

Emissão de CO₂ e número de internações hospitalares por doenças respiratórias: previsão de internação com redes neurais artificiais

Este estudo investigou a capacidade preditiva das RNA's para explicar o número de internações hospitalares provocadas por doenças respiratórias na cidade de Campo Grande (MS), em função do volume de emissão de CO₂ e do número de habitantes. A relevância do estudo é observada pela utilização da inteligência artificial para auxiliar na previsão de doenças respiratórias na população devido ao efeito do volume de CO₂ emitido pelos veículos automotores. O estudo é caracterizado como descritivo-exploratório e o período de análise foi de 2005 a 2016. Os dados utilizados na pesquisa foram obtidos junto à SEMAGRO/MS, IBGE e DATASUS. Concluiu-se que o modelo de RNA foi capaz de explicar, com erro de 0,11 o número de internações provocadas por doenças respiratórias. Pode-se afirmar que o modelo apresentou valores satisfatórios para sua validação e uso.

Palavras-chave: Emissão de CO₂; Doenças respiratórias; Redes neurais artificiais; Campo Grande.

CO₂ emission and number of hospital admissions for respiratory diseases: expected hospitalization with artificial neural networks

This study investigated the predictive capacity of ANN's to explain the number of hospital admissions caused by respiratory diseases in the city of Campo Grande (MS), depending on the volume of CO₂ emissions and the number of inhabitants. The relevance of the study is observed by the use of artificial intelligence to assist in the prediction of respiratory diseases in the population due to the effect of the volume of CO₂ emitted by motor vehicles. The study is characterized as descriptive-exploratory and the period of analysis was from 2005 to 2016. The data used in the research were obtained from SEMAGRO/MS, IBGE and DATASUS. It was concluded that the RNA model was able to explain, with an error of 0.11, the number of hospitalizations caused by respiratory diseases. It can be said that the model presented satisfactory values for its validation and use.

Keywords: CO₂ Emission; Respiratory tract; Artificial neural networks; Campo Grande.

Topic: **Desenvolvimento, Sustentabilidade e Meio Ambiente**

Reviewed anonymously in the process of blind peer.

Received: **01/04/2021**

Approved: **28/04/2021**

Raul Asseff Castelão 

Universidade Anhanguera, Brasil

<http://lattes.cnpq.br/1364663546445753>

<http://orcid.org/0000-0002-4677-6088>

raulasseffcastelao@gmail.com

João Bosco Arbués Carneiro Júnior 

Universidade Federal de Rondonópolis, Brasil

<http://lattes.cnpq.br/5073023761658236>

<http://orcid.org/0000-0001-7094-2245>

jbacj@hotmail.com

Celso Correia de Souza 

Universidade Anhanguera, Brasil

<http://lattes.cnpq.br/2881392515816773>

<http://orcid.org/0000-0002-2689-8264>

csouza939@gmail.com

Daniel Massen Frainer 

Universidade Estadual do Mato Grosso do Sul, Brasil

<http://lattes.cnpq.br/6910455102814572>

<http://orcid.org/0000-0003-0813-214X>

danielmfrainer@gmail.com

Josimar Fernandes de França 

Universidade Anhanguera, Brasil

<http://lattes.cnpq.br/2910153620827488>

<http://orcid.org/0000-0001-6795-9302>

josimargtl@gmail.com



DOI: 10.6008/CBPC2179-6858.2021.004.0047

Referencing this:

CASTELÃO, R. A.; CARNEIRO JÚNIOR, J. B. A.; SOUZA, C. C.; FRAINER, D. M.; FRANÇA, J. F.. Emissão de CO₂ e número de internações hospitalares por doenças respiratórias: previsão de internação com redes neurais artificiais. **Revista Ibero Americana de Ciências Ambientais**, v.12, n.4, p.605-615, 2021. DOI: <http://doi.org/10.6008/CBPC2179-6858.2021.004.0047>

INTRODUÇÃO

As doenças respiratórias são responsáveis por um expressivo número de internações hospitalares e até mesmo de óbitos. Elas afetam o sistema respiratório e provocam inúmeros tipos de doenças, tais como: bronquite, enfisema, asma, câncer, rinite, sinusite, tuberculose, entre outros. Geralmente, este tipo de doença tem relação direta com o meio ambiente e com a ação do homem na natureza.

