

Clusterização, Classificação e Predição de "Pré-Efeito Anódico" de cuba de redução de alumínio primário

Bruno N.M.S Conte¹, Thiago N.M.S Conte¹, Roberto C.L. de Oliveira¹,

¹Programa de Pós-graduação em Engenharia Elétrica (PPGEE)

Campus Guamá – Universidade Federal do Pará (UFPA)

CEP 66075-110 – Belém – PA - Brasil

{brunonicolau.conte, thiagonconte}@gmail.com, limao@ufpa.br}

***Abstract.** Application of Artificial Neural Networks (ANN) in data classification in areas requiring high technology such as the aerospace, automotive and energy sectors has been shown to be a promising approach in behavioral discrimination. An ANN together with clustering algorithms were then used to model computationally patterns of the occurrence of the anode effect of the furnace of the aluminum reduction industry. The input data used in the classification consists of the collection of a Brazilian company, internationally recognized by the quality standards of the metal produced. The results obtained demonstrate a good approximation of the simulations against the experimental data.*

***Resumo.** Aplicação de Redes Neurais Artificiais (RNA) na classificação de dados em áreas que demandam alta tecnologia como os setores aeroespacial, automotivos e de energia tem se mostrado uma abordagem promissora na discriminação de comportamento. Uma RNA junto com algoritmos de clusterização foram, então, utilizados para modelar computacionalmente padrões da ocorrência do pré-efeito anódico do forno da indústria de redução de alumínio. Os dados de entrada utilizados na classificação constituem-se da coleta de uma empresa brasileira, internacionalmente reconhecida pelos padrões de qualidade do metal produzido. Os resultados obtidos demonstram boa aproximação das simulações frente aos dados experimentais.*

1. Introdução

Atualmente a grande preocupação mundial com a grave situação ambiental do planeta e também por crescentes exigências legais estão levando as indústrias de redução de alumínio primário ao desenvolvimento sustentável de produção, com escopo de reduzir os impactos ambientais de sua atividade econômica. Assim, torna-se necessária a busca de práticas operacionais e de controle da produção que sejam ambientalmente responsáveis. Essa responsabilidade ambiental tem como foco principal a redução dos gases do efeito estufa, redução do consumo de energia e aumento de produtividade (MARCIA, 2018).

É oportuno ressaltar, que o processo de redução de alumínio é responsável por uma grande quantidade de emissão de gases causadores do efeito estufa, como o gás carbônico (CO₂) e o metano (CH₄) (GRJOTHEIM & KVANDE, 1993). Eles retêm a

energia solar na atmosfera causando a elevação da temperatura média global. Essa elevação causa impactos ambientais e alterações climáticas graves, como o aumento na frequência e na intensidade de secas e cheias e o derretimento das calotas polares, elevando o nível dos mares e diminuindo a reserva de água doce do mundo (ABAL, 2017).

Como alternativas tecnológicas para mitigar o problema ambiental e o desenvolvimento de novas estratégias apoiada na sustentabilidade, tento em vista a problemática do agravamento da concentração de gases de efeito estufa, aumento extremo na tensão do forno e conseqüentemente a perda de produção em toda a linha de cubas, este trabalho propõe a utilização de algoritmos de aprendizado de máquina como Rede Neurais Artificiais para avaliar seu potencial de diagnosticar padrões e a capacidade de clusterização (agrupamento) com K-Means Clustering, Agrupamento Aglomerativo e Birch com aprendizados de modo não supervisionado no comportamento do pré-efeito anódico.

2. Efeito Anódico

A indústria de redução de alumínio, através de um processo mundialmente conhecido como Hall-Héroult, transforma alumina em alumínio líquido. Neste processo, são despejados vários insumos, necessários para redução da alumina como Fluoreto de Alumínio (AlF_3), Fluoreto de Cálcio (CaF_2) e Carbonato de Sódio (Na_2CO_3) e outros. Tais variáveis recebem forte influência da variação de temperatura do forno. Portanto, os mesmos devem manter estável a temperatura do forno eletrolítico, pois o processo físico-químico para fabricar o alumínio exige uma estabilidade térmica de modo a evitar a formação de gases e conseqüentemente a destruição do forno (CONTE, 2015)

Durante o processo de transformar alumina em alumínio líquido a ocorrência do efeito anódico é atribuída a formação de um filme isolante, e com esse comportamento o banho não pode mais molhar a superfície anódica, até que a barreira de gás isolante seja quebrada. O efeito anódico causa um aumento extremo na tensão do forno e conseqüentemente uma elevação na temperatura do banho, com temperaturas altíssimas, resultando em um distúrbio térmico, com a possibilidade de ocorrer o derretimento da camada isolante da forno e as conseqüências finais são a perda de produção em toda a linha de fornos, sua vida útil diminuída e a produção dos principais gases, PFCs, que contribuem para o aumento do efeito estufa. (SILVA, 2009).

