

Estudo avaliativo da emissão de CO₂ a partir de combustíveis fósseis utilizando Redes Neurais

Evaluation study of CO₂ emission from fossil fuels using Neural Networks

Maria Inês Vasconcellos Furtado*

Rafaela Campos Furtado**

Resumo

O dióxido de carbono (CO₂) é o um gás poluente que contribui para o efeito estufa, sendo emitido para atmosfera através atividades humanas. Uma das fontes é a queima parcial de combustíveis fósseis, especialmente petróleo e seus derivados. Desta forma, este trabalho busca relacionar a emissão de CO₂ das fontes do tipo combustível líquido e gasoso, com o consumo de combustível do mesmo tipo, no Brasil, num período compreendido de 1950 a 2007. Para obter o entendimento foi utilizado Redes Neurais Artificiais para realizar a predição de CO₂ emitido com o consumo de diversos combustíveis derivados do petróleo. Entende-se que apesar da simplificação do problema, o presente estudo mostra-se altamente promissor.

Palavras-chave: Redes Neurais. Dióxido de Carbono. Poluição. Sustentabilidade. Combustível Fóssil.

Abstract

Carbon dioxide (CO₂) is a polluting gas that contributes to the greenhouse effect and is emitted into the atmosphere through human activities. One source is the partial combustion of fossil fuels, especially oil and its derivatives. Thus, this work aims to associate the emission of CO₂ from sources of liquid and gaseous fuel, with the use of such fuel in Brazil, in a period between 1950 and 2007. In an attempt to understand this, Artificial Neural Networks were used to predict CO₂ emissions with the

* Doutora em Sistemas Computacionais pela Universidade Federal do Rio de Janeiro; Investigadora no Instituto Universitário de Lisboa (ISCTE), Portugal; Email: Maria.Furtado@iscte-iul.pt

** Pós-graduada em petróleo e gás pela Universidade Federal do Rio de Janeiro, Engenheira de petróleo e gás pela Universidade Veiga de Almeida, geógrafa pela Universidade Federal Fluminense; Analista de óleo e gás na Infotec Brasil; Email: rafaelacfurtado@gmail.com

consumption of several oil-based fuels. It is considered that this study, although the problem is simplified, is highly promissory.

Keywords: Neural Networks, Carbon Dioxide, Pollution, Sustainability, Fossil Fuel.

Introdução

O Brasil está entre os países com maior aumento de motorização individual, fato que impacta negativamente não somente o tráfego de veículos nos grandes centros urbanos e nos congestionamentos, mas também ao meio ambiente, devido à poluição sonora e atmosférica (DRUMM, 2014). No Brasil, em fevereiro de 2019 havia cerca de dois automóveis por habitante, totalizando mais de 100 milhões de veículos (DENATRAN, 2019).

Os derivados de petróleo consumidos mundialmente se destinam ao setor de transportes, seguidos pela indústria. O uso desses combustíveis fósseis está associado à poluição do ar devido à sua combustão parcial, gerando resíduos na atmosfera, como o CO₂.

Esse aumento do transporte individual, ocorrido nos últimos anos, está atrelado à expansão da capacidade instalada da indústria automobilística, fruto de uma política industrial que se pautou principalmente pela atração de novas plantas automotivas para o país. Para dar vazão a essa produção crescente, houve oferta abundante de crédito para aquisição de veículos e uma política tributária que reduziu impostos de veículos populares. Por outro lado, o aumento de renda da população, desde 2003, ampliou a base de consumidores dos veículos particulares (IPEA apud NERI, 2012).

O Brasil, apesar de não ter metas obrigatórias de redução de dióxido de carbono (CO₂), assumiu o compromisso voluntário de reduzir suas emissões até o ano de 2020, sendo signatário de diversos acordos multilaterais para o esforço global de mitigação dos Gases do Efeito Estufa (GEE), como o Acordo de Paris.

Neste trabalho, para a entendimento da relação entre o consumo de combustível fóssil em suas formas líquida e gasosa e o CO₂ emitido propõe-

se o uso de redes neurais artificiais para a realização da previsão da emissão do referido gás.

