



UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS PARA DETECÇÃO DE ADULTERAÇÃO DE GASOLINA

Camila Chaves Mariano

Ana Paula Alves Duarte

Lucas Duarte Inácio

Giovanni Pereira Bueno

Paulo Roberto Duarte

André Reis

¹Edyene Oliveira

Gisele Mendes

¹edyene.oliveira@prof.una.br

Instituto de Educação Continuada e Pesquisa

Centro Universitário UNA

Rua dos Guajaras, 175 – Centro, 30180-100, Belo Horizonte, MG, Brasil.

Resumo. Atualmente, ainda existem várias amostras de gasolina fora da especificação sendo comercializadas, o que pode ser indício de adulteração. As autoridades brasileiras por meio das ações da ANP (Agência Nacional do Petróleo) estabelecem qualidade mínima dos combustíveis, assegurando-lhes, em princípio, uniformidade da produção à revenda. Porém, tais especificações foram adotadas, em grande parte, visando bom funcionamento do motor e não adulterações. Várias pesquisas têm sido realizadas a fim de identificar com eficiência a qualidade da amostra de gasolina. Porém, os resultados obtidos ainda não oferecem rapidez e praticidade. O objetivo geral desta pesquisa é o estudo de uma metodologia alternativa que emprega as curvas de destilação, obtidas segundo a ASTM D86, em conjunto com técnicas de redes neurais artificiais. Foram utilizadas as RNAs Multi_Layer_Perceptron com os algoritmos Levemberg Marquardt, Bayesian e Scaled. Para modelagem das redes neurais artificiais foi usada a ferramenta Matlab que processou 9.177 amostras de gasolina com 4 tipos de solventes: aguarrás, tinner, solvente de borracha e querosene. Nos testes realizados, a rede neural artificial obteve desempenho de 94%.

Palavras-chave: Gasolina, controle de qualidade, rede neural artificial.

INTRODUÇÃO

A prática da adulteração de combustíveis no Brasil tem gerado apreensão em torno do assunto, o que leva a ANP (Agência Nacional de Petróleo) a reforçar o monitoramento e fiscalização do controle de qualidade (Mendes, 2012).

São muitas as consequências causadas pela utilização da gasolina adulterada, que, por sua vez, acabam danificando os veículos dos consumidores. Se houver excesso de álcool anidro na composição da gasolina, isso causará um desequilíbrio no funcionamento do motor, que consumirá muito mais combustível, além de provocar corrosão no mesmo, sendo necessária limpeza e até mesmo troca das peças que foram danificadas (Takeshita, 2006).

Outra consequência notável é o prejuízo ao meio ambiente, a emissão dos compostos NO_x e SO_x e CO, devido à combustão irregular que é provocada pelo combustível adulterado (Takeshita, 2006).

Existem diversos métodos para verificação de amostras de gasolina para detecção de adulteração. Um método que podemos destacar é a utilização de redes neurais artificiais.

As redes neurais artificiais são capazes de resolver uma série de problemas complexos. Em um ambiente em que os dados mudam constantemente e não há uma lista de preceitos, esse método torna-se muito útil, classificando padrões e criando previsões (Russel, 2010).

1. TRABALHOS CORRELATOS

Atualmente, as redes neurais artificiais (RNA) são utilizadas com êxito para os mais diversos problemas, inclusive na adulteração da gasolina.

O primeiro trabalho analisado foi do autor Ozaki (2010), onde é mostrado que as redes neurais artificiais foram capazes de processar os dados de impedância destes sensores e separá-los de acordo com as classes de adulteração. Neste trabalho foi possível classificar com sucesso adulterações de gasolina agrupando as adulterações em: gasolinas com teor alcoólico elevado; com ponto final de ebulição baixo; e com temperatura acima de 90% na destilação.

