



DETECÇÃO DE ADULTERAÇÃO DA GASOLINA UTILIZANDO REDES NEURAIS ARTIFICIAIS

Victor Oliveira Silva
Carina de Souza
Sandro Maia Quirino
Carla Araújo Parreira
Silvio Lacerda Silva
Edyene Cely Oliveira
Gisele Mendes
edyene.oliveira@gmail.com

Instituto de Educação Continuada e Pesquisa
Centro Universitário UNA
Rua dos Guajaras, 175 - Centro, Belo Horizonte, 30180-100, Minas Gerais, Brasil

Abstract: *Brazilians have been affected by the commerce of adulterated gasoline. The ANP (Brazilian National Agency of Petroleum, Natural Gas and Biofuels) is responsible for inspection of fuel quality which is offered to the final consumers. In addition, they collect samples from stations and perform all the laboratory analysis to verify if it is in conformity with the specified parameters. In order to make this process faster and efficient, some alternatives have been developed. This article proposes the identification of gasoline adulteration using Artificial Neural Networks (RNA). For this reason, it was used some data concerning the distillation of gasoline as the input parameter for RNA. After the analysis, values were specified for gasoline in compliance with both standards and different levels of adulteration. Thus, the RNA has been elaborated and configured, being able to respond with a high level of precision, in case that gasoline has been either adulterated or unadulterated.*

Keywords: *Artificial neural network, Adulterated gasoline, Gasoline distillation, Detection of adulteration of petrol by distillation.*

1. INTRODUÇÃO

A adulteração da gasolina é um problema que afeta grande parte dos brasileiros atualmente, ainda que os mesmos não tenham consciência deste fato. A lei nº 8176 define que:

[...] define-se, como crime contra a Ordem Econômica, o tipo Penal da venda de combustíveis adulterados, popularmente conhecido como adulteração de combustíveis, que compreende a aquisição, distribuição e revenda de derivados do petróleo, gás natural e suas frações recuperáveis, dentre outros combustíveis líquidos carburantes, em acordo com os parâmetros legais (Brasil, 1991).

Existe um percentual de adição de etanol de 27% na gasolina comum e 25% na gasolina Premium definidos pelo governo federal. Porém devido ao baixo custo do etanol em relação a gasolina e de outros solventes como, por exemplo aguarrás, querosene, solvente de borracha e thinner, estes são adicionados em porcentagens não permitidas a fim de elevar o lucro dos proprietários de postos de gasolina (Petrobrás, 2014). Dessa forma, ao adquirir um combustível não conforme com as normas, o veículo funcionará com menor desempenho, podendo trazer sérios danos ao motor, acarretando prejuízos ao usuário (Fogaça, s.d b).

Atualmente existem poucos estudos sobre métodos eficientes capazes de detectar rapidamente um combustível adulterado. Porém um pesquisador da UNICAMP desenvolveu um sistema ótico capaz de medir variações no índice de refração da gasolina, com alta sensibilidade, através de análises gráficas atual com o modelo salvo no sistema (Cordeiro, 2009).

Dentre as formas de análise de resultados para verificar a possível adulteração na gasolina, está o uso de uma Rede Neural Artificial (RNA). A RNA é um modelo matemático computacional capaz de gerar saídas de sistemas que possam generalizar as características das entradas (Braga, 2007).

Com base nisto, viu-se que é possível desenvolver uma rede neural capaz de realizar a distinção entre gasolina conforme e adulterada a partir do treinamento sobre uma base de dados com informações conhecidas. Isso torna o processo de análise mais rápido para que as ações contra os postos ocorram em um tempo menor evitando assim que o consumidor final seja prejudicado.

Desta forma este trabalho tem por finalidade avaliar os dados contidos na base de dados gerados por (Mendes, 2012), referente às curvas de destilação de várias amostras de gasolina, para identificar as variáveis que possam indicar irregularidades na mesma. Em seguida, gerar um modelo de RNA apta a apontar anormalidades na gasolina a partir das características recebidas.

2. REFERENCIAL TEÓRICO

2.1 A gasolina

A gasolina é um produto derivado do petróleo formado por vários compostos químicos denominados hidrocarbonetos. Ao sofrer explosão na câmara de combustão, produz energia para que o motor movimente os veículos, libera CO₂ e vapor de água (Del Pino, 1996).