A emissão de CO₂ é um problema crescente e que necessita de informação científica, econômica e social para reduzir as incertezas remanescentes. É preciso uma melhor compreensão e capacidade de previsão deste gás. As Redes Neurais são capazes de aprender através de exemplos, extraíndo informações relevantes, e, a partir daí, generalizar as informações aprendidas, gerando uma representação do problema estudado. Elas são consideradas um excelente instrumento de proposta de soluções interessantes em diversas áreas do conhecimento.

A forma como as redes neurais são criadas, os mecanismos de aprendizado e o algoritmo usado no seu desenvolvimento são o que modifica a sua área e o foco de aplicação.

Este trabalho objetiva investigar a utilização de Redes Neurais Artificiais para realizar a previsão da emissão de CO₂ no ar a partir dos dados de consumo de combustível fóssil dos tipos líquido e gasoso.

O problema da emissão de CO₂ já é por si só uma justificativa, porém ao se pensar no uso de ferramenta que auxilie em uma tomada de decisão, bem como possibilite entender o relacionamento entre variáveis diversas, é importante e instigante. Além de ser uma alternativa para representar de forma mais realística e com maior nível de detalhes o comportamento de determinados problemas, como o da emissão de CO₂ em relação ao consumo de combustível fóssil.

O problema do CO₂

Em 2015, foi assinado o então denominado “Acordo de Paris”, que, em seu ponto principal, trata do esforço para reduzir as emissões de gases de efeito estufa (GEE) a partir de 2020. Um dos focos principais é a redução dos gases oriundos das emissões da queima de combustíveis fósseis.

Entre 2014 e 2016, as emissões mundiais se mantiveram em níveis constantes, induzindo a ideia de que iniciariam um processo de redução,

porém, entre 2017 e 2018, as emissões voltaram a crescer (HAUSFATHER, 2018).

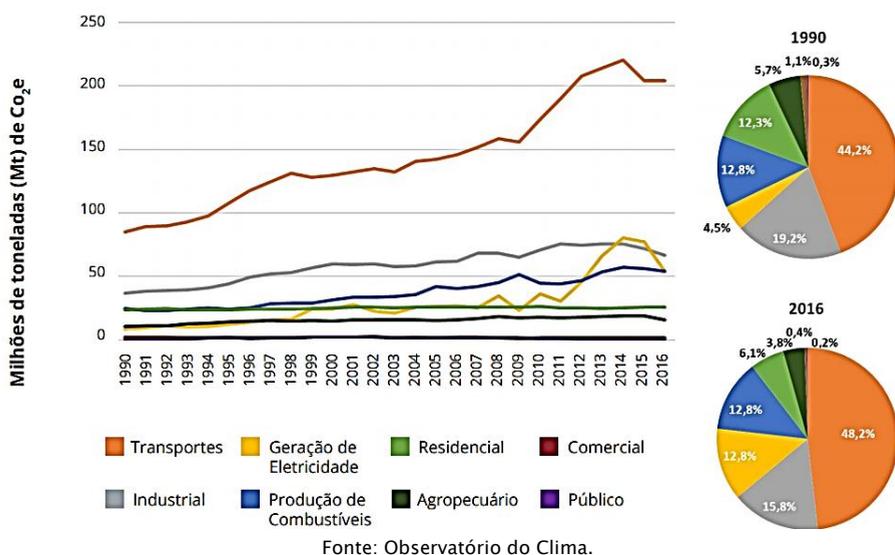
Conforme Vital, em dezembro de 2018, durante a 24^a Conferência das Partes da Convenção do Clima das Nações Unidas (COP-24), realizada na Polônia, foi divulgado que as emissões de dióxido de carbono (CO₂) alcançaram níveis recordes naquele ano, tendo, como fonte principal de emissão, a queima dos combustíveis fósseis. Vale ressaltar que o Brasil representa apenas 3,8% das emissões mundiais.

O setor de agronegócios lidera o ranking de emissões de GEEs no Brasil, com 71%, seguido de transportes, industrial e produção de combustíveis/energia.

A redução de emissão de CO₂ no setor transportes afeta diretamente ao mundo, especialmente aos centros urbanos, pois, conforme Hausfather (2018), o uso global de petróleo e gás está crescendo continuamente neste setor e há uma lentidão mundial no desenvolvimento de soluções alternativas, como os veículos elétricos ou de combustível menos poluente.