3. Revisão Bibliográfica

Referente as aplicações de redes neurais artificiais em sistemas de indústrias de redução de alumínio primário, podem ser citados trabalhos no que concerne a modelagem do Pré-efeito Anódico. Nesse sentido, (CONTE THIAGO, CONTE BRUNO e OLIVEIRA, 2017) desenvolveram um trabalho que avalia dois tipos de Redes Neurais Artificiais na tarefa de predição do Pré-Efeito Anódico que ocorre nos fornos de redução de alumínio primário. A proposta é utilizar Redes Neurais Multicamadas Diretas (RNMD) e Redes Neurais Recorrentes (RNR) para identificar a ocorrência do Pré-Efeito Anódico do forno eletrolítico.

CONTE e col. (2018) comparam RNAs com as técnicas de mineração de dados Árvore de decisão e Random Florest para avaliar sua capacidade de diagnosticar

padrões na ideia de identificar o Pré-Efeito Anódico dos fornos de redução de alumínio primário.

ANTÔNIO SILVA (2009), a partir dos sinais de Tensão e corrente apresenta a investigação de modelos paramétricos ARX e OE que melhor representa o funcionamento do Forno eletrolítico para possibilitar a predição do efeito anódico no processo produtivo do alumínio.

Entretanto, o diferencial desse trabalho atual, em relação aos artigos mencionados acima é realizar primeiro uma tarefa de aprendizado descritivo, ou não supervisionado, para identificar informações relevantes nos dados sem a presença de um elemento externo que guiaria o aprendizado, e posteriormente realizar um aprendizado preditivo, treinando e criando um estimador a partir dos rótulos da tarefa de agrupamento anterior, e por fim avaliar o modelo de rede preditiva com as etiquetas do banco de dados originais.

4. Aprendizado

Em um aprendizado supervisionado tradicional, buscar-se treinar a rede neural com os dados de entrada e sua classe categórica previamente disponíveis, assim, a rede ajusta seus pesos a cada interação, baseado nos rótulos de saída de cada registro. O desafio aqui proposto é obter uma eficiência na predição supondo que essas classes de saídas não existam em um primeiro momento, ou seja, realizamos primeiro um aprendizado não supervisionado para rotular nossos dados de entrada e posteriormente treinamos a nossa rede neural com os rótulos definidos anteriormente, e por fim, avaliamos a saída da rede neural com as classes originais.

Na primeira etapa, é escolhido o melhor resultado das técnicas de Clusterização K-Means, Agrupamento Aglomerativo e Birch, utilizadas neste trabalho e, que tem como objetivo a identificação de propriedades intrínsecas aos dados de entradas.

Na segunda etapa é utilizado uma Rede Neural Artificial com treinamento supervisionado, onde cada neurônio produzirá um valor de saída que é então comparado ao valor de saída especificado pelo cluster.

Na última etapa, após o treinamento da rede, realizamos os testes de validação dos padrões treinados, e a partir disso, são calculados os erros da rede neural artificial com as amostras da classe alvo original, ou melhor, o treinamento deste cenário é semelhante ao primeiro, sendo que a diferença essencial são os dados selecionados da base não agrupados. Os testes de treinamento efetuados correspondem a variável Voltagem Líquida, Fluoreto de Alumínio (no Banho), Fluoreto de Cálcio (% no Banho), Temperatura de Banho, Intensidade de Corrente, Voltagem Bruta e Pré-Efeito Anódico.

No contexto deste trabalho, o algoritmo K-Means é uma técnica que possui o objetivo de criar k grupos (partições) iniciais, e em seguida, utilizar métricas para realocação iterativa baseada em similaridade, de forma a melhorar a posição do centroide dentro de cada grupo. O Agrupamento Aglomerativo é clustering hierárquico que cria um clusters aninhados mesclando-os ou dividindo-os sucessivamente. Essa hierarquia de clusters é representada como uma árvore (ou dendrograma). O Bich é um algoritmo que constrói uma estrutura de dados em árvore com os centróides do cluster sendo lidos da folha. Cada subcluster mantém uma soma linear, soma quadrada e o número de amostras nesse subcluster (SCIKIT-LEARN, 2018).