Segundo a Petrobrás, as gasolinas comercializadas no Brasil são classificadas em dois tipos: Comum e Premium, sendo, portanto, diferenciadas pela octanagem. A gasolina do tipo Comum possui octanagem mínima de 87 IAD (Índice Anti Detonação), e a gasolina do tipo Premium contém octanagem mínima de 95 IAD. Todas elas recebem adição de álcool anidro dentro do percentual permitido pela Portaria ANP nº 309 de 27/12/2001 cabendo aos distribuidores colocar demais aditivos.

A octanagem é a resistência à compressão, também conhecida por índice de octanas. Geralmente, as adulterações na gasolina a diminuem, e quando esse índice é baixo, pode ocorrer mal funcionamento do motor e/ou diminuição da sua potência. Tendo isso em vista, a gasolina é considerada de melhor qualidade, quando resiste a essa taxa de compressão sem sofrer combustão prematura. Infelizmente, a análise de adulteração não pode ser realizada a partir deste índice, pois, em alguns casos, a adulteração pode levar ao aumento da octanagem, como é o caso da adição do etanol, aditivo mais usado pelos distribuidores, visto que seu custo é mais barato que da gasolina, assim aumentando seus lucros. Essa adição também pode acarretar sérios problemas aos veículos. Além disso, cada posto possui um tipo de aditivos que modificam os níveis de octanagem, não sendo possível fazer uma padronização desse valor (Fogaça, s.d a) (Pinheiro, 2014).

Geralmente, a adulteração da gasolina é feita acrescentando-se etanol, porém, podem ser adicionados também querosene, óleo diesel, aguarrás e solvente de borracha. Esses são os principais produtos utilizados para adulteração, e uma justificativa básica para isso é que todos eles são solúveis na gasolina (Fogaça, s.d b).

A adulteração da gasolina pode prejudicar o motor porque ocorre uma injeção de uma mistura empobrecida de ar/combustível. Com a adulteração, a gasolina tem seu poder calorífico diminuído e isso proporciona uma redução de potência causando falhas no funcionamento do motor e até corrosão de peças (Takeshita, 2006).

A Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP) é responsável pela fiscalização da adulteração de combustível, e para isso mantém o Programa de Monitoramento da Qualidade dos Combustíveis em que uma amostra da gasolina é coletada para que sejam realizados testes em laboratório. Após a realização dos testes, são divulgados boletins mensais disponíveis para acesso. No mês de maio de 2017, 8.998 amostras foram coletadas e 246 não estavam em conformidade com as especificações (ANP, 2017).

2.2 Métodos simples de detecção de adulteração da gasolina

Dentre as várias maneiras de detectar adulterações em gasolina, a mais clássica é o teste de proveta. Este teste tem por finalidade detecção de adulteração por etanol. Para realização deste, basta colocar 50 ml de gasolina na proveta e, em seguida, adicionar 50 ml de solução de cloreto de sódio. Com a mesma tampada, mistura-se lentamente a gasolina e a solução, em seguida, deixa a mistura em repouso por um instante. A solução de cloreto de sódio, mais especificamente, a água, retira o álcool contido na gasolina (Lima, 2009).

Por meio da diferença de densidade, é possível perceber a olho nu a separação que ocorre, na qual a água fica na parte inferior juntamente com o álcool que se uniu à ela e a gasolina na parte superior da proveta. Para determinar se a quantidade de etanol presente na gasolina está dentro dos parâmetros estabelecidos por lei, basta ver quanto de álcool foi retirado dela e realizar uma regra de três simples. A Figura 1 exemplifica esse processo (Lima, 2009).




Figura 1: Teste rápido de adulteração de gasolina

Fonte: (Carro & Carros, s.d.)

Para detectar adulteração com uso de óleo diesel o teste pode ser efetuado por meio de exposição a luz ultravioleta. O diesel emite uma fluorescência que causa um aspecto turvo na mistura (Eberlim, 2011).

2.3 Método de detecção por destilação

A destilação é um processo de separação de dois componentes envolvidos, sendo dois líquidos ou, um líquido e um sólido (saís). Esta pode ser do tipo simples ou fracionada, sendo, a simples utilizada para separar saís de líquidos e a fracionada para separar dois líquidos (Levorato, 2006).