Considerando apenas o setor de energia, o segmento de transportes é o maior emissor, conforme o Observatório do Clima, com 48% do total, sendo tais emissões igualmente divididas entre transporte de carga e passageiros. A figura 2 apresenta as emissões de CO₂, considerando apenas o setor de energia por segmento de atividade. O consumo de combustíveis neste segmento foi o maior do setor de energia, o que se refletiu nas emissões: desde 1990, quando eram de 85,2 milhões de toneladas, elas cresceram 139%.

Figura 1 - Emissões de CO^o no setor de energia.



Para o caso de transporte de passageiros no Brasil, a emissão de CO₂, formado principalmente pela combustão incompleta de combustíveis fósseis, o crescimento acontece devido ao aumento dos engarrafamentos, maiores distâncias percorridas nos grandes centros e a perda da competitividade do etanol.

Redes Neurais Artificiais

Segundo Haykin (1999), a principal motivação para o estudo de redes neurais artificiais é a possibilidade de processar informações de forma totalmente diferente de um computador tradicional. Tal como o cérebro humano, a existência de dados incompletos e inconsistentes podem ser processados por meio do entendimento de padrões ou do uso de uma determinada experiência adquirida. Dessa forma, pode-se afirmar que é um sistema tolerante a falhas.

A simulação cognitiva, através de redes neurais artificiais, permite fazer predições em quase todos os problemas práticos do cotidiano, pois elas são capazes de extrair as informações relevantes de padrões de entrada

que lhes são apresentados e suscitar uma representação própria do problema.

Esta técnica permite simular as estruturas e os mecanismos de raciocínio utilizados pelos operadores no cumprimento de suas atividades, estando inspirada em conceitos desenvolvidos na modelagem cognitiva, e utiliza os formalismos de representação de estruturas de domínio da Inteligência Artificial, que é um vasto campo que contém diversos componentes importantes, como as Redes Neurais Artificiais.

Uma Rede Neural Artificial (RNA) consiste em uma estrutura conexionista, na qual o processamento é distribuído por um grande número de pequenas unidades densamente interligadas. Esse paradigma procura entender e emular as propriedades decorrentes do alto grau de paralelismo e conectividade dos sistemas biológicos.

Conforme Furtado, uma rede neural é composta por muitos elementos processadores, os neurônios, interligados por conexões denominadas de sinapse. Apesar de cada neurônio realizar um processamento simples, a associação os capacita a realizar problemas altamente complexos.

O número e modo pelo qual os neurônios estão interconectados, bem como os pesos destas conexões e no número de camadas definem tipos diferentes de RNA, denominadas arquiteturas e topologias neurais.

Para resolver uma determinada classe de problemas, uma rede neural deve, após a definição de sua arquitetura e topologia, ser treinada através de algum processo capaz de modificá-la gradualmente, de modo a adaptá-lo à determinação dessa classe de problema.

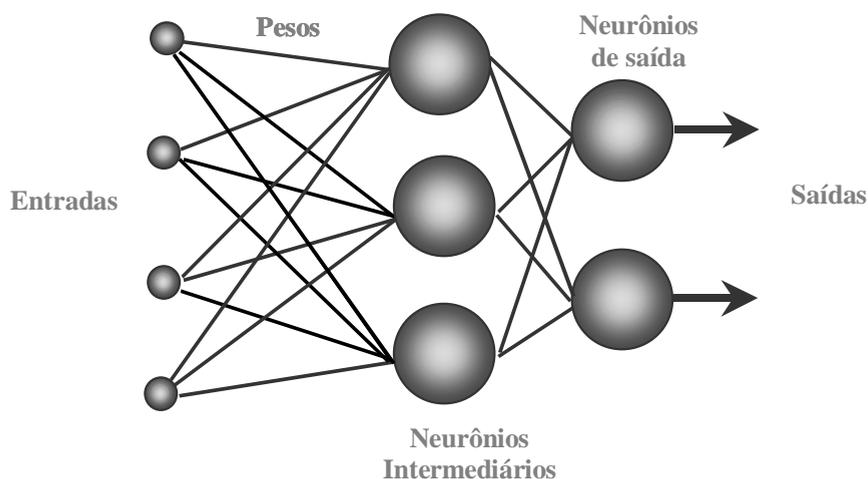
Furtado diz que “os mecanismos de aprendizado possibilitam a modificação do padrão de interconexão. Para treinamento, podem ser utilizados os mecanismos de aprendizado supervisionado, por reforço ou não-supervisionado”.

