

Projeções da produção de rebanhos e área de cobertura de pastagem usando modelagem ARIMA com abordagem hierárquica para o estado do Pará e suas regiões

Mikeias S. Oliveira¹, Rafael S. Fernandes¹, Marcio R. S. Melo², Daniel L. Souza³, David C. C. Silva², Gilberto N. Souza Jr², Marcus B. Braga².

¹Campus Parauapebas – Universidade Federal Rural da Amazônia (UFRA)
PA-275 s/n – Zona Rural – 68.515-000 – Parauapebas, PA – Brazil

²Campus Paragominas – Universidade Federal Rural da Amazônia (UFRA)
PA-256 s/n – Nova Conquista – 68.627-451 – Paragominas, PA – Brazil

³Departamento de Computação – Centro Universitário do Estado do Pará (CESUPA) Av. Governador José Malcher, 1963 – 66.060-230 – Belém, PA – Brazil

{mikeias.d.s.o,daniel.leal.souza}@gmail.com,{rafasfer2,marcio.melo,david.silva,marcus.braga,gilbertojr}@ufra.edu.br

Abstract. *Livestock in the territory of Pará offers planning challenges for both the state and the private sector, with consequences of herd expansion impacting economic and socio-environmental variables. This article presents a study on livestock projections in terms of production and pasture coverage area using ARIMA (AutoRegressive Integrated Moving Average) modeling through the hierarchical approach. A short-term time series data analysis framework was developed, covering data referring to the state of Pará between the years 1985 to 2021, with projections until 2026. The results indicate an increase of 19% in the number of cattle and 1.5% in pasture areas in the state of Pará, revealing an increase in productivity in the Marabá region, as well as stabilization in the Redenção region.*

Resumo. *A pecuária no território paraense oferece desafios de planejamento tanto para o estado, quanto para iniciativa privada, com consequências da expansão do rebanho impactando em variáveis econômicas e socioambientais. Este artigo apresenta um estudo sobre projeções de produção de rebanhos e área de cobertura de pastagem utilizando a modelagem ARIMA (AutoRegressive Integrated Moving Average) por meio da abordagem hierárquica. Foi desenvolvido um framework de análise de dados de séries temporais de curto prazo, abrangendo dados referentes ao estado do Pará e suas regiões entre os anos de 1985 e 2021, com projeções até 2026. Os resultados indicam um aumento de 19% de efetivo bovino e 1,5% nas áreas de pastagem do estado do Pará, revelando um aumento de produtividade na região de Marabá, bem como uma estabilização na região de Redenção.*

1. Introdução

O Brasil, em 2021, registrou um efetivo bovino estimado em 224 milhões de cabeças, contando com fatores capazes tanto de garantir o suprimento de carne bovina no âmbito nacional, quanto atender parte da demanda internacional [IBGE 2023]. Naturalmente, a garantia de oferta de carne bovina exige que haja capacidade de produção, isto é, condições edafoclimáticas, bem como fatores de produção, entre os quais a terra é um fator preponderante.

Neste sentido, a pecuária no estado do Pará é presumida em mais de 23,9 milhões de cabeças, sendo o terceiro maior, superado apenas pelos estados do Mato Grosso (32,4 milhões) e Goiás (24,2 milhões). Em 1981, o estado Pará era o décimo rebanho nacional, com pouco mais de 2,8 milhões de cabeças (2,3% do total do país); nono, em 1991, o total era superior a 6,6 milhões (4,4% no rebanho nacional); em 2001, aparecia em sétimo com 11 milhões ou 6,3%, em 2011 já estava em quinto com 18,2 milhões ou 8,6%; e, como destacado anteriormente, em 2021, o rebanho paraense ultrapassou a marca de 20 milhões de cabeças e atingia 10,7% do efetivo brasileiro. Em relação às taxas de crescimento do rebanho bovino no período de 1974 a 2021, o incremento brasileiro foi de 1,93% ao ano, o do Pará foi de impressionantes 6,61% a.a. [IBGE 2023].

Estudos buscam, por um lado, explicar as causas e consequências da expansão do rebanho no território paraense e, por outro, mostrar as correlações entre as variáveis econômicas e socioambientais [De Mello, 2006]. Destaca-se que, para além do quantitativo de animais, essa dinâmica ajudou a povoar o estado, bem como desenvolver áreas até então pouco conectadas com os centros econômicos do país e do exterior, contribuindo, por exemplo, na redução dos preços da carne, na garantia de disponibilidade de proteína animal, na manutenção das taxas cambiais e no saldo da balança comercial brasileira.