Assim como espectroscopia de infravermelho, a curva de destilação permite a previsão de propriedades físico-químicas da gasolina. Por meio da mesma, pode-se notar os desvios gerados pelos adulterantes, pois cada tipo de adulterante modifica uma propriedade específica da gasolina, sendo assim é possível a identificação de adulteração e do adulterante. Estudos recentes têm mostrado que as curvas de destilação em conjunto com ferramentas quimiométricas apresentaram resultados melhores ou similares aos obtidos pelos métodos cromatográficos e espectroscópicos (Mendes, 2012).

Esta técnica é um importante objeto de análise de adulteração, sendo a maioria dos casos de adulteração registrados no Brasil, constantes como não conforme na curva de destilação, seguido de adulteração por etanol anidro e por último a octanagem (Takeshita, 2006).

O controle de qualidade da ANP estipula valores de temperatura aos quais a curva de destilação da gasolina deve respeitar. Os pontos da curva requeridos para análise são percentuais de volume recuperado de 10%, 50% e 90% além do ponto final. Esta curva é

gerada com dados oriundos da destilação que pode ser feita por processo manual ou utilizando um destilador automático (Mendes, 2012).

2.4 Redes neurais artificiais

Conhecida também por sua sigla RNA, a rede neural artificial, é um ramo da inteligência artificial (IA), projetado para modelar o funcionamento do cérebro humano, por meio de simulações computacionais, empregando associação de neurônios para solução de problemas complexos (Fleck et al., 2016).

O entendimento de redes neurais artificiais requer a utilização de termos aplicados à rede neural biológica, correspondentes à constituição de um neurônio. Quando o neurônio recebe alguma informação, por meio dos impulsos elétricos, os dendritos, transmitem a informação para outros neurônios, onde através da sinapse, faz a conexão entre os neurônios de uma rede. Tais neurônios conectados, fazem associação de informações recebidas, que pode ser comparada à um somatório matemático e assim fazendo essa troca de informações a todo instante (Ludwig, 2007).

A classificação das RNAs podem ser dadas de duas maneiras: A primeira é através da arquitetura da rede neural, que considera o número de camadas e o número de neurônios por cada camada. Toda RNA é constituída por uma camada de entrada e outra de saída, tendo como referência da arquitetura o número variável de camadas entre a camada de entrada e a camada de saída. É através da arquitetura de uma RNA, que se pode dizer o tipo de problema que a rede é capaz de resolver (Alves, 2007).

Por sua vez, a segunda classificação é realizada pelo tipo de conectividade entre as camadas, podendo ser totalmente conectada ou fracamente conectada, onde no primeiro caso, todos os neurônios de uma camada estão ligados a todos os neurônios da camada adjacente. No segundo caso os neurônios de uma camada não estão totalmente conectados à camada adjacente, não realizando conexões sinápticas entre todos os elos (Alves, 2007).

A principal propriedade de uma RNA está relacionada com a sua capacidade de aprendizado e de generalização, realizada pelo ajuste de parâmetros da rede. Neste aprendizado, existe um elemento que faz a comparação entre o valor de saída desejado e o valor de saída que foi encontrado. Após a comparação, as sinapses são ajustadas com o objetivo de diminuir a diferença entre as duas informações comparadas, aproximando-se do valor desejado e gerando um modelo não-linear, tornando sua aplicação bastante eficiente (Ludwig, 2007) (Spörl et al., 2011).

2.5 Validação de dados por RNA

Para obter um resultado eficaz através das redes neurais, é necessário trabalhar com um banco de dados consistente que nem sempre precisa ser grande, ou seja, os dados precisam conter informações que facilite a generalização e correlação entre as variáveis de entrada. Tais dados devem ser tratados e normalizados antes de serem enviados à rede. Dentre os tratamentos está a eliminação de outliers. Um outlier pode ser definido como um ponto ou valor de amostra que se encontra muito distante dos demais valores encontrados em uma base de dados (Figueira, 1998).

Para configurar uma rede neural artificial, deve ser analisado cada caso em particular, e estudado cada tipo de arquitetura de rede, para se obter o melhor resultado possível. Complexidade, tempo de treinamento, tempo de classificação e outros parâmetros devem ser levados em consideração sempre que for escolher um modelo de rede neural (Braga, 2007).

