applied System Innovation, vol. 2, n. 15., pp. 1-25.
- Caner, M., Gedik, E., Kecebas, A. 2011. Investigation on thermal performance calculation of two type solar air collectors using artificial neural network, Expert Systems with Applications, vol. 38, pp. 1668-1674.
- Correa-Jullian, C., Droguett, E., Cardemil, J. 2020. Operation scheduling in a solar thermal system: A reinforcement learning based framework, Applied Energy, vol. 268, pp. 1-16.
- Duffie, J. A., Beckman, W. A., 2013. Solar Engineering of Thermal Processes, John Wiley & Sons. 4ª Edição.
- Feierl, L., Unterberger, V., Rossi, C., Gerardts, B, Gaetane, M. 2023. Fault detective: Automatic fault-detection for solar thermal systems based on artificial intelligence, Solar Energy Advances, vol. 3. Artigo submetido e apresentado na Conferência EuroSun 2022.
- INMETRO, 2021. Regulamento técnico da qualidade para equipamentos de aquecimento solar de água (Portaria Nº 420/21). Disponível em: <http://www.inmetro.gov.br/legislacao>. Acesso: 08 nov. 2023.
- Sacomano, J. B. *et al.* Indústria 4.0: conceitos e fundamentos. Editora Edgard Blücher Ltda.
- Taboada, I., Daneshpajouh, A., Toledo, N., de Vass, T. 2023. Artificial intelligence enabled project management: A systematic literature review, Applied Sciences, vol. 13, pp. 1-23.
- Yaïci, W., Entchev, E. 2014. Performance prediction of a solar thermal energy system using artificial neural networks, Applied Thermal Engineering, vol. 73, n. 1, pp. 1348-1359.

APPLICATION OF ARTIFICIAL INTELLIGENCE IN THE ANALYSIS OF THE EFFECT OF THE ABSORBER PAINT TYPE AND PLATE-TUBE CONTACT TYPE ON SOLAR COLLECTORS ENERGY PRODUCTION

Abstract. *The use of artificial intelligence (AI) has expanded in recent years, particularly regarding machine learning. In this context, this work proposes the application of the Naïve Bayes (NB) classification algorithm trained by a database of Flat Plate Solar collectors energy efficiency test results, within the scope of the Brazilian Certification Program of Solar Heating Systems. The research objective is to propose a method to predict the probability that a solar collector, which presents a specific constructive evidence: special or common painting on the absorber plate and plate-tube contact by welding or mechanical fitting, will obtain an “A” classification in the efficiency test. As the database grows, the learning of the NB algorithm is reinforced and inference becomes more accurate. The results, for a database of 40 collectors, showed that given that a solar collector has special painting and welding the probability that the collector will obtain an “A” classification is 88.7%. When, instead of welding, there is mechanical fitting (maintaining the special painting) this probability reduces to 43.3% and when, instead of special painting, common painting is observed (maintaining the welding) the probability decreases to 35.2%. Finally, it was found that if neither special painting nor welding are observed, the probability of being class “A” is only 5%. Additionally, the algorithm was applied to other database sizes, resulting in negligible variation in the results, proving that database size used was satisfactory. In summary, the work proved the great impact, on solar collector energy production, of special or selective painting on the absorber plate, as well as the importance of welding the tubes to the plate, instead of fitting the tubes mechanically to absorber plate. Future works may measure this effect in economic terms and also use the algorithm to evaluate other collector design characteristics.*

Keywords: Artificial Intelligence, Energy Production, Solar Collector Design