Em contrapartida, a expansão da atividade pecuária pode levar à degradação do solo e desmatamento [Castro *et al.* 2005]. Adicionalmente, é necessário preservar áreas de vegetação nativa, estas que, são fundamentais para manter a biodiversidade e os serviços ecossistêmicos que beneficiam a sociedade [Parron *et al.* 2015]. Em particular, o governo do Pará tem promovido políticas públicas que visam minimizar impacto ambiental da atividade produtiva sendo, em destaque, a criação de áreas protegidas e o estabelecimento de incentivos fiscais para produtores rurais que adotam práticas sustentáveis. Conseqüentemente, o uso de sistemas integrados de produção agropecuária e a adoção de técnicas de manejo mais eficientes tornam-se imprescindíveis para a conservação ambiental [Scaff *et al.* 2004].

Tendo por base tal conjuntura, os modelos matemáticos, estatísticos e computacionais são ferramentas de grande importância e possibilitam, por exemplo, prever a demanda por carne bovina, a evolução da atividade pecuária e as tendências de mercado, subsidiando os produtores em tomadas de decisões estratégicas baseadas em dados [Zanella *et al.* 2016; Casagrande and Hoss 2010]. Ademais, as projeções geradas por esses modelos, tanto na questão do efetivo de rebanhos do estado, quanto da questão do uso de cobertura da terra por pastagem, também podem ajudar na preservação ambiental a fim de avaliar a capacidade de suporte dessas áreas, evitando a superexploração e o desmatamento desordenado.

Um dos modelos mais utilizados para a projeção de séries temporais é o ARIMA (*AutoRegressive Integrated Moving Average*), capaz de analisar o comportamento histórico dos dados, identificar padrões e tendências, e assim, realizar previsões precisas [Silva *et al.* 2017]. Uma das principais vantagens do modelo ARIMA é sua capacidade de lidar com dados não estacionários, ou seja, dados que possuem tendências e sazonalidades, permitindo realizar previsões a curto e médio prazo, que pode ajudar na tomada de decisões mais assertivas [Fattah *et al.* 2018]. Este modelo também tem a vantagem de ser relativamente simples e fácil de interpretar, além de ser aplicável a uma ampla gama de séries temporais [Amin *et al.* 2013].

Ressalta-se que atualmente modelos de aprendizado de máquina estão sendo bastante utilizados, contudo, esses métodos se comportam melhor se tiverem uma quantidade de dados significativa. Alguns desses modelos necessitam de milhares de dados para gerar um nível de predição generalista, com baixo teor de tendência e sobreajuste de dados [Weigend *et al.* 1995]. Por sua vez, modelos estatísticos como ARIMA são bem empregados para a projeção de séries de dados curtas, gerando valores confiáveis em termos de precisão sobre os dados observados [Hongzhan *et al.* 2012].

Este estudo propõe um framework de análise de séries temporais de curto prazo (de 1985 até 2021, totalizando 36 registros no decorrer dos 36 anos) para a previsão de tendências de crescimento, estabilização ou redução da produção da pecuária de bovinos. Utilizou-se fontes de dados públicas para a criação de um banco de dados para análise das variáveis sob a perspectiva econômica, social e ambiental, a saber: Sistema IBGE de Recuperação Automática (<https://sidra.ibge.gov.br/home/abate/brasil>) para coleta dos dados de produção; e MapBiomas Brasil (<https://mapbiomas.org/>), para coleta dos dados de uso e cobertura da terra.

O presente estudo tem por objetivo identificar as regiões mais relevantes, bem como a trajetória da produção de rebanhos (número de cabeças) e área de cobertura de pastagem (hectares), visto que essas informações possuem relação direta no campo econômico e socioambiental, sensíveis para o estado do Pará. O repositório deste trabalho se encontra no link: https://github.com/npcateam2/data_agro.

2. Materiais e métodos

2.1. Modelagem ARIMA com abordagem hierárquica

Tipicamente, as séries temporais hierárquicas são utilizadas em divisões geográficas, e desagregadas em categorias mais finas. Essas categorias são aninhadas nas categorias de grupos maiores e, portanto, a estrutura é agregada hierarquicamente [Hyndman & Athanasopoulos 2018].

O Pará é geograficamente distribuído em 7 regiões intermediárias (Belém, Castanhal, Marabá, Redenção, Santarém, Altamira e Breves) e 21 regiões imediatas (Belém, Cametá, Abaetetuba, Castanhal, Bragança, Capanema, Paragominas, Capitão Poço, Marabá, Parauapebas, Tucuruí, Redenção, Tucumã-São Félix do Xingu, Xinguará, Santarém, Itaituba, Oriximiná, Altamira, Almeirim-Porto de Moz, Breves e Soure-Salvaterra). Além das áreas geográficas do Pará, o estado em sua totalidade também foi utilizado para realização das projeções.