Ramos et al. (2019) investigaram a relação da queima de cana-de-açúcar sobre as internações hospitalares por doenças respiratórias na cidade de Presidente Prudente, SP. Para tanto, usaram dados colhidos no Sistema Único de Saúde (SUS). Dentre as doenças, foram observadas internação por asma, pneumonia, broncopneumonia e infecções de vias aéreas superiores, no período de 28 de março de 2011 a 28 de dezembro de 2012. Observaram que a queima da palha de cana-de-açúcar aumenta o número de internações provocadas por doenças respiratórias, principalmente a pneumonia.

Outro fato que prejudica o sistema respiratório é a queima de combustível e a consequente emissão de gases veiculares. Nesse processo, são liberados diversos tipos de gases que afetam o sistema respiratório. O dióxido de carbono (CO₂) é um desses gases que são liberados e que acabam prejudicando a saúde humana, principalmente, por doenças respiratórias.

Sendo assim, inúmeras pesquisas são realizadas com o intuito de investigar a relação da emissão de gases veiculares e a saúde humana. Para isso, normalmente, são utilizados métodos estatísticos tradicionais, tais como análise da correlação, regressão linear, modelos de séries temporais, regressão logística, entre outros. No entanto, com o desenvolvimento da inteligência artificial, abriu-se outras oportunidades de métodos de pesquisa para este fim, com destaque às redes neurais artificiais (RNA's).

As RNA's são um tipo de método de inteligência artificial que pode ser utilizado com o intuito de estudar relações de previsão entre emissões de gases veiculares e doenças respiratórias. Cunha (2010) explica que as RNA's são estruturadas a partir do funcionamento do cérebro humano, com o intuito de copiar sua fórmula inteligente de processar a informação. Explica, ainda, que as RNA's são modelos computacionais não lineares inspirados na estrutura da interligação de neurônios com o intuito de realizar as seguintes operações: aprendizagem, associação, generalização e abstração.

Diante do exposto, tem-se a seguinte questão de pesquisa: Qual a capacidade preditiva das RNA's para explicar a quantidade de internações hospitalares provocadas por doenças respiratórias em função da emissão de CO₂ e do número de habitantes de uma cidade?

Assim, o objetivo deste trabalho foi estimar o número de internações hospitalares provocadas por doenças respiratórias em função da emissão de CO₂ por veículos automotores e do número de habitantes de uma comunidade utilizando um modelo de RNA's. Especificamente, pretende-se apresentar as estatísticas descritivas das variáveis deste estudo; construir, treinar e validar um modelo de RNA com essas variáveis; utilizar o modelo construído e validado para realizar previsões.

Com a utilização das RNA's, importante ferramenta de inteligência artificial, espera-se pode fazer previsões de internações hospitalares por doenças respiratórias em função do volume de emissão de CO₂. A

importância do presente estudo é mostrar inicialmente se existem relação entre essas variáveis e, em seguida, construir um modelo de RNA's que poderá ser utilizado por gestores públicos, ou outros interessados, para propor e elaborar políticas de saúde pública que possam amenizar os problemas provocados pela queima de combustível por veículos automotores. Enfim, vislumbra-se ainda, a importância que métodos de inteligência de artificial têm para realizar previsões.

MATERIAIS E MÉTODOS

Este estudo é classificado como descritivo-exploratória, pois, teve como finalidade utilizar as RNA's para prever o número de internações hospitalares em decorrência de doenças respiratórias e o volume emissão de CO₂ por veículos automotores e o número de habitantes de uma comunidade em um determinado período.

As variáveis utilizadas no modelo de RNA foram volume de CO₂ emitidos pelos veículos automotores, o número de habitantes e o número de internações hospitalares provocadas por doenças respiratórias na comunidade, no período considerado.

