



Previsão do Rebanho bovino no Brasil utilizando Redes Neurais Artificiais para cálculo e valoração do potencial de geração de energia elétrica a partir do biogás.

Victor Bueno Fontes (UTFPR)
victorfontes7@gmail.com

Matheus Fellipe Babinski Dantas De Araujo (UTFPR)
araujo.1996@alunos.utfpr.edu.br.com

Felippe Martins Damaceno (Unioeste)
felippemartins.utfpr@gmail.com

A bovinocultura é considerada um dos principais destaques do agronegócio brasileiro, o país comporta o segundo maior rebanho do mundo. Essa alta produtividade nas atividades agrícolas produz, junto com o desenvolvimento socioeconômico, resíduos altamente poluentes, que ao produzirem biogás se tornam uma potencial forma de reciclagem e geração de energia. O planejamento dos sistemas energéticos é importante para o processo de tomada de decisões em contextos macros e micros. Sendo verossímil considerar que uma das mais importantes ferramentas para realizar este planejamento é a previsão de produção de energia. O interesse deste exemplar se concentra em prever valores futuros, utilizando Rede Neural Artificial, do rebanho bovino no Brasil, para poder, portanto, calcular e valorar o potencial energético da utilização das fezes de bovinos em confinamento. Isto, para auxiliar em futuros processos de tomada de decisões.

Palavras-chave: Rede Neural, Biogás, Energia Sustentável, Bovinos.

1. Introdução

O território nacional apresenta uma grande diversidade de produtos oriundos do agronegócio. A bovinocultura por exemplo, é considerada um dos principais destaques do agronegócio brasileiro, afinal, o país comporta o segundo maior rebanho do mundo. Tal potencial foi motivo de busca por novas tecnologias, relacionadas ao agronegócio, nas últimas décadas. Isto, visando o desenvolvimento dos sistemas produtivos e o impulsionamento dos índices de produtividade, caminhando, portanto, para uma forma de negócio mais eficiente e sustentável (ABIEC, 2016).

Essa alta produtividade nas atividades agrícolas produz, junto com o desenvolvimento socioeconômico, resíduos altamente poluentes. Dessa forma, se faz necessária a indagação das questões ambientais envolvidas nestas atividades econômicas, sendo uma das alternativas mais viáveis, para lidar com seus impactos negativos, a digestão anaeróbia destes resíduos, utilizando o biogás originado, como uma forma de reciclagem e geração de energia.

O uso do biogás presta um serviço de saneamento ambiental, reaproveitando a biomassa que seria descartada durante o processo de produção, como restos de plantações e excrementos de animais. Em uma análise de Rodrigo Galvão, integrante da Agência Internacional de Energia (AIE), caso o potencial de produção de biogás de todo o Brasil fosse voltado para a geração de energia elétrica, seria equivalente a 24% de toda a demanda nacional de energia (DALLACORTE, 2018). A exploração do potencial desta fonte de energia se demonstra ainda mais interessante para o contexto nacional quando dados, provenientes da Empresa de Pesquisa Energética (EPE), prevê um crescimento médio de 4,3% de energia elétrica consumida entre os anos de 2013 e 2023 no Brasil.

Ponderando sobre o planejamento dos sistemas energéticos, é verossímil considerar que uma das mais importantes ferramentas para esta atividade é a previsão de demanda e produção energética. Visto que em um contexto de crescimento do setor, faz-se necessário o investimento em técnicas e metodologias que gerencie as incertezas intrínsecas ao mercado (CAMPOS, 2008).

Um dos métodos utilizados para a realização de previsões é o emprego de redes neurais artificiais. Conforme dito por Haykin (2001), as redes neurais artificiais podem ser definidas como informações manipuladas por um sistema de interação de unidade básica de processamento, chamadas de neurônios artificiais.

Dessa forma, de maneira quantitativa, buscou-se observar e valorar a dimensão da energia elétrica que poderia estar sendo gerada, nos próximos anos, caso houvesse o aproveitamento das fezes bovinas. Isto, utilizando uma análise da série temporal do crescimento populacional do rebanho bovino brasileiro por meio de redes neurais e programação em R.

2. Referencial teórico

2.1. Rebanho bovino

A bovinocultura tem múltiplas finalidades dentro da produção de matérias primas, sendo, esta criação de rebanho, importante para o agronegócio nos setores da pecuária de corte e de leite. O agronegócio, por sua vez, é entendido como a soma de quatro segmentos: insumos para a agropecuária, produção agropecuária básica, agroindústria e agrosserviços. A análise desse conjunto de segmentos é feita para o ramo agrícola e para o pecuário, que, ao serem somados, com as devidas ponderações, obtém-se a análise do agronegócio.