As redes neurais podem ser classificadas em dois tipos: redes diretas ou não-recorrentes (*feedforward*) e recorrentes (*feedback*). As Redes Neurais diretas estão estruturalmente dispostas em camadas, em que cada camada de neurônio recebe sinais somente das camadas anteriores, ou seja, o sinal

de processamento é direto, sem retorno na rede ou na realimentação. A sua saída é exclusivamente determinada em função da entrada e dos valores dos pesos sinápticos. Já as Redes Neurais Recorrentes possuem realimentação, isto é, há conexões das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores. As redes que possuem esta estrutura desenvolvem uma memória em longo prazo nos neurônios internos.

Entre as diferentes arquiteturas neurais, a mais usual é o *Perceptron* Multicamadas (MLP), representada esquematicamente na Figura 2. Nesse tipo, cada camada neural tem sua função. As camadas intermediárias realizam o processamento, extraíndo as características dos dados, construindo um padrão próprio, representativo do problema, que será disponibilizado para a camada de saída.

Figura 2 – Rede Neural Artificial de múltiplas camadas

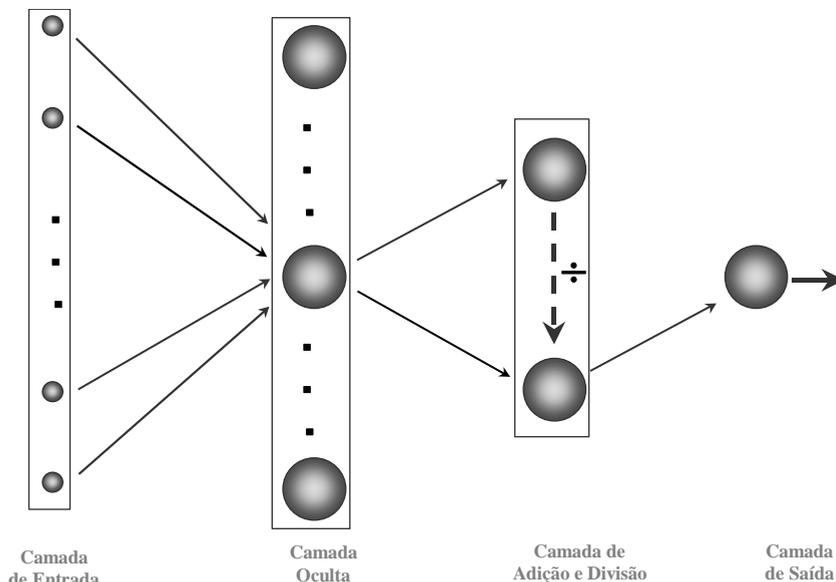


Fonte: Furtado, 2019.

A rede neural probabilística (PNN), representada na Figura 3, é do tipo multicamada, *feedforward*, com comportamento estocástico, que permite fazer a associação entre a estrutura da rede e funções de densidade de probabilidades. Tais redes possuem um aprendizado rápido, sendo capaz de realizar ótimas classificações. As PNNs com o número suficiente de dados

convergem para o Classificador Bayesiano, que, por definição, é ótimo (FREITAS, 2016).

Figura 3 – Rede Neural do tipo PNN



Fonte: Furtado, 2019.

No presente estudo, utilizaram-se as redes do tipo MLP (*Perceptron* de Múltiplas Camadas) para modelar as complexas relações entre as variáveis de entrada com a de saída e a do tipo PNN (Rede Neural Probabilística) para realizar a previsão numérica e a aproximação dos dados.

Estudo de caso

O presente estudo de caso objetiva buscar o relacionamento através de Redes Neurais Artificiais em uma base formada pelos conjuntos de dados referentes ao consumo de combustível fóssil (líquido e gasoso) no Brasil entre os anos de 1950 e 2007 e dados da emissão de CO₂ pelos respectivos combustíveis, no mesmo período de tempo, apresentados na tabela 1.