Área de Estudo

Esta pesquisa teve como área de estudo a cidade de Campo Grande, capital do estado de MS que, segundo o IBGE (2019), possui cerca de 895.892 habitantes, uma extensão territorial de 8.092 km² e um PIB de, aproximadamente, 25,5 bilhões de reais em 2016. As principais atividades econômicas são a prestação de serviços e o comércio. Em 2018, a cidade tinha uma frota de 590.326 veículos, ou seja, aproximadamente 0,66 veículo por habitante. A cidade em estudo possui a maior frota de veículos de MS e a 15ª do Brasil.

Coleta de Dados

As variáveis utilizadas nesta pesquisa e na construção do modelo de RNA foram: volume de emissão de CO₂ por veículos automotores, número de internações provocadas por doenças respiratórias e número de habitantes da cidade de Campo Grande, no período de 2005 a 2016.

A variável quantidade de internações foi obtida no site do DATASUS, já as informações referentes ao número de habitantes da cidade foram coletadas junto ao IBGE. O volume de emissão de CO₂ foi obtido, a partir do volume de combustíveis consumidos na cidade de Campo Grande, no período considerado, na SEMAGRO/MS, transformado em volume de CO₂ com a aplicação da metodologia Top-Down, que realiza essa conversão.

Rede Neural Artificial

Para responder o problema desta pesquisa e, conseqüentemente, atingir os objetivos propostos, este estudo construiu um modelo de RNA com o auxílio do *Software Statistical Package for the Social Sciences* (IBM_SPSS, 2016). O tipo da rede foi a *Perceptron Multiestrato* (MLP). As variáveis independentes foram o volume de emissão de CO₂ e o número de habitantes e a variável dependente foi quantidade de internações

provocadas por doenças respiratórias no período de 2005 a 2016, na cidade de Campo Grande.

O quadro 1 apresenta as informações da RNA, com as características de sua arquitetura, bem como, a camada de entrada, a camada oculta e a camada de saída.

Quadro 1: Informações sobre a RNA utilizada.

Camada de entrada	Covariáveis	1	Volume de CO ₂
		2	N. de habitantes
	Número de unidades		2
	Método de reescalonamento para covariáveis		Padronizado
Camadas ocultas	Número de camadas ocultas		2
	Número de Unidades na Camada Oculta 1 ^a		2
	Número de Unidades na Camada Oculta 2 ^a		2
	Função de ativação		Tangente hiperbólica
Camada de saída	Variáveis dependentes	1	Internações
	Número de unidades		1
	Método de reescalonamento para dependentes de escala		Padronizado
	Função de ativação		Identidade
	Função de erro		Soma dos Quadrados

As variáveis independentes (camada de entrada) foram analisadas de forma padronizada, isto é, de cada variável subtrai-se a média e divide o resultado pelo desvio-padrão. O percentual de variáveis utilizadas para treinamento e para teste foram definidas e otimizadas pelo próprio software.

Na arquitetura da RNA foram utilizadas duas camadas ocultas, com funções de ativação do tipo tangente hiperbólica, cujos argumentos são valores reais no intervalo (-1, 1).

Por fim, a camada de saída também utilizou o método de reescalonamento padronizado, a função de ativação foi do tipo identidade, que usa argumentos com valores reais e retorna-os inalterados. Essa função é utilizada para variáveis dependentes numérica. A função de erro utilizada foi a média da soma dos quadrados dos erros.

RESULTADOS E DISCUSSÃO

Para o cálculo do volume de emissão de CO₂ fez-se uso do consumo de combustíveis por veículos automotores na cidade de Campo Grande, no período de 2005 a 2016, conforme quadro 2.

Quadro 2: Volume de combustíveis consumidos na cidade de Campo Grande (MS), no período de 2005 a 2016.