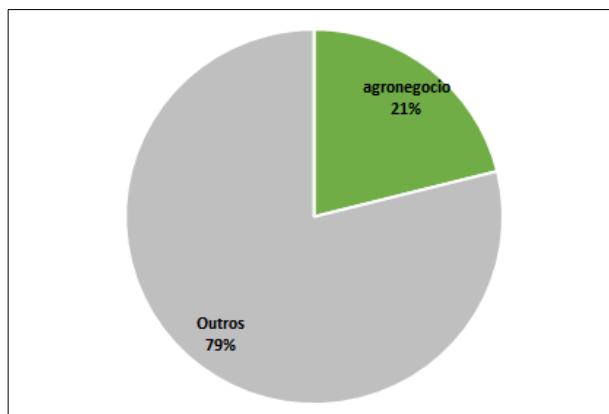
Figura 1 – Segmentos do agronegócio



Fonte: Cepea (2018)

Dentro do PIB do agronegócio, que representou, em 2018, 21,1% do PIB brasileiro, de acordo com o Centro de Estudos Avançados em Economia Aplicada (Cepea), está a pecuária, representando 26,5% do PIB do agronegócio.

Figura 2 – Gráfico do PIB brasileiro em 2018




Fonte: Próprio autor sobre os dados do Cepea (2018)

Em relação a agropecuária, esta representou, de acordo com dados coletados das Contas

Nacionais Trimestrais, em torno de 5,16% do PIB nacional de 2018, tendo maior representatividade no primeiro trimestre, onde representou 6,74%. do PIB. Além disso, este setor empregou 19 milhões de pessoas em 2016, segundo estudo feito pelo Cepea, este número representa 20% do total de empregos no país.

Figura 3 – PIB brasileiro por setor



Fonte: Próprio autor de acordo com dados do IBGE contas trimestrais (2018)

A pecuária é uma importante atividade para a economia brasileira, que tende a manter sua alta representatividade, considerando estudos da IPEA.

Figura 4 – Previsões para a taxa de crescimento do PIB agropecuário e por produto (2020)

Produto	Taxa de crescimento (em %)		Peso no PIB Agropecuário (c)	Contribuição para o crescimento do PIB Agropecuário (em p.p.)	
	Previsão anterior (a)	Previsão atual (b)		Previsão anterior (a x c)	Previsão atual (b x c)
PIB Agropecuário	3,8	2,4	100,0	3,8	2,4
Agricultura	4,5	2,8	67,3	3,0	1,9
Arroz em casca	1,0	3,6	1,3	0,0	0,0
Milho em grão	-4,0	-3,5	6,1	-0,2	-0,2
Trigo em grão e outros cereais	-7,6	-6,5	0,8	-0,1	-0,1
Cana-de-açúcar	1,0	0,8	9,6	0,1	0,1
Soja em grão	10,4	6,4	26,0	2,7	1,7
Outros produtos e serviços da lavoura	-1,2	-1,7	11,9	-0,1	-0,2
Mandioca	0,1	0,7	1,6	0,0	0,0
Fumo em folha	-1,9	-7,9	1,2	0,0	-0,1
Algodão herbáceo e outras fibras	1,8	-2,1	2,7	0,0	-0,1
Laranja	4,3	4,4	1,8	0,1	0,1
Café em grão	14,2	15,4	4,1	0,6	0,6
Pecuária	3,5	2,0	25,7	0,9	0,5
Bovinos e outros animais vivos	3,5	1,1	13,3	0,5	0,1
Leite de vaca e de outros animais	2,9	2,9	5,2	0,1	0,1
Suínos vivos	4,5	3,9	1,6	0,1	0,1
Aves vivas	2,1	0,6	3,0	0,1	0,0
Ovos de galinha e de outras aves	5,4	5,4	2,6	0,1	0,1
Outros	-2,4	-0,6	6,9	-0,2	0,0
Produtos da exploração florestal e da silvicultura	-6,5	-1,2	4,3	-0,3	-0,1
Pesca e aquicultura	4,1	0,5	2,7	0,1	0,0

Fonte: IPEA (2018)

2.2. Série temporal

Uma Série Temporal, também denominada Série Histórica, é uma sequência de dados obtidos em intervalos regulares de tempo durante um período específico (MORETTIN e TOLOI,

1987), ou seja, é uma coleção de observações feitas sequencialmente ao longo do tempo (EHLERS, 2009). Segundo Costa (2009), são diversos os exemplos de Séries Temporais (ST) em nossa realidade cotidiana, tendo aplicações em várias ciências como economia, medicina, meteorologia, epidemiologia, entre outras. São exemplos deste tipo de sequência de dados:

- Produção diária em uma fábrica;
- Preço diário de uma ação.

De acordo com Morettin e Toloí (2006) alguns conceitos importantes no entendimento de séries temporais são os Processos Estocásticos, Tendência, Sazonalidade e Estacionariedade, descritos a seguir:

- Processos Estocásticos: Coleção de variáveis aleatórias que, em geral, são utilizadas para estudar a evolução de fenômenos que são observados ao longo do tempo;
- Tendência: Comportamento de longo prazo da série, que pode ser causada por qualquer aspecto que afete a variável de interesse no longo prazo;
- Sazonalidade: Existente quando os fenômenos que ocorrem durante o tempo se repetem a cada período idêntico de tempo, como flutuações periódicas. Esta pode ser determinística, quando seu padrão sazonal é regular e estável no tempo, ou estocástica, quando a componente sazonal da série varia com o tempo;
- Estacionariedade: Relativa ao comportamento de uma ST em relação a sua média, variância e estrutura de autocorrelação, sendo estacionária quando apresenta equilíbrio estatístico sem tendência e não estacionária quando suas propriedades mudam com o decorrer do tempo. (MORETTIN e TOLOI 2006).