Em Borsato (2009) foi utilizado um modelo de RNA multicamada Perceptron para classificar amostras de gasolina. A aplicação da rede neural artificial serviu para classificar 100% do gás comercializado na região de Londrina-PR e identificar a gasolina adulterada, mesmo os suspeitos de adulteração.

Também, Viterbo (2011), desenvolveu um modelo de RNA utilizando topologia Multilayer Perceptron com uma camada oculta. O método de treinamento foi Levenberg-Marquardt backpropagation. Segundo o autor, os resultados contribuíram no sentido de preencher uma lacuna existente na determinação qualitativa da concentração relativa de compostos por espectroscopia na região do infravermelho.

Diante dos trabalhos existentes na literatura, este projeto possui diferenças na análise da base de dados. Não foi encontrado pesquisas com este mesmo viés, ou seja, que utilizou destilação da gasolina.

Nos casos citados, o mais próximo foi o de Ozaki (2010), porém, a destilação usada foi apenas uma das variáveis. No presente trabalho, a base de dados é composta por características de destilação. Embora o modelo de RNA seja clássico, tanto os algoritmos usados para treinamento quanto as características contribuem para novas pesquisas. Os autores deste trabalho estão pesquisando na mesma linha, porém, com outros modelos de RNA.

2. REFERENCIAL TEÓRICO

2.1 Redes Neurais Artificiais

Segundo Haykin (2009), as Redes Neurais Artificiais (RNA) apresentam dentre suas características modelos matemáticos que se assemelham às estruturas neurais biológicas. Essas possuem capacidade computacional adquirida por meio de aprendizado e generalização de estruturas chamadas de neurônios. O neurônio, por sua vez, é a unidade de processamento de informação que é fundamental para a operação da rede. Nele, tem-se uma função de ativação, que restringe a amplitude da saída do neurônio durante o treinamento.

As redes neurais artificiais são consideradas aproximadoras universais, podem aproximar qualquer função matemática. Inspirada nas funções fisiológicas do cérebro humano e do seu componente primário, o neurônio, conseguem reproduzir o comportamento multivariável e não linear entre variáveis a partir de um aprendizado anterior (Russell, 2010).

Redes neurais artificiais são utilizadas como ferramenta para solução de vários problemas, como: classificação, reconhecimento de voz, reconhecimento de imagens, previsões em áreas bem distantes umas das outras, mercado de ações e medicina (Rezende, 2005).

A estrutura apresentada na Figura 1 é o modelo básico de um neurônio artificial. O conjunto de valores representados por x_1 ..até x_m indicam os valores de entrada e o w_i os pesos sinápticos. Esses valores são multiplicados entre si para gerar a junção aditiva, além do valor de entrada, Bias b_k .




Figura 1: Modelo de um neurônio matemático

Para que uma rede neural artificial possa ser treinada existe um algoritmo específico para esta finalidade. São programas tradicionais escritos usando paradigma estruturado denominado algoritmo de aprendizagem. Tais algoritmos podem ser ou não supervisionados (Rezende, 2005). A definição de qual tipo utilizar depende do problema abordado. Caso seja problema de classificação ou previsão, o algoritmo de aprendizagem será o supervisionado. Para estes casos, ao informar o padrão, deve ser informado também a resposta correspondente ao padrão apresentado. Por outro lado, se for um problema de categorização, o algoritmo usado deve ser não supervisionado. Afinal, o objetivo é gerar classes, logo, a RNA irá receber os padrões de entrada e irá agrupá-los segundo a similaridade (Samarasinghe, 2007).

2.2 Metodologia

Este trabalho teve como objetivo explorar técnicas de detecção de adulteração de gasolina, utilizando curvas de destilação obtidas segundo a ASTM D86, juntamente com métodos de redes neurais artificiais, para o controle de qualidade deste combustível.