Ano	Gasolina (m ³)	Álcool (m ³)	Diesel (m ³)
2005	146.757	29.857	286.657
2006	149.944	28.693	253.245
2007	151.189	48.032	301.159
2008	156.325	73.124	360.060
2009	163.169	93.681	322.738
2010	200.413	74.922	344.258
2011	249.070	40.779	362.262
2012	269.970	36.328	371.192
2013	274.268	57.624	393.270
2014	289.984	70.150	393.160
2015	276.618	108.316	388.315
2016	325.086	44.040	379.676

Fonte: SEMAGRO (2019).

Aplicando o método Top-Down obtém-se os volumes de emissões de CO₂ por tipo de combustível e o volume total de CO₂ emitido no período em estudo (Tabela 1).

Tabela 1: Volume de CO₂, em tCO₂, emitidos pela queima de combustíveis na cidade de Campo Grande (MS), por tipo de combustível e o volume total emitido, no período de 2005 a 2016, em toneladas

Ano	Gasolina (tCO ₂)	Etanol (tCO ₂)	Diesel (tCO ₂)	Total (tCO ₂)
2005	311.479	32.867	716.123	1.060.469
2006	318.242	31.586	632.652	982.480
2007	320.885	52.874	752.351	1.126.110
2008	331.785	80.494	899.495	1.311.775
2009	346.313	103.124	806.259	1.255.696
2010	425.360	82.474	860.021	1.367.855
2011	528.629	44.889	904.998	1.478.516
2012	572.987	399.90	927.305	1.540.283
2013	582.111	63.433	982.461	1.628.005
2014	615.466	77.222	982.187	1.674.874
2015	587.097	119.235	970.083	1.676.415
2016	689.966	48.480	948.501	1.686.947

Observa-se na tabela 1 que o combustível que mais emite CO₂ é o diesel. Nota-se, ainda, que o álcool tem emissão bem inferior em relação aos demais combustíveis. Na tabela 2 estão apresentados os valores das três variáveis que foram utilizadas no estudo: o número de internações hospitalares por problemas respiratórios na cidade de Campo Grande, o número de habitantes da cidade e o volume de emissão de CO₂ no período de 2005 a 2016.

Os dados sobre a quantidade de internações foram obtidos no site do DATASUS (2019), do número da população no site do IBGE (2019), já os dados do volume de emissão de CO₂ foram obtidos inicialmente junto à SEMAGRO (2019), através do consumo de combustíveis, após, foi aplicada a metodologia Top-Down, conforme já explicado, para transformar os dados de combustíveis em volume de CO₂. Na tabela 3 são apresentados os valores referentes às estatísticas descritivas das variáveis da pesquisa.

Tabela 2: Valores das variáveis utilizadas na pesquisa, número de internações hospitalares, número de habitantes e volume de emissão de CO₂, em Campo Grande, no período de 2005 a 2016.

Ano	Número Internações	Número de habitantes	Volume de CO ₂
2005	3.453	749.768	1.060.469
2006	3.279	765.247	982.480
2007	3.544	724.524	1.126.110
2008	3.526	747.190	1.311.775
2009	3.976	755.107	1.255.696
2010	4.565	786.797	1.367.855
2011	4.408	796.252	1.478.516
2012	4.305	805.397	1.540.283
2013	5.358	832.352	1.628.005
2014	4.635	843.120	1.674.874
2015	4.527	853.622	1.676.415
2016	4.770	863.982	1.686.947

Tabela 3: Estatísticas descritivas das variáveis número de internações hospitalares, número de habitantes e volume de emissão de CO₂ da cidade de Campo Grande, no período de 2005 a 2016.