A equação (1) e a figura 2 mostra o gráfico formado pela função Sigmoid, que será utilizada (tipo de função mais utilizada na elaboração de RNAs). Tem como equação:

$$f(x) = \frac{1}{(1 + \exp(-x))} \quad (1)$$




Figura 2: Função Sigmoid

Fonte: Autores, 2017

A normalização é outra técnica formal que analisa os dados e os agrupa na melhor forma, minimizando o impacto dessas possíveis mudanças no funcionamento do sistema. Para deixar os dados mais coesos e facilitar a atuação dos softwares trabalhados, a normalização é realizada com base na fórmula a seguir (Caldeira, 2003):

$$V_{\text{normal}} = \frac{V_{\text{real}} - V_{\text{min}}}{V_{\text{max}} - V_{\text{min}}} \quad (2)$$

Sendo que:

V_{real} = Valor real da variável

V_{min} = Valor mínimo da variável

V_{max} = Valor máximo da variável

Após tratar os dados e definir o tipo de rede, devem-se dividir os dados em 2 grupos: Treinamento e Teste, onde o grupo de treinamento será responsável por treinar o sistema com o objetivo de obter uma consistência entre os valores e criar um padrão. O segundo grupo, de teste, servirá para testar a eficiência da rede, obtendo os resultados (Braga, 2007).

3. MATERIAIS E MÉTODOS

3.1 Substâncias/Materiais trabalhos

Para o desenvolvimento da RNA foram, primeiramente, efetuadas análises de gasolinas, não adulteradas e de gasolinas adulteradas, com determinados tipos de solventes a fim de se obter uma curva de destilação (Mendes, 2012).

Para aferir tais valores, na tese acima citada, foi utilizado o equipamento destilador automático Herzog, modelo HDA 627 (Figura 3). Este é composto por condensador, fonte de aquecimento, banho de resfriamento, sistema de medição e registro automático de temperatura e volume recuperado referentes ao cilindro coletor (Mendes, 2012).




Figura 3: Componentes do destilador segundo a ASTM D86

Fonte: Mendes, 2012

Os resultados gerados foram inseridos em um banco de dados, utilizado neste projeto para o treinamento e validação da rede. Deste banco de dados, 4.770 foram de amostras não-adulteradas e 9.270 de amostras adulteradas. Para realização deste projeto foi necessário trabalhar o banco de dados no Microsoft Excel e aplicá-lo ao Matlab, software responsável por criar, treinar e validar a rede neural artificial.

3.2 Processamento dos dados

Antes de gerar o modelo de RNA os dados originais foram processados. As variáveis de entrada utilizadas para a RNA foram: tempo e temperatura. A saída foi composta por uma classe (Sim ou Não), se a gasolina está ou não adulterada.

A Tabela 1 mostram os dados estatísticos das variáveis do banco de dados. É possível visualizar dados como valor mínimo, valor máximo, média e desvio padrão das variáveis existentes. Isso torna possível uma melhor avaliação da consistência destes dados, definindo sua importância para a criação da RNA.

A exclusão de alguns dados foi baseada na estatística. Pode ser considerado que: se os valores presentes na base de dados estudada estão entre o valor da média calculada ($\bar{x}$) e mais ou menos duas vezes e meia o desvio padrão (s) encontrado ($\bar{x} \pm 2,5*s$), pode-se garantir que mais de 98% dos valores estarão dentro do intervalo desejado. Os dados estatísticos necessários para fazer esses cálculos, juntamente com os valores de outliers encontrados, são exibidos na tabela 1 (Bráulio, 2015).

Tabela 1. Dados estatísticos das variáveis trabalhadas

Variáveis	Tempo (s)	Temperatura (°C)
Média	48.5	99.12
Desvio padrão	25.98	43.65
Valor mínimo	4	48.8
Valor máximo	93	227.2
Outlier superior	113.45	208,23
Outlier inferior	3.46	11.82

Após essa análise, dos 14.040 dados, 142 dados foram excluídos da base de dados por exceder os valores consistentes de outliers, o que corresponde a 1,01%. Sendo assim, a planilha a ser utilizada, passa a ter 13.898 dados, 4.770 não-adulteradas e 9.128 adulteradas.

3.3 Definição do modelo de rede neural artificial

O primeiro passo para o desenvolvimento da rede neural artificial no Matlab foi a importação dos dados de entrada e de saída, sendo declarados em forma de matriz. Após a importação para o Matlab da matriz de entrada e de saída na rede, torna-se necessária a escolha da rede, no caso deste projeto pode ser utilizada *Neural Net Fitting*, pois permite trabalhar com as duas camadas (entrada e saída) e com sistema *feed-forward*, método de aperfeiçoamento de aprendizagem, podendo realizar reconhecimento de padrões.