O objetivo de se analisar uma série temporal são diversos. Podendo esta análise ser utilizada para descrever propriedades da série, por exemplo, o padrão de tendência, existência de variação sazonal, outliers, alterações estruturais, controlar processos, prever valores futuros com base em valores passados, entre outros.

O interesse deste exemplar está em prever valores futuros com base em valores passados. Isto, considerando que o processo de tomada de decisão é sempre importante porque define rumos para a empresa (e sociedade) tanto no curto, quanto no médio ou longo prazo (RIBEIRO, 2003).

2.3. Redes neurais artificiais (RNA)

Redes Neurais são modelos baseados no funcionamento do complexo cérebro humano, sendo uma técnica de inteligência computacional comumente usada, em anos recentes, para realizar

previsões de série temporais (Zhang et al., 1998).

De uma maneira geral, esta teoria pode ser dividida em três conceitos, sendo elas:

- Neurônios: Constituído de três partes fundamentais: pesos sinápticos, sendo responsáveis por ponderarem os valores de entrada dos neurônios, regra de propagação, que define como as entradas são combinadas e função de ativação, que determina o efeito que o resultado da regra de propagação terá sobre o nível de ativação do neurônio;
- Topologia: Forma pela qual ocorrerá conexão entre os neurônios da RN. Sendo denominado “Camadas” os encadeamentos de vários neurônios;
- Aprendizado: processo pelo qual a RN aprenderá utilizando os padrões a ela apresentados. Esta característica confere a Rede Neural detalhes importantes acerca de seu funcionamento, sendo exemplos destes, segundo Silva et al. (2010), a capacidade de realizar generalizações, classificar padrões, agrupando e organizando e até a tolerância a falhas;

Matematicamente, um neurônio pode ser descrito pelas seguintes equações:

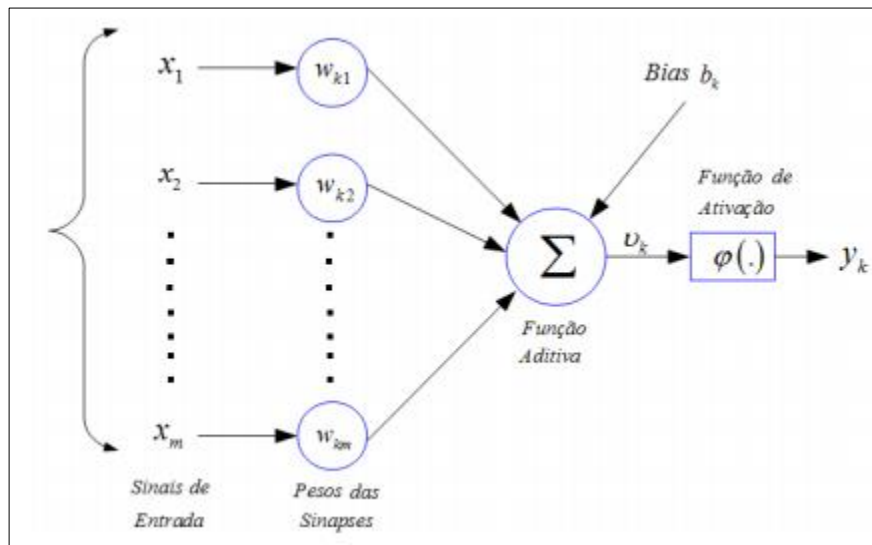
$$u_k = \sum_{i=1}^m w_{ki} x_{ki} \quad (1)$$

$$y_k = \varphi(u_k + b_k) \quad (2)$$

Onde são identificados alguns elementos básicos do modelo neural (HAYKIN, 2001), sendo:

- Sinapses, caracterizadas por seus pesos;
- Sinais de entrada $(x_{k1}, x_{k2}, \dots, x_{km})$, que são multiplicadas pelo peso sináptico $(w_{k1}, w_{k2}, \dots, w_{km})$;
- Função aditiva responsável pela soma ponderada dos sinais de entrada;
- Função de ativação $(\varphi(.))$ que restringe a amplitude da saída do neurônio e limita o intervalo permissível de amplitude do sinal de saída. Podem ser do tipo linear e não linear;
- Bias (b_k) que tem o efeito de aumentar, ou diminuir a entrada líquida da função de ativação.


Figura 5 – Representação de um neurônio



Fonte: Adaptado de Haykin (2001)

Uma Rede neural é formada pela interação de neurônios, podendo sua arquitetura ser representada pela seguinte forma:

Figura 6 – Representação de uma rede neural



Fonte: Adaptado de Haykin (2001)

O uso de modelos de Redes Neurais Artificiais tem sido adotado por diferentes profissionais em vários campos, incluindo estatística e econometria.

Neste exemplar, as Redes Neurais Artificiais serão utilizadas objetivamente para realizar predições de valores para o Rebanho Bovino no Brasil.