5. Resultados e Discussão

Em um primeiro momento, foi utilizada a técnica de amostragem Holdout, onde os dados foram subdivididos em 75% para treinamento e 25% para teste. Os 75% dos dados foram utilizados na indução e no ajuste do modelo e, os exemplos de testes para a avaliação da rede neural, pois apresentam novos objetos ao modelo. O mapa representado na Figura 1 é a representação gráfica simplificada do conhecimento dos dados categóricos de treinamento para três das seis variáveis utilizadas. O mapa pode ser visto como pontos de uma superfície onde representam as variáveis de entrada.

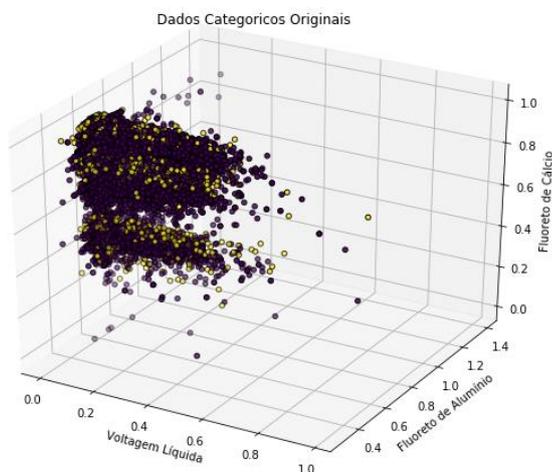


Figura 1. Características da base de dados Originais

A partir da base de dados, demonstrada anteriormente, foi utilizada a técnica K-Means parametrizada em: 2 clusters e medida de distancia euclidiana. O agrupamento 1 é para a situação 'sem pré-efeito anódico' e o agrupamento 2 é para a situação 'com pré-efeito anódico' A Figura 2 apresenta os resultados obtidos após a fase de agrupamento para 75% dos dados.

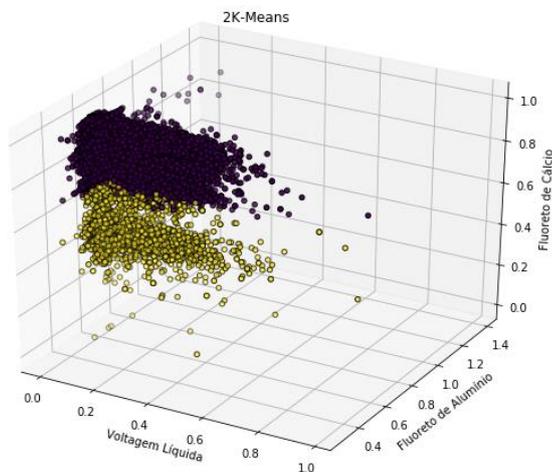


Figura 2. Características da base de dados com K-means

A fim de verificar a desempenho do K-Means, foi efetuado a clusterização utilizando o conjunto de treinamento descrito anteriormente com a técnica de Agrupamento Aglomerativo. O algoritmo foi então configurado para encontrar 2 cluster, medida de distancia euclidiana com critério de vinculação “Ward” (para minimiza a variação dos clusters que estão sendo mesclados) e adicionado restrição de conectividade. A Restrição de conectividade são impostas por meio de uma matriz de conectividade: uma matriz esparsa escassa que possui elementos apenas na interseção de uma linha e uma coluna com índices do conjunto de dados que devem ser conectados (SCIKIT-LEARN, 2018). Essas restrições são úteis para impor uma determinada estrutura local e tornar o algoritmo mais rápido comparado aos sem restrições, especialmente para o nosso número de amostras alto de 80380. Na Figura 3 pode-se observar o resultado do experimento.

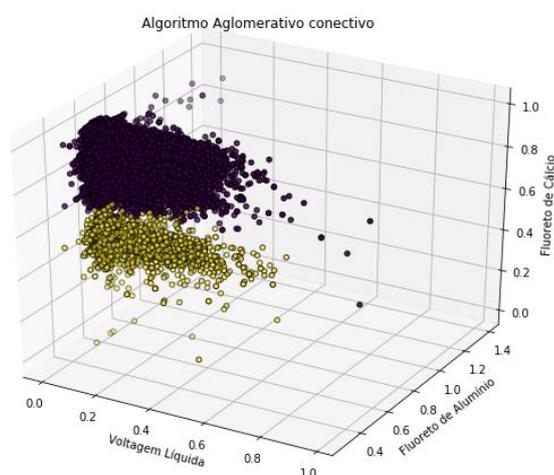


Figura 3. Resultado da base de dados com Agrupamento Aglomerativo

Quanto ao Agrupamento Birch, possui o fator de ramificação de 50 subcluster em cada nó e encontrar 2 cluster.