Este tipo de rede já define os parâmetros de treinamento (número de repetições, tempo de treinamento, interações, máximo de validação e valor mínimo de performance), mas podem ser alterados caso seja necessário. Nas versões mais recentes do Matlab, a arquitetura Perceptron multicamadas (MLP) teve seus atributos incluídos no modelo *feed-forward* citado acima, informações essas que são obtidas direto do menu Help do software.

3.4 Configuração da rede

Posteriormente é necessária uma configuração do percentual de amostras que será utilizado para treinamento, validação (responsável por medir a generalização da rede e interromper o treinamento), teste de desempenho do software e teste de eficiência. Deve ser efetuada a configuração dos neurônios da camada escondida, onde exige atenção, pois caso sejam utilizados poucos neurônios, ocorre uma baixa capacidade de generalização, conhecida como *underfitting*, porém ao utilizar neurônios em excesso, a rede perde sua capacidade preditiva, conhecida como *overfitting*, portanto para se obter um resultado satisfatório é preciso realizar testes da rede com quantidades diferentes de neurônios baseados em tentativa e erro. Alguns estudos sugerem que a quantidade de neurônios nessa camada, não ultrapasse a 10% do tamanho do banco de dados (Andrade, 2011).

3.5 Algoritmo da rede

O tipo de rede definido para este projeto conta com três algoritmos que realizam o treinamento de diferentes formas, estes são:

a) Levenberg Marquardt

É o algoritmo de *backpropagation* mais rápido dentre os trabalhados pelo software, porém, o que mais consome memória. O treinamento finaliza quando a rede pára de melhorar o desempenho por 6 períodos ou épocas, indicada por um aumento no erro quadrático médio, durante a validação. (Matlab, s.d a).

b) Bayesian Regularization

Este algoritmo é o mais demorado e preciso dentre os trabalhados pelo Matlab. Tem boa capacidade de generalização com bancos de dados difíceis ou ruidosos. O processo é chamado de regularização bayesiana. As paradas de validação são desabilitadas por padrão, sendo assim, o treinamento só finaliza quando há uma minimização máxima dos erros e pesos ou quando atingir 1000 repetições (Matlab, s.d b).

c) Scaled Conjugate Gradient

O algoritmo gradiente conjugado escalado é baseado em cálculos de erros quadrados em direções conjugadas e não executa uma verificação em cada iteração. É o modelo que consome menos memória.

O treino para quando ocorre uma dessas condições:

- O número máximo de repetições é atingido;
- O tempo máximo é excedido;
- O desempenho da validação aumentou muito desde a última vez que diminuiu, quando se usa essa validação;
- Quando há um aumento no erro quadrático médio (Matlab, s.d c).

4. REALIZAÇÃO DE TESTES

Definidos os parâmetros, alguns testes e modificações foram realizados com o intuito de obter o melhor aproveitamento possível da rede. Dentre as modificações mais comuns estão: o número de neurônios, a porcentagem de dados para treino, validação, teste e algoritmo da

rede, como descritos anteriormente. Em todos os testes, os dados inseridos no Matlab, não tiveram nenhum contato com a rede em treinamento, sendo assim, toda a eficiência da rede é devido à sua capacidade de previsão.

Como forma de “dificultar” o trabalho da rede, os dados foram misturados entre si, e dentre os testes, dados de várias regiões da planilha foram coletados para fazer a validação da rede. Desta forma, é garantida a aleatoriedade dos valores, sem nenhum tipo de padrão inicial.

4.1 Testes com 20% de dados para testes e variação da porcentagem dos parâmetros

Foram testados os três algoritmos mencionados nos item 3.5 a, b e c com a *Neural Net Fiting* com 200 neurônios (definido ao acaso) e com 20% do banco de dados para testar a eficiência da rede. Dos 80% restantes, 65% dos dados foram para treinamento, 20% para validação e 15% para testes de generalização de resultados do processo do Matlab. Após a conclusão, os dados para testar a eficiência foram inseridos no sistema e o resultado foi comparado com o valor desejado (real) e então calculado a eficiência do modelo. Terminado os comparativos com as três arquiteturas, foram realizados ajustes na porcentagem de dados de treino, validação e teste de generalização para 70%, 25% e 5%, depois para 75%, 20% e 5%, para 70%, 20% e 10%, para 60%, 25% e 15% e por fim 70%, 15% e 15% respectivamente e novamente a eficiência foi medida para os três algoritmos.