Parâmetros estatísticos	Número de internações	Número de habitantes	Volume de emissão de CO ₂
Média	4.195,50	793.613,17	1.399.118,75
Mediana	4.356,50	791.524,50	1.423.185,49
Desvio Padrão	638,91	46.549,02	253.409,62
Mínimo	3.279	724.524	982.480
Máximo	5.358	863.982	1.686.947
Coefficiente de variação (%)	15,23	5,86	18,11

Como se pode observar da tabela 3, segundo os coeficientes de variação, a variação da população de Campo Grande, com coeficiente de variação de 5,86%, foi muito homogênea de um ano para outro, não

mostrando tendência de alto crescimento. Já o número de internações hospitalares e o volume de emissão de CO₂, com coeficientes de variação de 15,23% e 18,11%, respectivamente, mostraram crescimentos mais robustos. O forte aumento do volume de emissão de CO₂ é devido, provavelmente, ao aumento do número de veículos automotores na cidade. Já o aumento do número de internações hospitalares por doenças respiratórias, se deve, segundo o problema de pesquisa do estudo, ao aumento do volume de emissão de CO₂, que será discutido a seguir.

Com o auxílio do software IBM_SPSS foi construída e validada a RNA para a previsão do número de internações hospitalares por doenças respiratórias em função do volume de emissão de CO₂ e do número de habitantes de uma comunidade, no caso, Campo Grande. A variável número de internações hospitalares foi considerada como variável dependente e as outras duas variáveis, volume de emissão de CO₂ e número de habitantes de Campo Grande, como variáveis independentes.

A RNA foi do tipo *Percepttron Multicamada*, com duas camadas ocultas e as variáveis independentes tratadas de forma padronizada. Várias tentativas foram realizadas com o intuito de diminuir o erro e melhorar a capacidade preditiva, sendo esse o motivo dessa característica de rede com duas camadas ocultas. A tabela 4 traz o resumo de processamento dos casos do modelo construído de RNA.

Tabela 4: Resumo de processamento dos casos do modelo de RNA construído.

		N	Porcentagem
Amostra	Treinamento	9	75,0%
	Testes	3	25,0%
Válido		12	100,0%
Excluídos		0	
Total		12	

Foi selecionado a arquitetura automática de rede, sendo assim, o próprio software determina a “melhor” proporção para as amostras de treinamento e de teste, sendo assim, foram utilizados 9 dados para treinamento e 3 para testes.

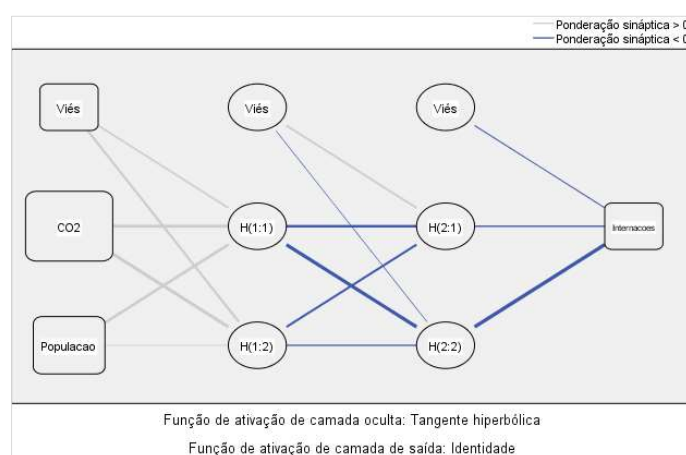


Figura 1: Diagrama da RNA com uma camada de entrada, duas ocultas e uma de saída.

A estrutura da RNA composta pela camada de entrada, as duas camadas ocultas e a camada de saída podem ser visualizadas na figura 1 que apresenta o diagrama da RNA.

Na figura 1 pode-se visualizar o comportamento das variáveis independentes, das duas camadas

ocultas e da camada de saída através da associação entre as camadas de entrada, e como foi feita o aprendizado nas camadas ocultas. Os valores que o software calculou para estimar a associação são apresentados na tabela 5.

As variáveis dependentes foram tratadas de forma padronizada, ou seja, os valores são transformados entre -1 e 1. Esse procedimento é utilizado para diminuir possíveis erros em decorrência de valores muito discrepantes entre as variáveis. Uma das grandes desvantagens das RNA's é a complexidade de entendimento das ponderações sinápticas, haja vista que essas utilizam sistemas de inteligência artificial e o modelo de aprendizado do cérebro humano, sendo assim, não existe equação ou fórmula como nos modelos tradicionais de previsão. Então, pode-se dizer que nas RNA's as variáveis são associadas e representando um relacionamento ajustado por todas as variáveis inseridas no modelo através da função de aprendizado, sendo essa função o que difere as RNA's dos demais modelos de previsão.