A Figura 1 mostra a estrutura hierárquica para uma única variável. No topo da hierarquia o valor “Total” refere-se ao estado do Pará como um todo (nível 1), que é desagregado em 7 regiões intermediárias (nível 2), que por sua vez são subdivididas em 21 regiões imediatas (nível 3). Para o contexto deste trabalho, o número total de séries temporais é $n = 1 + 7 + 21 = 29$ para $m = 3$ níveis. Já a série temporal no topo da hierarquia $y_{1,1}(t)$ será avaliada no tempo t , considerando a região ($i = 1$) do nível ($j = 1$) como a soma das séries de nível ($j = 2$). A expressão matemática (Equação 1) trata-se de um modelo de regressão para séries temporais dada por:

$$y_{1,1}(t) = y_{1,2}(t) + y_{2,2}(t) + \dots + y_{7,2}(t) \quad (1)$$

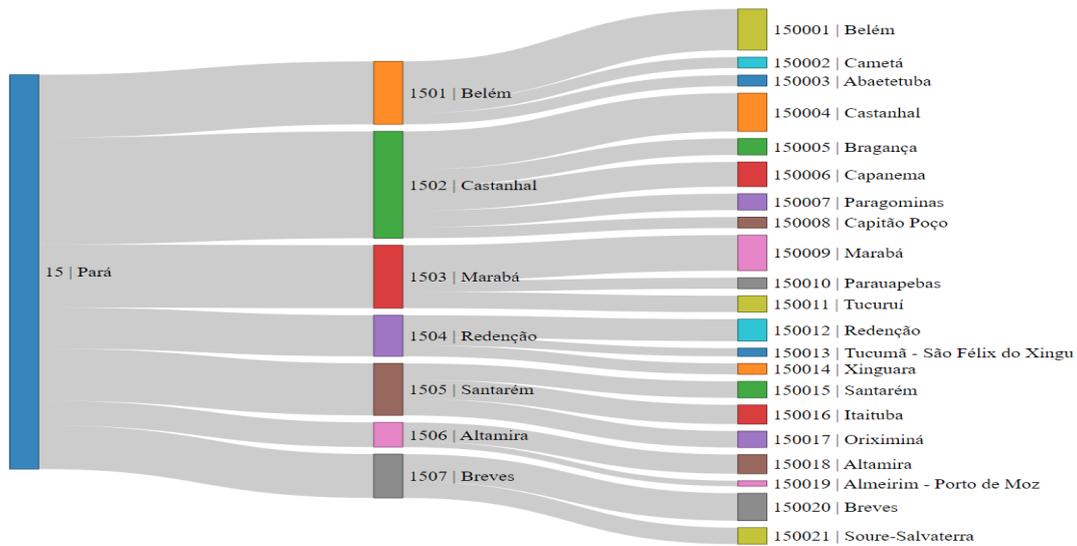


Figura 1. Diagrama de Sankey contabilizados pela quantidade de municípios do Pará

Consequentemente, as séries temporais de nível 2 são desagregadas como a soma das séries de nível 3. Por meio da notação matricial (Equação 2), a matriz $S_{n \times m}$ (matriz das somas), determina a maneira pela qual a série de nível inferior é agregada, descrita como:

$$\begin{bmatrix} y_{1,2} \\ y_{2,2} \\ y_{3,2} \\ y_{4,2} \\ y_{5,2} \\ y_{6,2} \\ y_{7,2} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 & 0 & \dots & 0 \\ 0 & 0 & 0 & 1 & \dots & 0 \\ 0 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & 0 & \dots & 1 \\ 0 & 0 & 0 & 0 & \dots & 1 \end{bmatrix} \begin{bmatrix} y_{1,3} \\ y_{2,3} \\ y_{3,3} \\ \vdots \\ y_{21,3} \end{bmatrix} \quad (2)$$

Observa-se que as variáveis $[y_{1,3}, y_{2,3}, y_{3,3}]$ referem-se as regiões imediatas de “150001 | Belém”, “150002 | Cametá” e “150003 | Abaetetuba”, respectivamente. Logo, apenas estas regiões compõem a região intermediária “1501 | Belém” sendo, as demais, multiplicadas por zero e excluídas da equação de regressão $y_{1,2}$.

De forma genérica, as previsões são necessárias para todas as séries agregadas e desagregadas, em que as previsões num determinado nível hierárquico sejam somadas da mesma forma que os dados. Isso é uma vantagem em termos de processamento metodológico dos dados, pois possibilita a integração das diversas séries das suas correspondentes regiões e posteriormente são reconciliadas para ajuste do valor final previsto.

Para os propósitos deste artigo, as previsões hierárquicas são realizadas por modelos ARIMA (do inglês “*autoregressive integrated moving average*”). Adicionalmente, o ARIMA sazonal adiciona termos que buscam capturar a dinâmica sazonal nos dados. Sua formulação básica, consiste numa parte não sazonal do modelo (p, d, q) , numa parte sazonal (P, D, Q) e um período sazonal (m) . O componente (p) corresponde a ordem da parte autorregressiva, o componente (q) a ordem da parte de média móvel e o componente (d) o grau de diferenciação envolvido [Box and Jenkins 1970].