2.4. Medidas de acurácia

Para que seja possível identificar a acurácia e consequentemente saber o quão confiável são os

modelos de previsão propostos, é necessário averiguar alguns métodos estatísticos de erros. Segundo, Makridakis e Hibon (1995) existem catorze medidas de precisão que podem ser identificados na literatura existente sobre previsão, de acordo com Fair (1986), existem três medidas mais comuns de precisão preditiva, sendo elas RMSE, MAE e índice de desigualdade de Theil. Neste exemplar utilizaremos RMSE, MAE, MAPE e MASE, desta forma, iremos nos restringir a esses 4 tipos de métodos. Onde serão considerados “n” o número de dados, “O” o valor observado e “P” o valor previsto.

O RMSE (*Root Mean Squared Error*) ou Raiz do Erro Quadrático Médio, representa as diferenças individuais quadráticas entre as séries temporais observadas e previstas:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (3)$$

Enquanto o RMSE representa as diferenças entre O e P elevadas ao quadrado. A verdadeira média dos desvios pode ser descrita pelo MAE (*Mean Absolute Error*):

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (4)$$

Além dessas, outra forma de medida de erro é o MAPE (*Mean Absolute Percentage Error*) ou Média do Erro Absoluto Percentual, que possui representação em termos percentuais.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{O_i - P_i}{P_i} \right| \times 100 \quad (5)$$

Outra medida para identificar a qualidade do modelo é o MASE (*Mean Absolute Scaled Error*) ou Erro médio absoluto em escala (KOEHLER e HYNDMAN, 2006). Que realiza uma comparação entre o modelo medido e o modelo naive de previsão:

$$MASE = \frac{MAE}{MAE_{na amostra, naive}} \quad (6)$$

Se $MASE > 1$ significa que a previsão atual é menos eficiente fora da amostra que uma previsão do tipo Naive na amostra. Desta forma, caso MASE dê maior que 1, seria interessante mudar o modelo de previsão para um do tipo Naive.

2.6. Biogás e biomassa

Biomassa pode ser definida como qualquer combustível ou matéria proveniente de seres ou organismos que estiveram vivos recentemente (HIGMAN e BURGT, 2003). O

aproveitamento de suas capacidades energéticas pode ser feita através da digestão anaeróbica em biodigestores, onde pela umidade e aquecimento acontecem a otimização do mesmo.

A biomassa é uma eficaz alternativa na produção e distribuição de energia. Sendo um combustível utilizado no meio rural, possibilita que propriedades deixam de ser dependentes dos fornecedores de energia, podendo talvez até fornecer energia para a rede. O biogás, produzido nos biodigestores, tem seu emprego como fonte energética primária para o fornecimento de energia mecânica em turbinas e motores, esses quando acoplados a geradores elétricos se torna possível a produção de energia elétrica.

O biogás tem ganhado certo espaço no Brasil, por justamente se utilizar de resíduos orgânicos, amplamente disponíveis no nosso meio econômico, resíduos estes que podem levar aproximadamente seis meses para se decompor e tornar-se em gás metano, um gás do efeito estufa, de fácil combustão (CARVALHO, 2013).

Um requisito para o biogás ter seu aproveitamento de forma otimizada, é 70%, ou mais, de sua composição deve equivaler a metano (MARQUES, et al. 2014). Desta forma, utilizando-se de todo material possível para a geração de energia, com os requisitos de otimização atendidos, a utilização do biogás se torna extremamente benéfica para ambos, o homem e a natureza.

3. Metodología

Para a elaboração deste trabalho foi realizada a coleta de dados da série histórica do número efetivo dos rebanhos, por tipo de rebanho, disponibilizado pelo Sistema IBGE de Recuperação Automática (SIDRA), sendo o tipo de rebanho escolhido o bovino e os dados correspondentes aos anos de 1980 até 2018, para a realização da análise da série temporal.

Após realizada a análise necessária, houve a identificação de que, entre os modelos considerados para realização da predição de séries temporais, a utilização de uma Rede Neural Artificial, seria a opção que traria os melhores resultados. Para a obtenção desta conclusão foram utilizadas medidas de acurácia, como o MAE (*Mean Absolute Error*), MAPE (*Mean Absolute Percentage Error*), entre outros.

Ademais, após a análise dos componentes e comportamento da série temporal, houve a decisão de que os dados que alimentariam as entradas da Rede Neural Artificial seriam os dados de 2005 até 2018. Isso, objetivando potencializar seus resultados ao retirar destes, efeitos de medidas externas, como as de âmbito de decisões governamentais. Além disso, os

dados relativos ao ano de 2018 foram separados do restante do conjunto para realizar o teste adicional, objetivando que os dados utilizados para a realização do treinamento da RNA não fossem os mesmos utilizados no teste, segundo (HYNDMAN, 2014), uma boa prática é separar os dados das bases utilizadas em duas partes, uma de treino e outra de teste. Desta forma, foi empregado aos conjuntos de dados a alimentação das entradas da RNA, por meio do software RStudio R Core Team (2020), gerando milhares de repetições em uma Rede Neural Artificial do tipo Nnetar (*Neural Net Auto Regressive*), sendo esta uma rede *feedforward* com uma camada oculta.