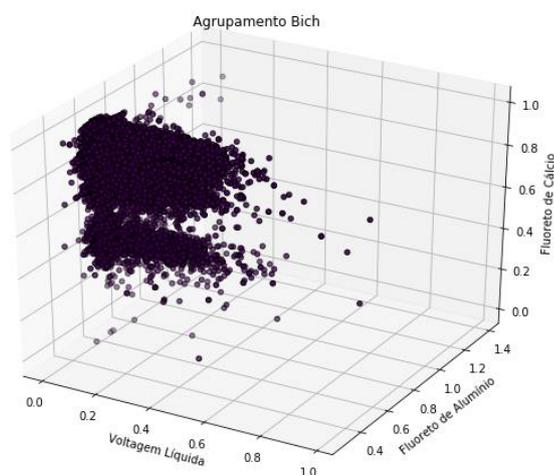


Figura 3. Base de dados com Agrupamento Bich

Dentre os resultados, a técnica de clusterização que apresentou o resultado mais promissor foi o Agrupamento Aglomerativo com melhores resultados ao ser submetido

nos critérios de avaliação adjusted Mutual information (AMI), Homogeneity metric e Completeness metric, conforme a Figura 4.

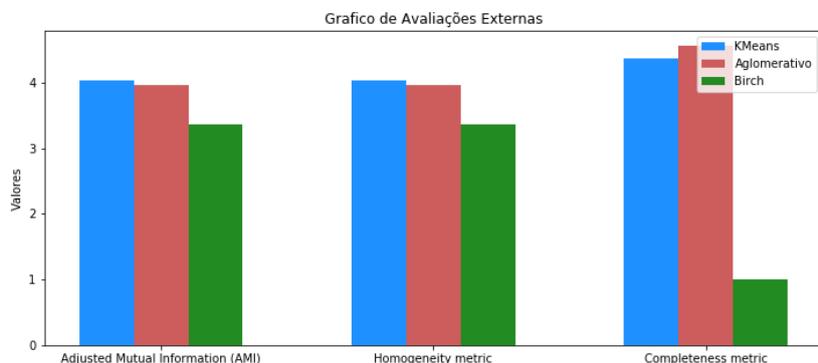


Figura 4. Critérios de avaliações

A partir destes resultados a rede neural artificial se responsabiliza por classificar o problema em questão. Na ocasião, a RNA utilizada no experimento foi “treinada” com os dados de treinamento e seus respectivos rótulos, definidos pela técnica de Agrupamento Aglomerativo sendo duas classes (0) indicador de “não pré-efeito anódico” e o numeral (1) para pré-efeito anódico.

A camada de entrada de dados é composta por 6 “neurônios”, onde são inseridos os dados obtidos na clusterização anterior. Os dados são então processados e enviados para as 2 camadas intermediárias constituída por 8 neurônios cada.

Após a etapa de treinamento o modelo então é criado, agora a nossa rede neural é submetida a uma avaliação com os 25% dos dados de testes que foram inicialmente separados, assim foi possível obter uma acurácia de 87% de acertos na classificação. A Figura 5 mostra um fluxo sobre o algoritmo.