Tradicionalmente, as previsões envolvem selecionar um nível de agregação e gerar previsões para este nível. Estes são então agregados para níveis mais altos, ou

desagregados para níveis mais baixos, para obter um conjunto de previsões coerentes para o resto da estrutura [Hyndman & Athanasopoulos 2018]. Este processo é conhecido como reconciliação de previsão e possui três abordagens tradicionais, a saber: “*bottom-up*”, “*top-down*” e “*Middle-out*”.

A abordagem “*bottom-up*” envolve primeiro as previsões das séries temporais de nível inferior e, em seguida, a soma destas séries irão produzir as séries superiores na estrutura. De forma contrária, temos a abordagem “*top-down*” e, por fim, a abordagem “*Middle-out*” combina as abordagens anteriores, ao partir de uma previsão em nível intermediário e gerando previsões para cima e para baixo [Gross & Sohl 1990]. Ressalta-se que a abordagem adotada independe do modelo de previsão utilizado.

Neste contexto as projeções são univariadas para cada série, mas reagrupadas e ajustadas com reconciliação de séries temporais hierárquicas, através do método de minimização por rastreamento [Wickramasuriya *et al.* 2017]. Esta técnica realiza a reconciliação “ideal” minimizando a variância total da previsão do conjunto de previsões coerentes, usando, portanto, todas as informações disponíveis dentro de uma estrutura agrupada.

2.2. Área de estudo, fonte e processamento de dados

O estado do Pará é o segundo maior estado do Brasil em extensão territorial, com 1.248.000 km², com mais de 8 milhões de habitantes, detendo cerca de 41.962 imóveis rurais médios e grandes, que se distribuem numa área de 25,1 milhões de hectares (20% do território do estado) [Atlas of Human Development in Brazil 2010; Governo do Pará, 2022].

O framework proposto segue o processo clássico de mineração de dados, com algumas adaptações em certos procedimentos, sendo as etapas correspondentes a: coleta, integração e investigação dos dados, seleção das variáveis, pré-processamento, divisão entre treinamento e validação, treinamento dos modelos via parametrização por busca em grid, validação dos dados, pós-processamento (reconciliação hierárquica), e uso do modelo para geração das projeções [Rotondo *et al.* 2020].

Os dados coletados no presente estudo são anuais, referente ao período entre 1985 e 2021. Desta forma, cada uma das 29 séries temporais possui 36 dados de análise para as duas variáveis consideradas neste estudo (efetivo de rebanho e área de pastagem).

Inicialmente foi necessário tratar e integrar os dados das diferentes bases formando um conjunto de dados únicos. Além da integração das duas bases, foi incluído também os detalhamentos geográficos aos dados, como regiões intermediárias e imediatas. Os dados de cobertura de terra da plataforma MapBiomas correspondem a mapas classificados com base na família de satélites do programa *LandSat*, com resolução espacial de pixel de 30 metros [Souza Jr *et al.* 2020]. A plataforma disponibiliza a área de hectares de cada uma de suas classes por municípios, que para esse trabalho, contabilizou-se 143 registros diferentes de municípios do estado do Pará. As informações preservadas se reservaram ao município, identificador de classe (valor que indica se o pixel de imagem é classificado como pastagem, soja, floresta etc.), nome da classe e ano do registro. As classes de interesse foram mantidas e as demais foram descartadas, sendo classes de interesse a classe de Pastagem.

Já o banco de dados agregados do SIDRA disponibiliza séries temporais coletadas por estimativas e consultas a especialistas de diversos campos do conhecimento, como: administração pública, agroindústria, economia agrícola e estatística [SIDRA, 2023]. Essa ferramenta possibilita a recuperação de dados diretamente dos sistemas de dados do IBGE por município. Dentro deste sistema, diversas tabelas são disponibilizadas com as mais diferentes finalidades. As tabelas extraídas possuem o efetivo dos rebanhos (número de cabeças de bovinos). Os registros dos dados passaram por transformações e limpezas que garantiram a qualidade e coerência dos dados. Após essa limpeza, as informações foram mescladas com os dados de cobertura da terra.

2.3. Avaliação

A avaliação das previsões no treinamento e seleção dos parâmetros dos modelos ocorre pelo método de validação cruzada de séries temporais por janela deslizante [Westerveld *et al.* 2021; Hyndman 2023]. Os modelos são, portanto, definidos por busca em *gridsearch*, uma técnica que de forma exaustiva modifica os parâmetros de entrada de um modelo e avalia com base nos resultados qual o melhor conjunto de parâmetros. Esse processo é aplicado em previsões a cada 4 anos à frente dos dados de treinamento. Os dados de treinamento do primeiro *fold* (conjunto de dados segregados) vão até o ano 2017, e a cada *fold* o dado de treinamento aumenta um passo (janela de tamanho igual a 1 ano), até chegar ao ano final de 2021. Já os valores de cada componente do ARIMA, utilizados na função do *gridsearch*, foram:

- (p, d, q) , da parte não sazonal, varia nos valores 0, 1 e 2;
- (P, D, Q) , da parte sazonal, são valores fixo de 0 e 1, respectivamente, sendo que a sazonalidade (m) varia entre os valores de 3, 6 e 12.