Com os dados obtidos da previsão realizada pela Rede Neural do rebanho bovino no Brasil, é possível prever a quantidade de fezes que este rebanho irá gerar, e conseqüentemente, calcular a energia que pode ser gerada pelo biogás gerado pelas fezes destes animais. Entretanto, é importante considerar que apenas 2% do rebanho bovino (aproximadamente 5 milhões de cabeças) é submetido ao confinamento, prática que tornaria viável a coleta das fezes do animal. Sendo assim, para os cálculos, serão considerados apenas 2% dos valores previsto para o rebanho bovino para cada ano entre 2019 e 2025.

Considerando a revisão de Pauletti e Motta(2004), um bovino adulto excreta, em média, 23,5 kg de fezes e 9,1 kg de urina. Esta quantidade de fezes, por sua vez, é capaz de gerar 1,15m³ de metano, ou 1,77m³ de biogás, considerando que 65% do biogás é composto de metano. Isto, de acordo com a revisões que informam que 1 quilograma (Kg) pode proporcionar 0,049 m³ de metano por kg de fezes e 0,294 kW/kg.

Considerando que 1m³ de biogás equivale à 1,8 kW de potência elétrica final, sendo esta a equivalência empregado por fabricantes de motores e geradores (FOCKING; Branco Motores,2009). Podemos deduzir, pela fórmula abaixo, que 1 boi é capaz de gerar 3,2 kW de potência elétrica por dia, ou 1168 kW de potência elétrica por ano, ou ainda, 0,13 kW por hora.

Isto pode ser verificado a partir da seguinte fórmula:

$$E_a = d_a \times F_d \times \frac{W}{kg} \times \frac{1}{0,65} \times e \quad (7)$$

Onde:

- E_a : é a energia que pode ser produzida por um boi a cada ano, em kWh;
- d_a : A quantidade de dias presente em um ano, portanto, 365 dias;
- F_d : A quantidade de fezes gerada em um dia, sendo este 23,5 kg;

- $\frac{W}{kg}$: A potência elétrica que pode ser produzida por 1 kg de fezes, ou seja, 0,294 kW/kg;
- e : A eficiência do gerador.

Para a realização da valoração da energia produzida, utilizou-se dos dados disponibilizados no site da ANEEL, fazendo-se uma média nacional do valor de comercialização do kilowatt-hora, conferindo assim um valor equivalente a R\$ 0,561 para cada kwh utilizado. Obtendo-se a seguinte fórmula:

$$V_a = E_a \times R\$ \tag{8}$$


Tendo:

- V_a : Valor da energia que pode ser produzida por um boi em um ano (R\$) ;
- E_a : A quantidade de energia produzida em kWh em um ano.

4. Resultados e discussão

A figura a seguir representa os dados da Série Temporal que descreve o rebanho bovino entre os anos de 1980 e 2018, onde é possível observar um aumento significativo da taxa de crescimento do rebanho entre os anos de 1995 e 2005. Isto ocorreu devido ao significativo aumento do crédito destinado à pecuária bovina de corte, que cresceu 398% entre 1995 a 2003.

Figura 9 – Rebanho de bovinos no tempo de 1980 até 2018



Fonte: Próprio autor (2020)

A Tabela 1, apresentada a seguir, representa os valores dos testes de acuracidade do modelo, demonstrando que este possui alta acuracidade e portanto é um modelo com resultados

precisos. Afinal, independentemente da medida, o objetivo é obter os menores valores possíveis.

Tabela 1 – Tabela de medidas de acurácia

RMSE	MAE	MAPE	MASE
3423.006	2225.603	0.001047324	0.0009563561

Fonte: Proprio autor (2020)

A Tabela 2 expõe os valores obtidos com a previsão utilizando a Rede Neural Artificial para o Rebanho de bovinos no Brasil entre o ano de 2019 até o ano de 2025:

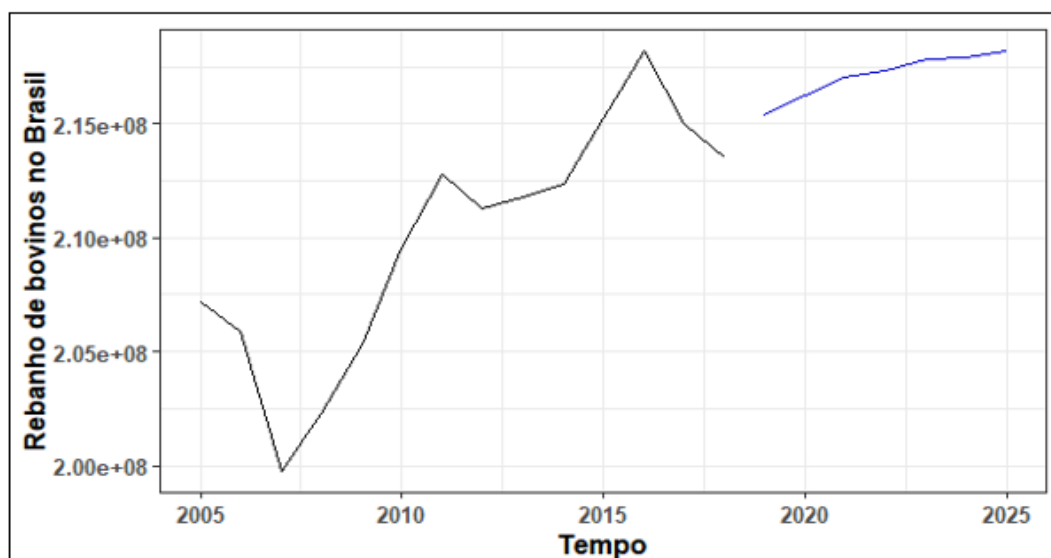
Tabela 2 – Tabela da previsão do rebanho bovino de 2019 até 2025