Tabela 1 – Dados utilizados no Estudo de Caso

Série Histórica	Repositório
Consumo de Óleo Diesel, Óleo Combustível, Gasolina, GLP, Gás Natural.	A partir de 1970: Brasil. Ministério de Minas e Energia. Empresa de Pesquisa Energética. Balanço Energético Nacional 2007: Ano base 2006. Para 1950–1969: Estatísticas históricas do Brasil: séries econômicas, demográficas e sociais de 1550 a 1988. 2. ed. rev. e atual. do v. 3 de Séries estatísticas retrospectivas. Rio de Janeiro: IBGE, 1990.
Emissão de CO ₂ de combustíveis fósseis por país	Boden, T.A., G. Marland, and R.J. Andres. 2013. Global, Regional, and National Fossil-Fuel CO ₂ Emissions. Carbon Dioxide Information Analysis Center, Oak Ridge National Laboratory, U.S. Department of Energy, Oak Ridge, Tenn., U.S.A. doi 10.3334/CDIAC/00001_V2013

Fonte: Os autores.

Os dados foram separados em conjuntos distintos e realizou-se o treinamento de seis diferentes arquiteturas neurais para cada grupo, utilizando um *software* denominado NeuralTools, da Palisade Corporation.

Realizou-se o estudo com três grupos distintos e, em todos os casos, a única variável de saída for a emissão de CO₂:

- 1) Dados do consumo combustíveis fósseis líquidos e emissão de CO₂ pela queima de combustíveis fósseis líquidos;
 - 2) Dados do consumo combustíveis fósseis gasosos e emissão de CO₂ pela queima de combustíveis fósseis gasosos;
 - 3) Dados do consumo combustíveis fósseis líquidos e gasosos e emissão de CO₂ pela queima de ambos os combustíveis fósseis.
- Neste caso considerou-se a emissão de carbono per capita.

O NeuralTools aplicou uma escala nas variáveis, todas numéricas, antes do treinamento, de forma que os valores de cada variável estivessem aproximadamente no mesmo intervalo. Isso otimiza o treinamento, principalmente nas fases iniciais.

Durante o treinamento, quando uma ou mais variáveis fossem consideradas menos significativa, o algoritmo de treinamento reduziria o

peso sináptico entre a entrada e os neurônios da primeira camada oculta, garantindo que representasse sua menor relevância.

Comparando, as redes MLP e PNN, há a existência de características que geram vantagens e desvantagens. As redes PNN treinam mais rapidamente, não necessitam a definição de sua topologia, ou seja, do número de camadas ocultas e dos nós (neurônios), além de retornarem as probabilidades de o caso se enquadrarem em diferentes categorias dependentes.

Já as redes do tipo MLP são menores, portanto, as previsões são mais rápidas, são mais confiáveis na presença de valores fora da faixa de intervalo dos dados de treinamento, ou seja, consegue trabalhar com dados dissonantes. Além disso, são capazes de fazer generalizações a partir de pequenos conjuntos de treinamento.

Análise e discussão dos resultados

O software utilizado, NeuralTools, gera relatórios ao final de cada rodada de treinamento. No relatório resumido, estão as informações gerais sobre o teste e treino, além de relatórios detalhados com as informações pertinentes a cada tipo de rede treinada.

Em todos os relatórios, é apresentado o desempenho da rede neural, as estatísticas de previsões errôneas, o número de dados utilizado no conjunto de treinamento e de teste. Além do relatório, o *software* também fornece gráficos de dispersão.

Foram estudados três casos distintos no presente trabalho, considerando os dados de combustíveis líquidos, combustíveis gasosos e combustíveis líquidos e gasosos. Para todos os casos, foram treinadas seis diferentes redes: cinco diferentes topologias de rede MLP – com o número de neurônios variando de dois a seis nós – e uma rede do tipo PNN.

A figura 4 apresenta um resumo de todos os casos rodados, considerando como variável de entrada o consumo das diversas formas de combustível fóssil e como variável de saída a emissão de CO₂ por tipo de combustível.