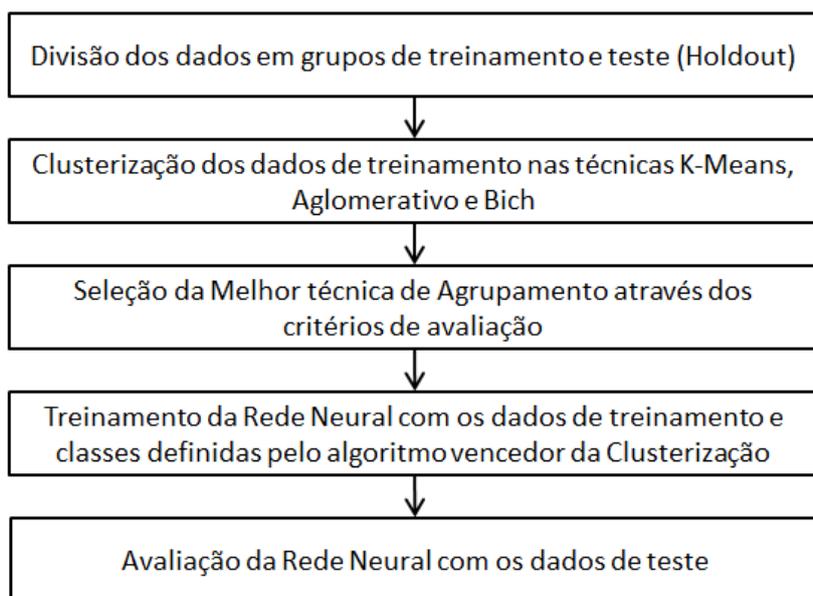


Figura 5. Fluxograma do Modelo Híbrido

Assim criamos um modelo híbrido que é capaz de descobrir sozinho relações, padrões, regularidades e categorias nos dados que lhe foram apresentados e por fim o treinamos sobre esses padrões identificados, permitindo assim, que o pré-efeito anódico seja identificado e realizado previamente ajustes nas variáveis atuais (Voltagem Líquida, Fluoreto de Alumínio, Fluoreto de Cálcio, Temperatura de Banho, Intensidade de Corrente, Voltagem Bruta)

Em caráter complementar o modelo predictor, através do uso combinado de algoritmo de clusterização e de redes neurais se mostrou bastante efetivo para potencializar o poder classificador. Os resultados apontaram que a metodologia “híbrida” é uma ferramenta importante para auxiliar no forno da indústria de redução de alumínio com base nos resultados afirmados na literatura revisada a saber: (CONTE THIAGO, CONTE BRUNO e OLIVEIRA, 2017) mostra a classificação com Redes Neurais Multicamadas Diretas (RNMD) tendo acurácia de 94% e Redes Neurais Recorrentes (RNR) com 83%. Com base aos resultados obtidos de (Thiago, Bruno e Limão, 2018) podemos observar acurácia de 98% seguindo a metodologia de validação cruzada.

6. Considerações finais

Após a clusterização e implementação da Rede Neural Artificial, os resultados gerados foram de ótima aproximação as classes alvos originais e, a precisão da RNA na sua tarefa de classificação depende da variabilidade dos valores das amostras usadas para os seus treinamentos.

A utilidade da aplicação de agrupamento sobre conjuntos de dados de treinamento constitui-se em uma tarefa importante para se obter a essência, a composição dos dados e agilizar a tomada de decisão. Outro ponto de destaque é a melhoria do modelo final, que se torna possível quando se agrega diferentes técnicas em prol do objetivo a ser alcançado.

As técnicas de agrupamento de dados foram utilizadas a fim de atingir um objetivo diferente sobre o problema de classificação do efeito anódico no forno de redução de alumínio.

7. Referências Bibliográficas

- Márcia (2018). Meio Ambiente: uma preocupação mundial. <https://www.sefaz.pi.gov.br>. Dezembro
- Grjotheim, K.; Kvande, H (1993). Introduction to Aluminium Electrolysis Understanding the Hall-Héroult Process. Aluminium-Verlag, 2ª edição.
- ABAL (2017). Alumínio brasileiro: soluções para uma vida sustentável. <http://abal.org.br>. dezembro.
- Conte, Thiago (2015). Modelagem Neural da Resistência Elétrica dos Fornos de Redução do Alumínio, Dissertação de Mestrado em Computação Aplicada, UFPA.
- Silva, Jose (2009). Modelagem Paramétrica de Fornos Eletrolíticas para Predição do Efeito Anódico. Dissertação de Mestrado, Universidade Federal do Maranhão.
- Conte, Thiago; Conte, Bruno; Oliveira, Roberto (2017). Comparação de Modelos Neurais Aplicados para Predição do Efeito Anódico de Fornos de Redução do

Alumínio Primário. In: Conferência Brasileira de Dinâmica, Controle e Aplicações, São José do Rio Preto - SP.

Conte, Thiago; Conte, Bruno; Oliveira, Roberto (2018). Uso de Técnicas de Mineração de Dados para Classificação do Efeito Anódico dos Fornos de Redução de Alumínio Primário. In: 80 Congresso Internacional do Alumínio, São Paulo.

Scikit-Learn (2018). Machine Learning in Python. <https://scikit-learn.org/stable/modules/clustering.html>.