Ano	Rebanho Bovino
2019	215.384.478
2020	216.219.926
2021	217.054.038
2022	217.355.489
2023	217.824.695
2024	217.888.607
2025	218.172.793

Fonte: Próprio autor (2020)

A Figura 10 reproduz graficamente a previsão realizada pelo modelo de RNA utilizado para o Rebanho de bovinos para os anos de 2019 até 2025, sendo representado pela linha em azul:

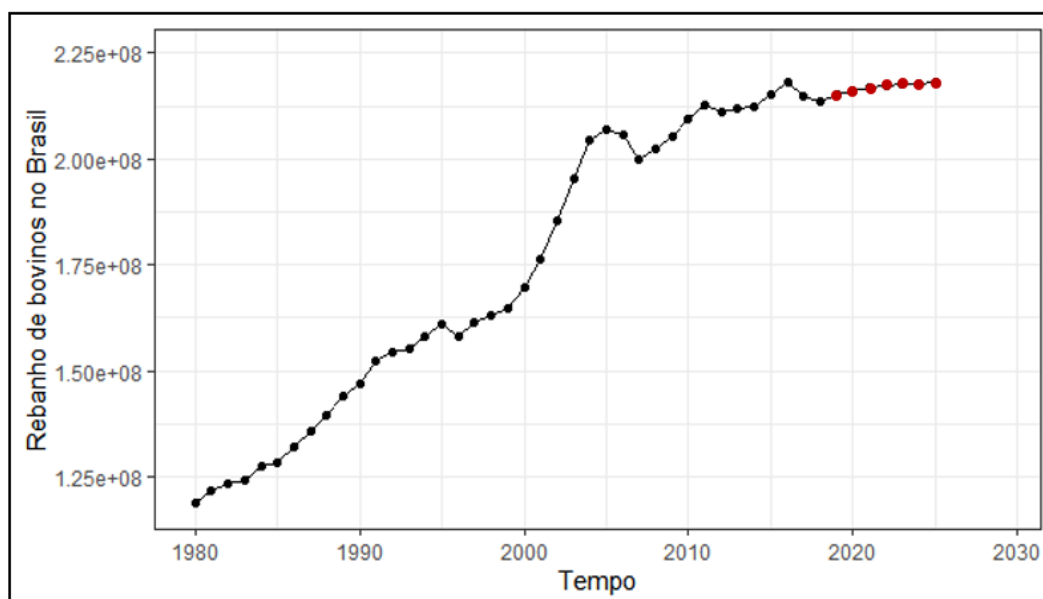
Figura 10 – Gráfico da previsão do rebanho bovino de 2019 até 2025



Fonte: Próprio autor (2020)

A Figura 11 exprime graficamente a previsão efetuada, estando em vermelho os valores correspondentes aos anos entre 2019 e 2025, e em preto os valores correspondentes aos anos entre 2005 e 2018:

Figura 11 - Gráfico rebanho de bovinos no tempo de 1980 até 2018 juntamente da previsão do rebanho bovino de 2019 até 2025



Fonte: Próprio autor (2020)

De acordo com valores gerados pela previsão da RNA, ocorrerá, entre os anos de 2018 e 2025 um aumento de 102,17% no Rebanho bovino, passando de 213,5 milhões para 218,1 milhões de bois no território nacional.

Considerando que apenas 2% dos bovinos estão confinados, e portanto, estão em condições de terem suas fezes coletadas, constrói-se a seguinte tabela:

Tabela 3 – Tabela da previsão do rebanho bovino e bovino confinado de 2019 até 2025

Ano	Rebanho bovino	Rebanho bovino confinado
2019	215.384.478	5.043.588
2020	216.219.926	5.063.152
2021	217.054.038	5.082.684
2022	217.355.489	5.089.743
2023	217.824.695	5.100.730
2024	217.888.607	5.102.227
2025	218.172.793	5.108.881

Fonte: Próprio autor (2020)

Adotando a estimativa, representadas pelas equações 7 e 8, foi obtido que um boi pode gerar

1168 kW de potência elétrica por ano, e portanto, R\$654,08. Este valor representa de maneira monetária a quantidade de energia gerada pelo boi.