Para avaliar os modelos, no processo de busca em grid, são utilizados os dados de validação (4 anos finais restantes) para calcular o erro com a métrica RMSE conforme Equação 3. Após a seleção do modelo, utiliza-se o modelo para realizar projeções históricas e a previsões à frente do horizonte de previsão, reavaliando o modelo com o coeficiente de variação (Equação 4), para fins de constatação do erro percentual.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (3)$$

$$coef_{var} = 100 \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}}{\bar{y}_t} \quad (4)$$

Em que, n é a quantidade total de elementos, t é o elemento da sequência real de y , e da sequência predita de \hat{y} , com \bar{y}_t sendo a média da sequência real. É importante ressaltar que, neste caso, existem os erros de ajuste (RMSE), que são calculados no processo de treinamento-validação, e os erros de previsão ($coef_{var}$), que são calculados após o treinamento-validação para análise percentual.

3. Resultados e discussões

Para aprofundar a análise, os gráficos exibidos nessa seção visam o entendimento do comportamento das séries projetadas ao decorrer dos anos para identificação de tendências de redução e crescimento. A Figura 2, Figura 3 e Figura 4 mostram essas tendências para o crescimento de rebanhos (número de cabeças) e da área de cobertura de

pastagem (hectares), para as 7 regiões intermediárias do estado do Pará, entre os anos 1985 até 2021, além de suas projeções até o ano de 2026, com ênfase para duas regiões intermediárias, sendo elas, Redenção e Marabá, que em relação às outras regiões, possuem maior quantidade de bovinos e regiões de pastagens.

De acordo com os dados (Figuras 2, 3 e 4), ao longo desses 36 anos, o Estado do Pará registrou aumento em seu efetivo bovino, de aproximadamente 595%, partindo de pouco mais de 3.4 milhões de cabeças em 1985, para quase 24 milhões de animais no ano de 2021, padrão observado também em suas projeções. Conforme as previsões, o ano de 2026 deverá apresentar um crescimento de cerca de 19% em comparação ao ano de 2021, com destaque para as regiões imediatas de Marabá, Tucuruí e Parauapebas.

Em relação ao quantitativo de áreas utilizadas com pastagem cultivadas (Figura 3), é possível observar dois períodos distintos: (1º) entre os anos 1985 e 2008, com tendência de crescimento marcado pela expansão das áreas de pastagem e associado sobretudo ao modelo extensivo de produção da pecuária, amplamente utilizado na época [Dias-Filho, 2016]; (2º) entre 2008 e 2021, percebe-se uma desaceleração no número de novas áreas destinada ao cultivo de pastagem resultante principalmente das políticas públicas voltadas ao monitoramento e controle do desmatamento (ex: operação arco de fogo), ocasionando em um impacto significativo sobre o processo de ampliação das áreas de pastagem cultivadas. Visto isso, é possível verificar uma estabilização nos valores das projeções para o ano de 2026 quando comparado com o ano de 2021, sendo observado apenas um aumento de 1,5% nas áreas de pastagem no estado do Pará. Destaca-se também o aumento da produção de bovinos e da área de pastagem na região imediata de Tucumã - São Felix do Xingu de forma a ultrapassar a região imediata de Redenção, além de um pequeno aumento na área de pastagem na região imediata de Tucuruí, conforme as projeções.

Baseado nos valores de número de cabeças e de hectares, foi calculada a produtividade pela razão dessas variáveis, descritas nos gráficos da Figura 5. As regiões imediatas de Parauapebas, Xingua, Marabá e Tucuruí, respectivamente, possuem crescimento de produtividade. A região de Redenção indica estabilidade de crescimento de produtividade, e a região de Tucumã - São Félix do Xingu, indica decréscimo de produtividade, conforme as projeções. Estes valores podem indicar que a adoção de técnicas voltadas ao manejo correto e necessário da pastagem estão possibilitando maior otimização dos recursos e a intensificação do uso de terra, o que contribui para o melhor desempenho da pecuária bovina, [Fernandes *et al.* 2008; Bungenstab *et al.* 2019].

4. Considerações finais

Com vasta extensão territorial e condições climáticas favoráveis, os rebanhos bovinos desempenham um papel crucial na economia do Pará, gerando empregos e renda. Além disso, a produção de carne bovina é um importante produto de exportação para o estado, ajudando a equilibrar a balança comercial e contribuindo para o desenvolvimento econômico.