Figura 4 – Resultados obtidos

Resumo			
<i>Informações da rede</i>			
Nome	Rede treinada em CO2 todos	Rede treinada em CO2 líquido	Rede treinada em CO2 gasoso
Configuração incluída na busca	GRNN, MLFN 2 a 6 nós	GRNN, MLFN 2 a 6 nós	GRNN, MLFN 2 a 6 nós
Melhor configuração	Previsor numérico de MLFN (6 nós)	Previsor numérico de MLFN (2 nós)	Previsor numérico de MLFN (3 nós)
Local	co2.xls	co2.xls	co2.xls
Variáveis categóricas independentes	0	0	0
Variáveis numéricas independentes	6 [Consumo-óleo-diesel, Consumo-óleo-comb, Consumo-gasolina, Consumo-gás-natural, ConsumoGLP-qde, PerCapita]	3 [Consumo-óleo-diesel, Consumo-óleo-comb, Consumo-gasolina]	2 [Consumo-gás-natural, ConsumoGLP-qde]
Variável dependente	Var. numérica (CO2-Total)	Var. numérica (CO2-CombLíquido)	Var. numérica (CO2-CombGas)
<i>Treinamento</i>			
Número de casos	9	55	55
Tempo de treinamento	00:27:42	01:00:00	00:42:14
Número de tentativas	4142433	19949773	14437136
Motivo da parada	Parada automática	Parada automática	Parada automática
% previsões inadequadas (30% tolerância)	0,00000%	18,1818%	23,6364%
Erro médio quadrático	0,00001234	725,90	25,54
Erro médio absoluto	0,00008223	584,05	14,87
Desvio padrão de erro absoluto	0,00009198	431,06	20,76
<i>Teste</i>			
Número de casos	2	14	14
% previsões inadequadas (30% tolerância)	0,00000%	7,1429%	14,2857%
Erro médio quadrático	66,33	539,73	61,37
Erro médio absoluto	58,91	452,49	35,78
Desvio padrão de erro absoluto	30,49	294,22	49,85
<i>Conjunto de dados</i>			
Nome	CO2 todos	CO2 líquido	CO2 gasoso
Número de linhas	69	69	69
Tags de casos manuais	Não	Não	Não
<i>Análise de impacto de variáveis</i>			
Consumo-óleo-comb	55,8371%	57,2163%	
Consumo-óleo-diesel	29,6417%	0,322955606	
Consumo-gasolina	14,5212%	0,105281285	0,899018339
Consumo-gás-natural	0,00000%		0,100981661
ConsumoGLP-qde	0,00000%		
PerCapita	0,00000%		

Fonte: adaptado pelos autores do Quadro Resumo.

Para todos os casos estudados a rede do tipo MLP apresentou os melhores resultados, mas com topologias distintas.

A porcentagem de previsões inadequadas é considerada relativamente boa para este estudo considerado preliminar e simples, pois não se analisou outros fortes fatores que auxiliam na concentração ou diluição de poluentes na atmosfera, como ventos, inversões térmicas, engarrafamentos, tamanho da população, dentre outros fatores relevantes.

Apesar do estudo relativo ao caso, que inclui todos os tipos de combustível juntos, ter apresentado o menor erro para os conjuntos de treinamento e de conjunto de teste (0,0%), entende-se que tal previsão é errônea, pois as redes treinadas desconsideraram o consumo do gás como um emissor de poluente.

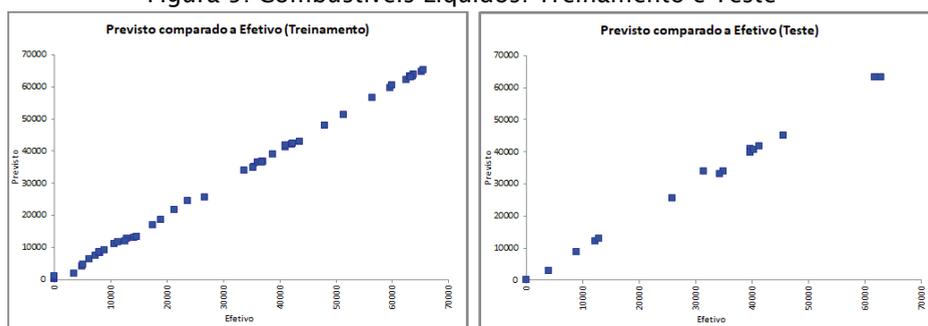
Certamente a rede não decorou os dados do conjunto de treinamento, pois, quando isso acontece, há um aumento considerável no erro pertinente ao conjunto de testes.