Levando em consideração apenas os valores previstos para o Rebanho bovino confinado da Tabela 3, junto com as equações 7 e 8, para calcular, respectivamente, a quantidade de energia total e o valor desta, que poderia estar sendo produzida por todos os bois em confinamento do país, foram montadas as seguintes tabelas:

Tabela 4 - Tabela da previsão da energia gerada de 2019 até 2025

Ano	Energia(kWh)
2019	5.890.911.151
2020	5.913.761.219
2021	5.936.574.746
2022	5.944.819.635
2023	5.957.652.736
2024	5.959.400.773
2025	5.967.173.452

Fonte: Próprio autor (2020)

A Tabela 4 representa a previsão de energia gerada em kWh pelo rebanho bovino confinado no Brasil.

Tabela 5 - Tabela da previsão do valor em reais da energia gerada de 2019 até 2025


Ano	R\$
2019	3.304.801.155,54
2020	3.317.620.043,61
2021	3.330.418.432,46
2022	3.335.043.815,04
2023	3.342.243.184,96
2024	3.343.223.833,39
2025	3.347.584.306,49

Fonte: Próprio autor (2020)

A Tabela 5 representa a previsão do valor da energia gerada pelo rebanho bovino confinado no Brasil.

Os valores obtidos podem ser representados pelos seguintes gráficos:

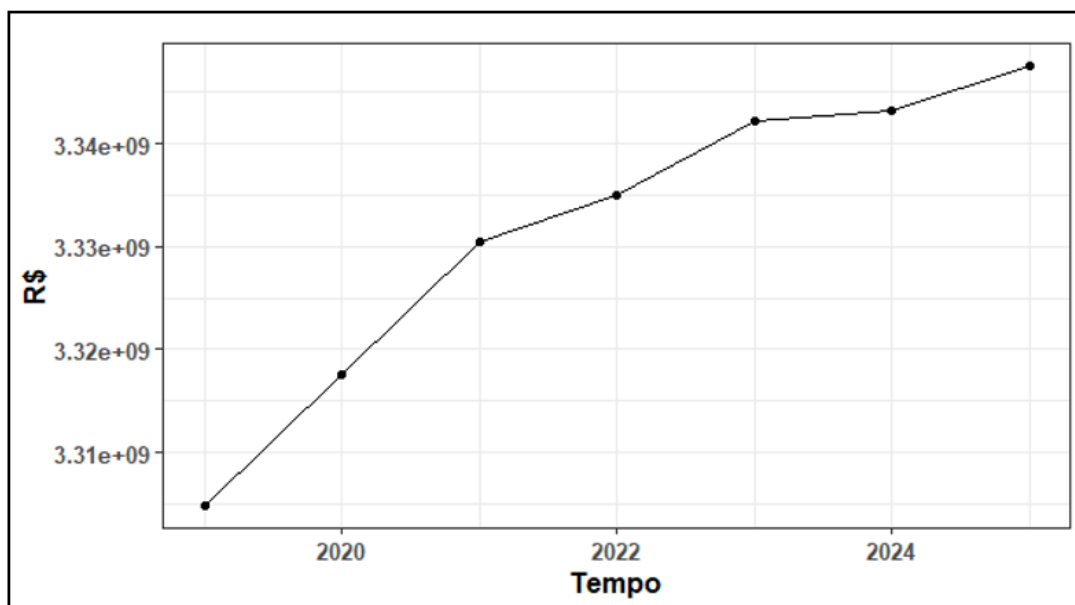
Figura 12 – Gráfico da previsão da energia gerada de 2019 até 2025



Fonte: Próprio autor (2020)

A Figura 12 representa graficamente a energia produzida pelo rebanho bovino entre os anos de 2019 e 2025.

Figura 13 – Gráfico da previsão do valor em reais da energia gerada de 2019 até 2025



Fonte: Próprio autor (2020)

A Figura 13 representa graficamente o valor da energia produzida pelo rebanho bovino entre os anos de 2019 e 2025.

5. Conclusão

Apesar de apenas 2%, aproximadamente, do rebanho bovino nacional estar em confinamento, é plausível concluir que visar utilizar potencial energético das fezes desses animais, para a produção de energia elétrica a partir da produção de biogás, uma fonte alternativa, renovável e disponível, pode vir a ser uma boa opção. Afinal, considerando a produção da Usina Hidrelétrica Itaipu Binacional, que é líder mundial em produção de energia limpa e renovável, no ano de 2019, um dos anos mais secos na história da usina, onde a Itaipu produziu 79,4 milhões de MWh, ou 79,4 bilhões de kWh, a utilização das fezes de bois confinados, considerando a eficiência de geradores, poderia gerar, utilizando a previsão para o mesmo ano, a mesma quantidade de energia que 7,42% da produção da usina.

O valor de 5,89 bilhões de kWh produzidos, para o ano de 2019, é o suficiente para abastecer, durante um ano, mais de 3 milhões de residências no país.

Ademais, de acordo com a valoração realizada, o montante que poderia ser gerado pelos animais em confinamento, de 3,304 bilhões de reais em 2019, representa 0,045% do PIB brasileiro, sendo este, para o ano de 2019, de R\$ 7,3 trilhões.