Este trabalho utilizou-se de um framework baseado no modelo ARIMA com modelagem hierárquica capaz de gerar projeções relacionadas ao estado do Pará, com valores de média de erros percentuais em 6,85% (efetivo de rebanhos) e 3,70% (área de cobertura). Este framework pode ser uma ferramenta fundamental para uma gestão mais sustentável da atividade pecuária no estado do Pará. Ao fornecer informações precisas sobre a evolução da atividade, os produtores e gestores públicos podem tomar decisões

mais acertadas, garantindo o equilíbrio entre a produção de carne bovina e a preservação ambiental.

As projeções de crescimento do efetivo bovino frente às projeções de redução das áreas de pastagens para o estado do Pará, apresentadas neste trabalho, evidenciam mudanças pelas quais vem passando a bovinocultura empregada. Essa análise é de funda-

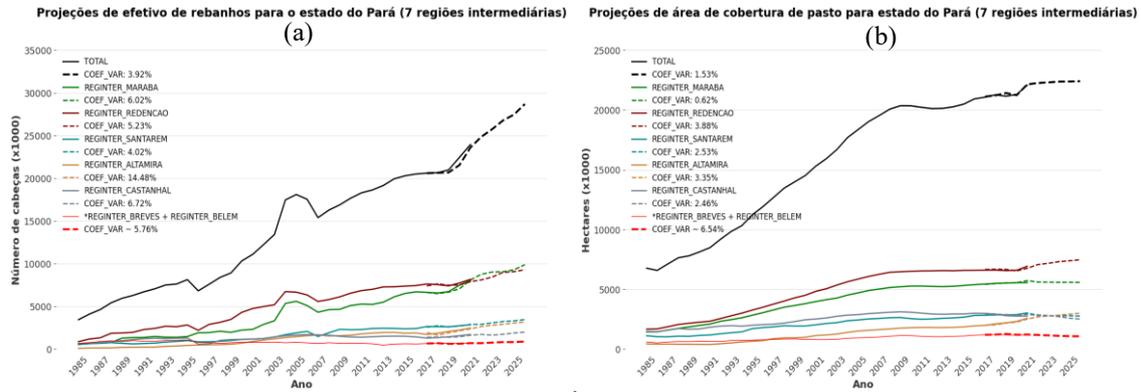


Figura 2. Gráficos com as projeções e valores reais de efetivo de rebanhos no Pará com o erro percentual. Linhas contínuas representam os dados reais e as linhas pontilhadas representam as projeções geradas pelo modelo.

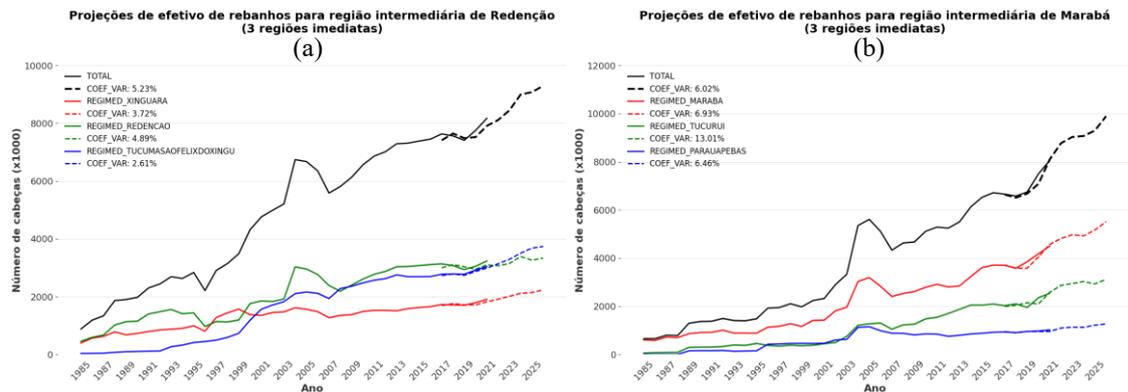


Figura 3. Gráficos com as projeções e valores reais de efetivo de rebanhos das regiões intermediárias de Redenção e Marabá com o erro percentual.