4.2 Teste com 20% de dados para testes e variando a quantidade de neurônios

Como forma de tentar melhorar a eficiência dos modelos, a quantidade de neurônios foi modificada para 500 e depois para 1000, que se aproxima do limite definido por Andrade (2011). Dessa vez, a porcentagem de dados para treino, validação e teste foram 70%, 25% e 5% e depois 65%, 20% e 15% respectivamente para cada quantidade de neurônios, pois foram as que tiveram melhores rendimentos no item anterior. Criadas as redes e testadas as eficiências desses modelos, os resultados foram salvos para serem comparados.

4.3 Teste com 30% de dados para testes e variando parâmetros e neurônios

Nesta fase, optou-se por aumentar a porcentagem de dados de teste de eficiência em 10%, passando a ter 4.169 dados. De forma similar, novas redes foram criadas, com os três algoritmos e testes foram realizados com 70%, 25% e 5% e 65%, 20% e 10% de treino, validação e teste de generalização, respectivamente, com 200 e 1000 neurônios.

5. ANÁLISE DOS RESULTADOS

Ao final dos testes, os dados obtidos como possíveis saídas para a rede que foi testada, foram exportadas para o Excel que fez a comparação do valor obtido com o valor desejado (valor real), e o resultado foi exibido em porcentagem de acertos.

5.1 Eficiência

Analisados os dados da saída desejada com os dados obtidos através das redes neurais criadas, de diversos testes, o melhor aproveitamento constatado dentre todos eles foi de 95,5%, utilizando 200 neurônios, 70% dos dados para treino, 25% para validação e 5% para testes no próprio software. Além disso, 2.779 dados, equivalente a 20% do total, ficaram responsáveis por testar a eficiência da rede após o treinamento, constatando tal assertividade. A diferença do pior para o melhor resultado foi de 7,5%.

Dessa forma, com esse aproveitamento alto, se torna viável a utilização desse método como forma de detecção de adulteração da gasolina associada às curvas de destilação das mesmas. Assim, reduzindo bastante o tempo de análise do combustível, permitindo notificar os usuários e postos de combustível sobre uma possível adulteração, garantindo menores prejuízos aos usuários, que rapidamente saberão o estado dos combustíveis dos postos. Os resultados do melhor teste são exibidos na figura 4.

SAÍDAS		Saída Obtida padronizada	Comparação das saídas	Dados testados 2779 Acertos 2654 Acetividade 95,5%
Desejada	Obtida			
0	0,06066	0	1	
0	0,0122	0	1	
1	1,03201	1	1	
0	0,39017	0	1	
1	0,98855	1	1	
1	1,01306	1	1	
0	-0,0427	0	1	
1	0,44251	0	0	
1	0,96724	1	1	
1	0,99058	1	1	
1	0,24025	0	0	

Figura 4: Resultados finais

Fonte: Captura de tela do software Excel, Autores, 2017

5.2 Dificuldades apresentadas e trabalhos futuros

Entender e tratar os bancos de dados disponibilizados por Mendes (2012), de modo a deixá-lo no padrão aceito pela rede, além das dificuldades em definir o modelo de rede e especificação do algoritmo que retorna a maior quantidade de acertos.

Para o desenvolvimento de trabalhos futuros serão realizados testes em laboratório utilizando gasolina adulterada com variadas porcentagens de etanol, pois este é hoje o principal componente de adulteração no Brasil. Serão avaliadas as diferenças de PH, densidade, volatilidade, expansividade da borracha e variação de cores, parâmetros estes que serão utilizados como entrada da rede para que a mesma possa informar se o combustível está ou não de acordo com as normas vigentes.

6. CONCLUSÕES

Como visto, este trabalho trata do desenvolvimento de uma rede neural artificial para detecção de adulteração de gasolina. Após estudos realizados sobre identificação de adulteração com uso da curva de destilação, redes neurais artificiais e o tratamento da base de dados inicial, as informações foram inseridas no programa e alterações foram efetuadas a fim de se obter um resultado final satisfatório.

Com a realização dos primeiros testes e do treinamento da rede, foram notados alguns dados que influenciavam negativamente no aproveitamento final. Estes foram trabalhados de forma que a essência das informações existentes na base inicial não fosse perdida. Com isso, 1,01% dos dados sofreram eliminação por Outlier. Aplicando a rede Neural Net Fitting o algoritmo que obteve melhor resultado foi o Bayesian Regularization ficando com um grau de acerto de 95,5%.