Em concordância com a previsão de crescimento do rebanho bovino nacional, realizada pela utilização de uma Rede Neural Artificial, que prevê, para o período de 2018 à 2025, um aumento de 2,17% ou 4,6 milhões de cabeças em números absolutos. É plausível afirmar que esta representatividade energética tende a aumentar.

O impacto positivo da utilização desta energia não está somente em valores monetários e energéticos, mas está, também, no impacto que esta pode gerar em questões ambientais, já que o metano, principal gás do biogás, é considerado o segundo que mais contribui com o efeito estufa, perdendo apenas para o dióxido de carbono.

6. Referências

ABIEC - ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS EXPORTADORAS DE CARNES. Pecuária Brasileira. Disponível em: < http://www.abiec.com.br/3_pecuaria.asp>. Acesso em: 30 Mar. 2020.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL. Atlas de Energia Elétrica. 2 ed. 2005. Disponível em: < <http://www.aneel.gov.br/aplicacoes/Atlas/download.htm>>. Acesso em: 28 Abril 2020.

CARVALHO, Manuel. (2013). Futuro do lixo. Disponível em: . Acesso em: Abril, 2020.

CEPEA. PIB DO AGRONEGÓCIO CRESCE 3,81% EM 2019. PIB DO AGRONEGÓCIO , 6 mar. 2020. Disponível em: https://www.cepea.esalq.usp.br/upload/kceditor/files/Cepea_PIB_CNA_2019.pdf. Acesso em: 18 maio 2020.

EHLERS, R. S. Análise de Séries Temporais. 4ª ed., Laboratório de Estatística e Geoinformação, Departamento de Estatística, UFPR, Curitiba, PR, 2007. Disponível em: . Acesso em: 20 de abril de 2020.

HAYKIN, S. Neural networks: a comprehensive foundation. (2ª ed.) Upper Saddle River, New Jersey: Prentice Hall. 1999.

HIGMAN, Christopher; BURGT, Maarten Van Der. Elsevier Science, Gasification, Gulf Professional Publishing: Feedstocks and Feedstock Characteristics. 1 ed., cap. 4, Burlington, MA, USA, 2003.

HOFFMANN, Rodolfo. Distribuição de renda medidas de desigualdade e pobreza., 1998.

HYNDMAN, Rob Athanapoulos; ATHANASOPOULOS, George. Forecasting: Principles and Practice. [S. l.: s. n.], 2018. Disponível em: <https://otexts.com/fpp2/>. Acesso em: 3 maio 2020.

IBGE. Sistema IBGE de Recuperação Automática - SIDRA. In: Pesquisa de pecuária municipal.. Disponível em: <https://sidra.ibge.gov.br/tabela/3939>. Acesso em: 1 fev. 2020.

IPEA. Economia Agrícola. Carta de Conjuntura, 2º trimestre de 2018. Disponível em: https://www.ipea.gov.br/portal/images/stories/PDFs/conjuntura/180529_cc_39_economia_agricola.pdf. Acesso em: 9 maio 2020.

LATORRE, M. R. D. O; CARDOSO, M. R. A. Análise de séries temporais em epidemiologia: uma introdução sobre os aspectos metodológicos. Rev. Bras. Epidemiol. Vol. 4, Nº 3, 2001.

MORETTIN, P. A.; TOLOI, C. M. C. Previsões de Séries Temporais, 2ª ed. Atual, São Paulo, 1987.

NICOLAS. Accuracy module. Disponível em: <https://surprise.readthedocs.io/en/stable/accuracy.html>. Acesso em: 7 maio 2020

PESSOA, Vanira; RIGOTTO, Raquel. Agronegócio: geração de desigualdades sociais, impactos no modo de vida e novas necessidades de saúde nos trabalhadores rurais, 2 abr. 2012. Disponível em: <https://www.scielo.br/pdf/rbso/v37n125/a10v37n125.pdf>. Acesso em: 9 maio 2020.

RIBEIRO, A. L. Teorias da Administração. São Paulo: Saraiva, 2003.

SOUZA, Rodrigo Clemente Thom de. Previsão de séries temporais utilizando rede neural treinada por filtro de Kalman e evolução diferencial. 2008. Dissertação (Mestrado em Engenharia de Produção e Sistemas) - Pontifícia Universidade Católica do Paraná., 2008. Disponível em: <https://docs.ufpr.br/~thom/papers/dissertation.pdf>. Acesso em: 11 fev. 2020

VICENTE, Renato. Redes Neurais para Inferência Estatística. USP, 2006. Disponível em: <https://www.ime.usp.br/~rvicente/RNcomMatlab.pdf>. Acesso em: 3 fev. 2020

XIE, H.; TANG, H.; LIAO, Y. Time series prediction based on narx neural networks: an advanced approach. Proceedings of the Eighth International Conference on Machine Learning and Cybernetics. China, 2009.

ZHANG, L.; LUH, P. B. Neural network-based market clearing price prediction and confidence interval estimation with an improved extended Kalman filter method. IEEE Transactions on Power Systems, Vol. 20, No. 1, p. 59-66, 2005.