Tabela 5: Estimativas de Parâmetro.

Preditor		Predito				Camada de saída Internações
		Camada oculta 1		Camada oculta 2		
		H (1:1)	H (1:2)	H (2:1)	H (2:2)	
Camada de entrada	(Viés)	0,302	0,380			
	CO ₂	0,465	0,532			
	População	0,430	0,105			
Camada oculta 1	(Viés)			0,334	-0,040	
	H (1:1)			-0,382	-1,009	
	H (1:2)			-0,349	-0,198	
Camada oculta 2	(Viés)					-0,166
	H (2:1)					-0,287
	H (2:2)					-1,068

Diante disso, é válido mencionar que a função aprendizado visa diminuir o erro, ou seja, a diferença entre os valores preditos e os valores observados. Na tabela 6, observa-se a sumarização do modelo predito e seu erro, principal medida para validação das RNA's.

Tabela 6: Sumarização do modelo.

Treinamento	Soma dos erros quadráticos	0,910
	Erro relativo	0,227
	Regra de parada usada	1 passos consecutivos sem diminuição de erros*
	Tempo de treinamento	0:00:00.00
Testes	Soma dos erros quadráticos	0,054
	Erro relativo	0,111

Variável dependente: Número de internações hospitalares. *Os cálculos de erro têm como base a amostra de teste.

O erro relativo é a soma dos quadrados dos erros da variável dependente, no modelo desta pesquisa, o valor determinado foi de 0,111 ou 11,10%. Em RNA não há um valor de parâmetro para comparar se a rede possui capacidade preditiva ou não, o que pode ser dito é que quanto menor o erro melhor sua capacidade de previsão. No caso deste estudo, foram efetuadas inúmeras tentativas para diminuir o erro. Vale aqui mencionar que o valor encontrado de 0,111 foi o menor. Outra observação interessante na tabela apresentada é o tempo de treinamento da rede, haja vista que foram utilizadas somente 12 observações, por isso, o tempo aprendido foi zero.

Segundo equação apresentada no quadro 2 do referencial teórico, o grau de ajustamento do R² entre

os dados reais e os dados previstos foi de 0,67 ou 67,22%.

Em seguida, dando continuidade no processo de validação do modelo construído, apresentam-se as figuras 2 e 3, as quais trazem o comportamento do valor predito em função do valor real e o gráfico de dispersão dos resíduos, respectivamente.




Figura 2: Gráfico do valor predito pelo valor real de internações hospitalares.

Observa-se, na figura 2, o comportamento linear dos pontos dispersos no gráfico, atendendo assim, a necessidade que tais valores apresentem linearidade. A figura 3 traz o gráfico dos resíduos da RNA, donde se espera que o comportamento desses resíduos não apresente linearidade, ou seja, para a validação do modelo é necessário visualizar tais pontos em forma de retângulo dispersos, sem apresentar nenhuma tendência.

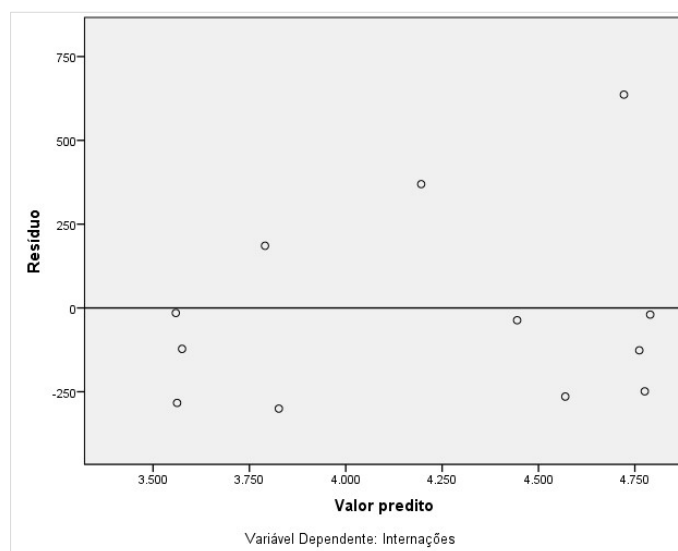


Figura 3: Gráfico dos resíduos.