Os dados utilizados neste trabalho como referência para Rede Neural Artificial foi proveniente do trabalho de (Mendes, 2012). O conjunto de dados totalizou 9.267 amostras. Os experimentos foram realizados com a gasolina misturada com 4 (quatro) tipos de solventes, com a temperatura variando entre 4°C e 98°C. O volume de mistura variou entre 6% e 50% de cada solvente sendo medidos no momento da ebulição.

Para treinamento da RNA, o conjunto de dados foi dividido em 3 partes, sendo 80% (7.431) utilizados para treinamento, 10% (918) para validação e 10% (918) para testes do modelo.

As camadas de entradas das RNAs receberam três dados: tempo (momento de ebulição da gasolina), temperatura e porcentagem de mistura diluída. A camada de saída esperada era o tipo de adulteração utilizada na amostra da gasolina, e foi composta por 4 neurônios: aguarrás (A), querosene (Q), solvente de borracha (SB) e tinner (T).

Como a saída continha quatro tipos distintos optou-se por normalizar os valores, pois as RNAs apresentam melhor desempenho quando os dados estão normalizados ou binários. Outra característica importante é que as RNAs trabalham com dados numéricos que podem ser discretos (inteiros) ou contínuos (decimais). Sendo assim os tipos de misturas foram codificados em valores discretos, como, 1, 2, 3 e 4. Esses valores foram associados às informações acima, ou seja, (1- aguarrás, 2 –querosene, 3 – solvente de borracha, 4 –tinner). Em seguida foram inseridos na RNA como dados binários. A saída ficou semelhante à Tabela 1:

Tabela 1. Solventes diluídos na gasolina

Dados nominais	Dados Normalizados
Aguarrás	0001
Querosene	0010
Solvente de borracha	0011
Tinner	0100

3. ANÁLISE DOS RESULTADOS

A rede neural artificial *feedforward* empregada neste trabalho com o algoritmo do tipo *Bayesian Regularization* obteve melhores resultados em relação às outras duas RNAs, atingindo uma convergência de até 94% durante o treinamento.

Já a RNA que utilizou o algoritmo *Backpropagation Levenberg Marquadt* teve um desempenho menor em relação ao algoritmo de treinamento *Scaled*, atingindo 91% de acertos na fase de treinamento. Ao aumentar a quantidade de neurônios de 150 para 200, não houve alteração no percentual de desempenho. Porém de 200 para 300 neurônios houve aumento significativo de 1%, atingido o máximo de acerto desta RNA durante os treinamentos.

Os resultados apresentados pela RNA com algoritmo *Scaled Conjugate Gradient* condiz com o tipo de algoritmo, pois ele é rápido, não consome grande quantidade de memória da máquina e, interrompe o treinamento quando o erro aumenta. O número máximo de épocas para o treinamento das três RNAs foi estipulado em 1000 repetições. Porém, este algoritmo assim como o *Levenberg Marquadt* utilizam desempenho da RNA como critério de parada. O algoritmo continua o processamento enquanto houver melhoria nos resultados. A partir da estagnação da curva de desempenho, o algoritmo interrompe o treinamento. O percentual máximo de desempenho do algoritmo *Scaled Conjugate Gradient* foi de 92%.

A Tabela 2 mostra os percentuais de desempenho máximo obtidos das 3 RNAs utilizadas:

Tabela 2. Desempenho máximo dos testes das três RNAs

Tipo de rede	Train/Val/Test	Neurônios	Desempenho da RNA
Bayesian	80% 10% 10%	300	94%
Levenberg	80% 10% 10%	300	91%
Scaled	80% 10% 10%	300	92%

A Figura 2 mostra o gráfico de regressão da RNA que obteve melhor resultado com a respectiva quantidade de neurônios utilizada no experimento. Os valores de R na regressão indicam a correlação entre os dados de entrada e os valores de saída. Desta forma, para valores de R iguais a 1 significa uma estreita relação, ao passo que se R for igual a 0 (zero), a RNA não conseguiu aproximar ou encontrar relação entre a entrada e a saída.