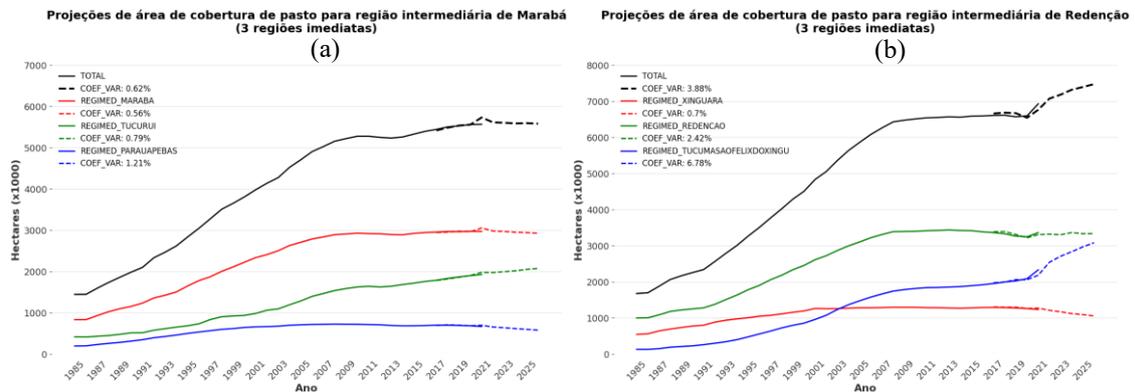


Figura 4. Gráficos com as projeções e valores reais de cobertura de pastagem das regiões intermediárias Redenção e Marabá com o erro percentual.

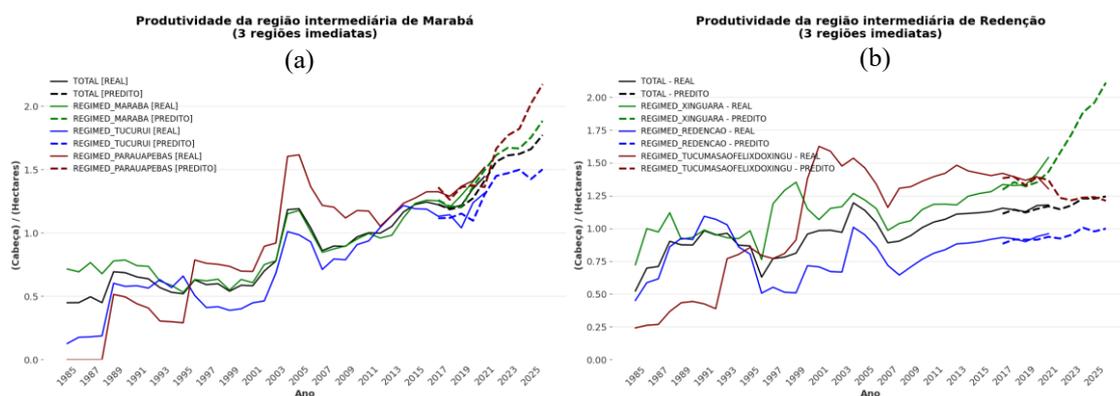


Figura 5. Gráficos com as projeções e valores reais de produtividade com o erro percentual para as regiões intermediárias de Redenção e Marabá.

mental importância para monitorar possíveis efeitos no meio ambiente amazônico. Destaca-se que: o preparo adequado do solo para seu cultivo; a adoção de técnicas ligadas ao manejo do pastejo, como exemplo os sistemas rotacionados, que permitem aumentar a taxa de lotação; e a adoção de sistemas integrados com a lavoura; podem auxiliar na diminuição da pressão exercida por este setor produtivo sobre as áreas de floresta nativa.

Referências

- Amin, A.; Grunske, L; Colman, A. (2013). An approach to software reliability prediction based on time series modeling. *Journal of Systems and Software*, 86(7), pp.1923-1932.
- Atlas of Human Development in Brazil. (2010) Ranking | Atlas do Desenvolvimento Humano no Brasil, <http://www.atlasbrasil.org.br/2013/pt/ranking/>, Accessed December 2020.
- Box, G. E. P., & Jenkins, G. M. (1970). *Time series analysis: Forecasting and control*. Holden-Day
- Bungenstab, D. J.; Almeida, R. G. de; Laura, V. A.; Balbino, L. C.; Ferreira, A. D. (ed.). (2019). *ILPF: inovação com integração de lavoura, pecuária e floresta*. 835 p. Brasília, DF: Embrapa. ISBN: 978-85-7035-922-3
- Casagrande, L. F., Hoss, O. (2010). Métodos de forecasting conjugado com um método qualitativo e um método com a média das previsões quantitativas e qualitativas. *Revista CAP - Número 04 - Ano 4 - Volume 4*.
- Castro, E. (2008). Dinâmica socioeconômica e desmatamento na Amazônia. *Novos Cadernos NAEA v. 8, n. 2, p. 5-39, dez. 2005, ISSN 1516-6481*
- Dias-Filho, M. B. (2016). *Uso de Pastagens para a Produção de Bovinos de Corte no Brasil: Passado, Presente e Futuro*. Belém, PA: Embrapa Amazônia Oriental. 42 p. Documentos / Embrapa Amazônia Oriental, ISSN 1983-0513
- Fattah, J.; Ezzine, L.; Aman, Z.; Moussami, H. E.; Lachhab, A. (2018). Forecasting of demand using ARIMA model. *International Journal of Engineering Business Management*. Volume 10: 1–9. 2018. DOI: 10.1177/184797901880867
- Fernandes, P. C. C.; Grise, M. M.; Alves, L. W. R.; Silveira Filho, A.; Dias-Filho, M. B. (2008). *Diagnóstico e modelagem da integração lavoura-pecuária na região de Paragominas, PA*. Belém, PA: Embrapa Amazônia Oriental. 33p. Documentos/ Embrapa Amazônia Oriental, ISSN 1517-2201.
- Governo do Pará. (2022). *PLANO ESTADUAL DE BIOECONOMIA DO PARÁ -PlanBio Pará*, https://www.semas.pa.gov.br/wp-content/uploads/2023/01/Plano-Estadual-V9_pg-simple-2-1.pdf, Accessed April 2023.