É válido ressaltar que este resultado foi obtido devido a especificação de parâmetros no projeto. Por se tratar de uma ferramenta que será utilizada para detectar algo que é considerado um crime no Brasil, a confiabilidade dos resultados deve ser a maior possível, o que foi obtido através dos valores obtidos na saída da rede.

Durante o desenvolvimento deste projeto, foi possível perceber os benefícios que a tecnologia pode gerar associada a outros campos da ciência, sendo utilizada como ferramenta de auxílio para facilitar e otimizar o trabalho de profissionais de diversas áreas de atuação, bem como poder auxiliar e muito na fiscalização de postos de combustível, reduzindo o tempo de análise e diminuindo o prejuízo ao usuário.

Apesar das dificuldades citadas no item 5.2, as mesmas foram solucionadas durante o desenvolvimento do projeto. Portanto é possível concluir e atingir os objetivos propostos para este projeto.

AGRADECIMENTOS

A Deus, por nos dar forças e saúde todos os dias e direção no trabalho;

Ao Centro Universitário UNA, pelo apoio financeiro, por ceder os laboratórios e por permitir que esse projeto pudesse ser estudado;

Ao coordenador de cursos do instituto politécnico do Centro Universitário UNA do Campus Barro Preto, Walisson Ferreira, pela total prestatividade e apoio ao longo do desenvolvimento deste projeto;

A todos que diretamente ou indiretamente contribuíram para a realização deste projeto, sejam amigos, pais e funcionários do Centro Universitário UNA.

REFERÊNCIAS

Alves, D.M., 2007. *Quantificação da Glicemia Através de Análises de Imagens da íris Humana Utilizando Redes Neurais*. Universidade de São Paulo, São Carlos. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18133/tde-20112007-104513/pt-br.php>>. Acesso em: 30. jun. 2017.

ANP. *Boletim de Monitoramento da Qualidade dos Combustíveis*. (2017). Disponível em: <http://www.anp.gov.br/wwwanp/images/Qualidade/Boletim/Bq_Combustiveis_052017.pdf>. Acesso em: 28. jun. 2017.

Braga, Antônio de Pádua., 2007. *Redes Neurais Artificiais: Teoria e Aplicações*. 2. ed. Rio de Janeiro: Ltc, 2007. 226 p. BRASIL (Org.). *Lei Nº 8.176, De 8 De Fevereiro De 1991*. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/L8176.htm>. Acesso em: 28. mai.

Braulio, C; Oliveira, Janaína; Torres, Octávio; Moraes, Reinaldo., 2015. *Estatística e probabilidades*. Belo Horizonte: Grupo Ânima Educação, 163 p.

Caldeira, Carlos., 2003. *Normalização de base de dados*. Évora: Departamento de Informática. Disponível em <http://ritacris.com/psi12_2015/docs/Normalizacao.pdf>. Acesso em: 29. mai. 2017.

Cordeiro, Cristiano Monteiro de Barros., 2009. Terno Xxx_Apelido www.inova.unicamp.br Sensor ultra sensível para detecção de combustíveis adulterados. Unicamp. Disponível em: <http://www.inova.unicamp.br/sici/visoes/ajax/ax_pdf_divulgacao.php?token=0slRFcBN>. Acesso em: 8 out. 2017.

Carro & Carros (Org.), 2017. Como descobrir se a gasolina do posto está adulterada. Disponível em: <<http://carroecarros.com.br/como-descobrir-se-gasolina-posto-esta-adulterada-nao-seja-enganado/>>. Acesso em: 10 jun. 2017.

Del Pino, José Claudio, Verno Krüger, and Maira Ferreira., 1996. "Poluição do ar." Porto Alegre: *Área de Educação Química*. [Air Pollution]. Disponível em: <http://www.quimica.seed.pr.gov.br/arquivos/File/AIQ_2011/poluicao_ufrgs.pdf>. Acesso em: 02. jun. 2017.

EBERLIM, M. *Processo de identificação de gasolina adulterada por solventes de detecção de marcadores químicos por espectrometria de massas com ionização à pressão atmosférica*. Disponível em: <http://repositorio.unicamp.br/bitstream/Reposip/84562/1/Pat_Brpi0503345.Pdf>. Acesso em: 20. abr. 2017.