Foram realizadas cerca de 30 execuções com variadas quantidades de neurônios, taxas de aprendizagem e momento. Porém, os resultados que apresentaram valores acima de 90% foram apresentados na Tabela 2.

Foi realizado teste com a base de dados normalizada e com os valores em estado bruto. No caso das características, os resultados não apresentaram diferenças em relação aos normalizados, portanto, neste trabalho optou-se por não explicitar.

Apenas as classes de saída foram normalizadas, pois apresentaram melhores performance.




Figura 2. Gráfico de desempenho da RNA Bayesiana

4. CONSIDERAÇÕES FINAIS

A aplicação de RNAs no tratamento de dados é especialmente importante quando os sistemas são não lineares e possuem comportamentos complexos.

Neste trabalho, as redes neurais artificiais obtiveram resultados satisfatórios, pois identificar amostras com misturas em tempo relativamente rápido é complexo. Os modelos gerados classificaram dados obtidos a partir da curva de destilação da gasolina, realizado por (Mendes, 2012). Os dados de entrada bem como as classes foram bem definidos o que contribuiu para o bom desempenho dos modelos. As RNAs geradas pertencem aos modelos clássicos, porém, alcançaram a finalidade esperada. Os testes realizados obtiveram resultados entre 91% e de 94%.

Esse trabalho tem como intuito prosseguir com outros dados e variáveis, além de geração de modelos como RNAs de contexto. Dados como pressão de vapor e octanagem da gasolina já estão sendo testados.

Pretende-se explorar a curva de destilação e, posteriormente, como trabalho futuro, gerar modelos de deep learning.

AGRADECIMENTOS

A nossa orientadora de projeto Edylene Oliveira pela orientação e incentivo.

A Gisele que nos concedeu os dados de sua tese e esteve a disposição para esclarecimento de dúvidas.

Ao Centro Universitário Una, principalmente ao coordenador Rodrigo Almeida e a diretora Tatiane Puiati pelo apoio financeiro.

REFERÊNCIAS

- Borsato, Dionísio. 2009. *Aplicação de redes neurais artificiais na identificação de gasolinas adulteradas comercializadas na região de Londrina - Paraná*. Quím. Nova, São Paulo, v. 32, n. 9, p. 2328-2332.
- Haykin, Simon, 2009. *Neural Networks and Learning Machines*, 3ª edição, New Jersey, Prentice Hall.
- Mendes, Gisele. 2012. *Detecção de adulterações em gasolina e previsão de parâmetros físico-químicos a partir de curvas de destilação associadas a ferramentas quimiométricas*. Tese de doutorado, Universidade Federal de Minas Gerais/Brasil.
- Ozaki S.T.R., 2010. *Detecção de adulteração de combustíveis com sensores poliméricos eletro depositados e redes neurais artificiais*. São Paulo.
- Rezende, S.O., 2005. *Sistemas Inteligentes – Fundamentos e aplicações*. Barueri, SP. Editora Manole.
- Russell, Stuart; Norvig, Peter., 2010. *Artificial Intelligence - A Modern Approach*, Third Edition, New Jersey, Prentice Hall Series em Inteligência Artificial.
- Samarasinghe, Sandhya., 2007. *Neural Networks for Applied Sciences and Engineering: From Fundamentals to Complex Pattern Recognition*, New Jersey, Auerback Publications.
- Takeshita E.V.Souza S.M.A.G.U.Souza A.A.U., 2007. *Adulteração de gasolina por adição de solventes: análise dos parâmetros físico-químicos*. Tese de Mestrado, Campinas, SP, Brasil.
- Viterbo, D. Vitor., (2011) *Classificação pela Concentração Relativa de Compostos Químicos Complexos por Redes Neurais Artificiais sobre Espectros Infravermelhos: O Caso de Adulteração de Combustíveis*. Dissertação de Mestrado. CEFET-MG, Brasil.