Para o caso dos combustíveis líquidos, o maior responsável pela emissão de CO₂, conforme os resultados obtidos, é o consumo do óleo combustível, sendo acompanhado pelo óleo diesel e tendo a gasolina com menor parcela de contribuição.

Em todos os casos estudados, as variáveis de entrada, consumo de combustível, apresentaram uma forte correlação com a emissão de CO₂. Essa correlação é apresentada em todos os 78 gráficos de dispersão gerados: um para cada caso e para cada resumo dos casos, além da geração de um gráfico para o conjunto de treinamento e outro para o conjunto de testes.

A figura 5 apresenta os gráficos de dispersão para os casos de combustíveis líquidos no conjunto de treinamento e de teste.

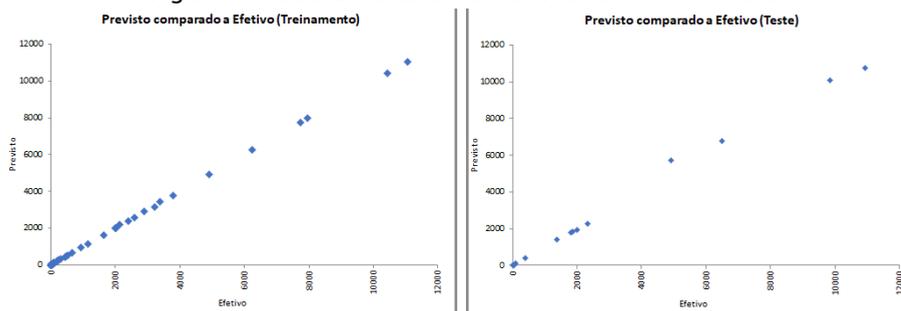
Figura 5: Combustíveis Líquidos: Treinamento e Teste



Fonte: NeuralTools.

A figura 6 apresenta os gráficos de dispersão para os casos de combustíveis gasosos, no conjunto de treinamento e de teste. Há um menor número de dados neste conjunto, pois não havia dados disponíveis do consumo de combustível gasoso entre os anos de 1939 e 1950, apesar de já estar sendo comercializado desde os anos 40.

Figura 6: Combustíveis Gasosos: Treinamento e Teste



Fonte: NeuralTools.

Nas figuras 5 e 6, os gráficos de dispersão apresentam uma correlação positiva forte, visto existir uma clara tendência nos dados. Quando a variável “Efetivo” aumenta, há, como esperado, um aumento conjunto na variável “Previsto”. Essa pouca dispersão dos dados indica que essa tendência é forte.

Considerações finais

A predição é considerada uma questão extremamente importante e atualmente está se tornando cada vez mais essencial. O próprio método científico tem a previsibilidade como um dos preceitos básicos para que se possa estabelecer hipóteses acerca do comportamento de qualquer objeto de estudo, tendo importância em inúmeros problemas práticos e cotidianos.

Este estudo certamente está longe de ser definitivo ou conclusivo, podendo ser estendido, aprimorando principalmente o conjunto de dados, não só em quantidade, mas em relação às variáveis utilizadas para predição.

Deve-se considerar não apenas o consumo de combustível, mas incluindo dados climáticos, de tráfego, localização geográfica, da qualidade dos carros, capacidade de dispersão de gases, dentre outros, para avaliar a emissão de CO₂. Outro fator importante e relevante para melhores resultados é o espaço de tempo das medições, pois trabalhou-se com médias anuais, sendo considerado ideal a medição diária.

O que este estudo apresenta é que a capacidade intrínseca de aprender através do processamento de pares dados de entradas x saída e de generalizar a partir de dados não-lineares são eficientes para aplicações através de uma abordagem com redes neurais para predição.

São utilizados neste estudo apenas dois tipos de redes neurais para fazer a predição, MLP e PNN, com suas topologias definidas pelo software NeuralTools. Deve-se testar outros tipos de redes e, preferencialmente, associando um algoritmo de otimização, de forma a testar apenas as redes mais promissoras.