Figueira, M., 1998. *Identificação de outliers*. Guarda: Millenium 12^a. Disponível em: <<http://www.ipv.pt/millenium/arq12.htm>>. Acesso em: 29. jun. 2017.

Fleck, Leandro; Tavares, Maria Hermínia Ferreira; Eyng, Eduardo., 2016. *Redes Neurais Artificiais: Princípios Básicos*. Disponível em: <<https://periodicos.utfrpr.edu.br/recit/article/view/4330/Leandro>>. Acesso em: 7 out. 2017.

Fogaça, J. *Índice de octanagem da gasolina*. (Sem data) a. Disponível em: <<http://mundoeducacao.bol.uol.com.br/quimica/Indice-octanagem-gasolina.htm>> Acesso em 17. abr .2017.

Fogaça, J. *Adulteração da gasolina e suas consequências*. (Sem data) b. Disponível em: <<http://mundoeducacao.bol.uol.com.br/quimica/adulteracao-gasolina-suas-consequencias.htm>> Acesso em 17. abr .2017.

Levorato, A. R., 2006. *Química: Ensino Médio*. 2 Ed. Curitiba/Pr: Ícone Audiovisual Ltda. 248 p. Disponível em: <http://www.educadores.diaadia.pr.gov.br/arquivos/File/livro_didatico/quimica.pdf>. Acesso em: 27. ago. 2017

Lima, N., 2009. *Utilização Da Cromatografia Gasosa Na Análise E Controle De Qualidade De combustíveis*. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.468.539&rep=rep1&type=pdf#page=90>> Acesso em 19. abr. 2017.

Ludwig J. O.; Montgomery, Eduard., 2007. *Redes Neurais: Fundamentos e Aplicações com programas em C*. Rio de Janeiro: Ciência Moderna. Disponível em: <<https://cepein.femanet.com.br/BDigital/arqTccs/0911270619.pdf>>. Acesso em: 28. jun. 2017.

Matlab (Org.). *Levenberg-Marquardt backpropagation*. (Sem data) a. Disponível em: <<https://www.mathworks.com/help/nnet/ref/trainlm.html>>. Acesso em: 24. ago. 2017.

Matlab (Org.). *Bayesian regularization backpropagation*. (Sem data) b. Disponível em: <<https://www.mathworks.com/help/nnet/ref/trainbr.html?requestedDomain=www.mathworks.com>>. Acesso em: 24. ago. 2017.

Matlab (Org.). *Scaled conjugate gradient backpropagation*. (Sem data) c. Disponível em: <<https://www.mathworks.com/help/nnet/ref/trainscg.html>>. Acesso em: 24. ago. 2017.

Mendes, Gisele., 2012. *Detecção de adulterações em gasolina e previsão de parâmetros físico-químicos a partir de curvas de destilação associadas a ferramentas quimiométricas*. Disponível em: <http://www.bibliotecadigital.ufmg.br/dspace/bitstream/handle/1843/SFSA-8ZKRMX/tese_gisele_mendes.pdf?sequence=1>. Acesso em: 20. abr. 2017.

Petrobras. *10 respostas para suas dúvidas sobre a gasolina*. 2014. Disponível em: <<http://gasolina.hotsitespetrobras.com.br/10-respostas-para-suas-duvidas/#10>>. Acesso em: 01. Jun. 2017

Pinheiro, N., L Felipe., 2014. *A alteração do tipo penal de adulteração de combustíveis: reflexo da constitucionalização do direito penal no mercado de combustíveis*. 2014. 169 f. Dissertação Mestrado em Constituição e Garantias de Direitos. Universidade Federal do Rio Grande do Norte, Natal. Disponível em: <<https://repositorio.ufrn.br/jspui/handle/123456789/14000>>. Acesso em: 02. jun. 2017.

Spörl, C.; Castro, E. G.; Luchiari, A., 2011. Aplicação de Redes Neurais Artificiais na construção de mod <elos de fragilidade ambiental. *Revista do Departamento de Geografia*, v. 21, n.1, p. 113-135. Acesso em: 06. Out. 2017

Takeshita, E., 2006. *Adulteração de gasolina por adição de solvente*. Disponível em: <<https://repositorio.ufsc.br/bitstream/handle/123456789/89520/226279.pdf?sequence=1>>. Acesso em: 15. ago. 2017.