Realmente, a figura 3 não apresenta comportamento linear, não existindo nenhuma lei de formação, atendendo, assim, as condições de que a RNA apresenta boa previsão. Por fim, faz-se necessário identificar a importância de cada variável independente para construção do modelo de RNA. Sendo assim, observa-se na tabela 7 como cada variável contribuiu para a rede neural estimada. Na figura 4 está apresentado

graficamente como cada variável independente contribui para a RNA, conforme tabela 7.

Tabela 7: Importância das contribuições de cada variável independente para o modelo.

Variáveis	Importância	Importância normalizada
Volume de emissão de CO ₂	0,577	100,0%
Número de habitantes	0,423	73,4%




Figura 4: Gráfico da importância de cada variável independente para o modelo.

Nota-se na tabela 7 e na figura 4 que ambas as variáveis (número de habitantes e volume de emissão de CO₂), contribuíram significativamente para a construção do modelo de RNA, no entanto, vale aqui mencionar que o volume de emissão de CO₂ apresentou uma maior significância para prever o número de internações provocadas por doenças respiratórias no município de Campo Grande (MS), no período de 2005 a 2016. Entretanto, é de suma importância observar que ambas as variáveis foram importantes para a construção da rede neural deste estudo.

Previsão com a Rede Neural Artificial

Após a apresentação das variáveis, da construção da RNA e da sua validação, nesta seção a RNA será utilizada para realizar previsões hipotéticas. Para isso, inicialmente, foi realizada uma comparação dos valores reais com os valores preditos, em seguida, é calculado o desvio-padrão da diferença dos valores reais x preditos e, por fim, foram utilizados valores hipotéticos para volume de emissão de CO₂ e número de habitantes para prever o total de internações provocadas por doenças respiratórias. Sendo assim, na tabela 8 são apresentados os valores reais e os valores preditos para a variável dependente número de internações hospitalares por doenças respiratórias.

Tabela 8: Quantidade de internações reais x quantidade de internações preditas.

Ano	Número Internações Reais	Número de Internações Preditas	Diferença nominal	Diferença percentual
2005	3.453	3.575	-122,17	-3,54%
2006	3.279	3.562	-283,40	-8,64%
2007	3.544	3.559	-15,04	-0,42%
2008	3.526	3.826	-300,33	-8,52%
2009	3.976	3.791	185,50	4,67%
2010	4.565	4.196	369,40	8,09%
2011	4.408	4.445	-36,63	-0,83%

2012	4.305	4.569	-264,45	-6,14%
2013	5.358	4.722	636,40	11,88%
2014	4.635	4.762	-126,52	-2,73%
2015	4.527	4.776	-248,65	-5,49%
2016	4.770	4.790	-19,82	-0,42%

Inicialmente, observa-se a proximidade dos valores reais com os valores preditos, apenas um valor apresentou, em valor absoluto, uma diferença superior a 10% (2013), no entanto, três valores apresentaram diferenças absolutas inferiores a 1% (2007, 2011 e 2016). Nota-se na tabela 8 que em 2013 a quantidade de internações foi a maior de todo o período da análise, sendo que as variáveis independentes mantiveram estáveis. Portanto, verifica-se a relevância da capacidade preditiva do modelo de RNA construído nesta pesquisa. Em seguida, faz-se necessário verificar a comportamento dos valores preditos, bem como, os valores reais. Para tanto, utilizou-se o parâmetro estatístico desvio-padrão (Tabela 9).

Tabela 9: Desvio-padrão da diferença dos valores reais x valores preditos.