Obstante a esses fatos, entende-se que o objetivo proposto neste estudo foi alcançado, pois a metodologia estudada mostrou ter potencial para ser aplicada neste tipo de problema, mesmo diante da diversidade de situações desconsideradas na modelagem dos dados. Os resultados animadores provindos da habilidade das redes neurais em inferir mapeamentos não-lineares, tornaram prósperas a prototipagem e predição destes sistemas complexos.

Os resultados obtidos neste estudo devem ser considerados preliminares, visto que houve a necessidade de se fazer interpolações que, possivelmente, não sejam completamente aceitáveis, mas que visaram minimizar a escassez dos dados de forma a adaptá-los aos modelos neurais, acarretando em incertezas associadas ao modelo proposto.

Porém, essas incertezas são minimizadas pela certeza de que as redes neurais são bastante efetivas no aprendizado de padrões a partir de dados não-lineares, incompletos, com ruídos e até compostos de exemplos contraditórios. Esta habilidade de manipulação de dados imprecisos faz com que as redes sejam extremamente eficazes no processamento de informações.

Seguindo as restrições impostas pelos dados disponíveis, o protótipo desenvolvido alcançou bons resultados, possibilitando o uso de redes neurais neste tipo de aplicação, podendo os resultados oriundos serem utilizados como elementos-chaves para elaboração de uma estratégia de controle ambiental.

Referências

CABRAL, S. D. **Proposta Metodológica para Monitoramento da Poluição Atmosférica Provocada pelo Sistema de Transporte Urbano – O Caso do Monóxido de Carbono**. 1997. Tese (Mestrado em Engenharia) – COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 1997.

CALÔBA, L. P. Introdução à Computação Neurona. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 9, 1992. Vitória, ES, Brasil, **Anais...** Vitória: Sociedade Brasileira de Automática, set. 1992, p. 25–38.

DENATRAN. **Frota de Veículos – 2019**. Disponível em: <<https://www.denatran.gov.br/estatistica/639-frota-2019>>. Acesso em: 3 jun. 2019.

DRUMM, F.C. et all. Poluição atmosférica proveniente da queima de combustíveis derivados do petróleo em veículos automotores. **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental – REGET**, Santa Maria, RS, v. 18, n.1, p. 66–78, abr. 2014.

FREITAS, L. P. S.; CABRAL, S. D. **Previsão da Variabilidade da Emissão de CO2 do Solo em Áreas de Cana-de-Açúcar Utilizando Redes Neurais Artificiais**. 2016. Tese (Doutorado em Engenharia Elétrica) – UNESP, Ilha Solteira, SP, Brasil, 2016.

FURTADO, M. I. V. **Redes neurais artificiais: uma abordagem para sala de aula**. Ponta Grossa, PR: Atena Editora, 2019.

HAUSFATHER, Z. Analysis: Fossil-fuel emissions in 2018 increasing at fastest rate for seven years. **Carbon Brief**, Clear on Climate, Global Emissions, 5 dez. 2018. Disponível em: <<https://www.carbonbrief.org/analysis-fossil-fuel-emissions-in-2018-increasing-at-fastest-rate-for-seven-years>>. Acesso em: 2 abr. 2019.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2nd ed. New Jersey, Prentice Hall, 1999.

NERI, M. **Desenvolvimento inclusivo sustentável?** Comunicados do Ipea n. 158, 2012.

OBSERVATÓRIO DO CLIMA. **Análise das emissões de GEE no Brasil (1970–2016) e suas implicações para políticas públicas e a contribuição brasileira para o Acordo de Paris.** São Paulo: Observatório do Clima, 2018.

STERN, A. C.; BOUBEL, R. W.; TURNER, D. B.; FOX, D. L. **Fundamentals of air pollution.** 2 ed. Orlando: Academic Press, Inc., 1984.

VITAL, M. H. F. Aquecimento global: acordos internacionais, emissões de CO2 e o surgimento dos mercados de carbono no mundo. **BNDES**, Rio de Janeiro, v. 24, n. 48, p. 167–244, set. 2018.

WASSERMAN, P. D. **Neural computing: theory and practice.** 1 ed. New York: Van Nostrand Reinhold, 1989.