- Gross, C.W.; Sohl, J.E. (1990). Disaggregation methods to expedite product line forecasting. *J. Forecast.*, 9: 233-254. <https://doi.org/10.1002/for.3980090304>
- Hongzhan, N., Guohui L., Xiaoman L., Yong W. (2012). Hybrid of ARIMA and SVMs for Short-Term Load Forecasting, *Energy Procedia*, Vol 16, p. 1455-1460, ISSN 1876-6102, doi: <https://doi.org/10.1016/j.egypro.2012.01.229>.
- Hyndman, R. J., Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*. Reino Unido: OTexts.
- Hyndman R. J. (2023). Cross-validation for time series. <<https://robjhyndman.com/hyndsight/tscv/>>. Acesso 15.02.2023.
- IBGE - Instituto Brasileiro de Geografia e Estatística. (2023). “Produção Pecuária Municipal” <<https://sidra.ibge.gov.br/pesquisa/ppm/quadros/brasil/2021>>. Acesso 14.01.2023.
- Weigend S. A , Mangeas M, and Srivastava N.A. (1995). Nonlinear gated experts for time series: discovering regimes and avoiding overfitting, *International Journal of Neural Systems*, VOL. 06, NO. 04 , doi: <https://doi.org/10.1142/S0129065795000251>.
- Westerveld, J. J. L.; Van den Homberg, M. J. C.; Nobre, G. G.; Van den Berg, D. L. J.; Teklesadik, A. D.; Stuit, S. M. (2021). Forecasting transitions in the state of food security with machine learning using transferable features. *Environment* Volume 786, 10 September 2021, 147366. <https://doi.org/10.1016/j.scitotenv.2021.147366>
- Wickramasuriya, S. L.; Athanasopoulos, G.; Hyndman, R. J. (2017). Optimal forecast reconciliation for hierarchical and grouped time series through trace minimization. 15 June 2017. <https://robjhyndman.com/papers/MinT.pdf>
- Mello, N. A. (2006). *Políticas territoriais na Amazônia*, 1ª edição. ISBN: 85-7419-620-7. Annablume
- Parron, L. M.; Garcia, J. R.; Oliveira, E. B. De; Brown, G. G.; Prado, R. B. (2015). *Serviços ambientais em sistemas agrícolas e florestais do Bioma Mata Atlântica*. Brasília, DF: Embrapa, 2015. Páginas:372 p. ISBN: 978-85-7035-485-3
- Rotondo A, Quilligan F. (2020). Evolution paths for knowledge discovery and data mining process models. *SN Computer Science*. 2020 Mar;1(2):109.
- Scaff, F.F; Tupiassu, L.D.C. (2004). Tributação e políticas públicas: o ICMS ecológico. *Revista de Direito Ambiental da Amazônia*. Manaus: Universidade do Estado do Amazonas, ano, 2, pp.15-36.
- SIDRA - Sistema IBGE de Recuperação Automática. (2023). <<https://Sistemasifdr.Bibliotecas-Bdigital.Fgv.Br/Bases/Sidra-Sistema-Ibge-De-Recuperacao-Automatica>>. Acesso 15.02.2023.
- Silva, L. (2017). *Análise de aplicação do modelo ARIMA: Estudo em uma instituição federal de ensino superior*. <https://repositorio.ufsm.br/bitstream/handle/1/11684/SILVA_Luiza_Da.pdf?sequence=1&isAllowed=y>. Acesso 25.05.2023.
- Souza Jr, C. M.; Shimbo, J, Z.; Rosa, M, R.; Parente, L. L.; et al., *Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine*. *Remote Sens*. 2020, 12, 2735; doi:10.3390/rs12172735
- Zanella, C.; Vieira, V.; Barichello, R. (2016). Previsão de demanda: um estudo de caso em uma agroindústria de carnes do oeste catarinense. *GEPROS. Gestão da Produção, Operações e Sistemas*, Bauru, Ano 11, nº 1, jan-mar/2016, p. 45-57.DOI: 10.15675/gepros.v11i1.1310.