		Diferença nominal	Diferença percentual
N	Válido	12	12
	Omisso	0	0
Desvio-Padrão		287,18	6,41%

Os valores encontrados nos desvios-padrão nominal e percentual, demonstram mais uma vez a relevância do modelo construído, pois, o valor de 2013 influenciou significativamente os resultados desse parâmetro estatístico e, mesmo assim, os valores calculados são de certa forma aceitáveis para este tipo de predição e tamanho da amostra. Enfim, após mais esta validação apresentada, utilizou de dados hipotéticos para usar a RNA para predição. Valores hipotéticos: Volume de emissão de CO₂: 1.700.000 toneladas; Número de habitantes: 900.000 habitantes.

Com o uso do *software* IBM_SPSS e também do arquivo gerado que nesse caso representa a RNA construída e validada, e que poderá ser utilizada para realizar previsões utilizando valores para as variáveis independentes. Encontrou-se o valor hipotético de que aconteceriam 4.818 internações provocadas por doenças respiratórias em Campo Grande.

CONCLUSÕES

Foi possível afirmar que as RNA's possuem capacidade para predição do número de internações hospitalares de Campo Grande em função do volume de emissão de CO₂ pelos veículos automotores e do número de habitantes da cidade, com erro de 11,1%, haja vista que o processo de construção e de validação do modelo, foram apresentados resultados satisfatórios e que creditam o modelo a ser utilizado para este fim.

Utilizando dados hipotéticos para as variáveis independentes, foi possível utilizar o modelo para estimar um valor predito para a variável dependente. O modelo demonstrou sua capacidade de predição, e apresentou resultado condizente a série histórica. Diante disso, a pesquisa demonstra sua relevância por utilizar uma importante ferramenta de inteligência artificial para prever número de internações de provocadas por doenças respiratórias em qualquer comunidade.

Por fim, sugere-se novas pesquisas que utilizem estas variáveis em outras técnicas de predição, tais como o modelo de regressão linear múltipla e, assim, comparar com a capacidade preditiva com as Redes Neurais Artificiais.

REFERÊNCIAS

CUNHA, G. B.. **Redes neurais artificiais aplicadas à previsão da incidência de malária no estado de Roraima**. Tese (Doutorado em Ciências) — Universidade Federal de Uberlândia, Uberlândia, 2010.

DATASUS. Departamento de Informática do Sistema Único de Saúde do Brasil. **Notas Técnicas**. Brasília: DATASUS, 2019.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Campo Grande MS/Panorama**. Rio de Janeiro: IBGE, 2019.

IBM_SPSS. **Neural Networks 24**. Rio de Janeiro: IBM_SPSS, 2016.

RAMOS, D.; PESTANA, P. R. S.; TREVISAN, I. B.; CHRISTOFARO, D. G. D.; TACAO, G. Y.; CORIPIO, I. C.; FERREIRA, A. D.; RAMOS, E. M. C.. Impacto da queima de cana-de-açúcar sobre internações hospitalares por doenças respiratórias por doenças respiratórias. **Ciência & Saúde Coletiva**, Rio de Janeiro, v.24, n.11, p.4133-4140, 2019.

SEMAGRO. Secretaria de Estado de Meio Ambiente e Desenvolvimento Econômico, Produção e Agricultura Familiar. **Perfil Estatístico de Mato Grosso do Sul**. Campo Grande: SEMAGRO, 2019.

A CBPC – Companhia Brasileira de Produção Científica (CNPJ: 11.221.422/0001-03) detém os direitos materiais desta publicação. Os direitos referem-se à publicação do trabalho em qualquer parte do mundo, incluindo os direitos às renovações, expansões e disseminações da contribuição, bem como outros direitos subsidiários. Todos os trabalhos publicados eletronicamente poderão posteriormente ser publicados em coletâneas impressas sob coordenação da **Sustenere Publishing**, da Companhia Brasileira de Produção Científica e seus parceiros autorizados. Os (as) autores (as) preservam os direitos autorais, mas não têm permissão para a publicação da contribuição em outro meio, impresso ou digital, em português ou em tradução.