



ISSN:1984-2295

# Revista Brasileira de Geografia Física

Homepage: [www.ufpe.br/rbgfe](http://www.ufpe.br/rbgfe)



## Produção Agropecuária e Correlação com a Dinâmica Climática em Caicó-RN<sup>1</sup>

Joselma Araújo de Lucena<sup>1</sup>; Bartolomeu Israel de Souza<sup>2</sup>; Marcelo de Oliveira Moura<sup>3</sup>; Joab de Oliveira Lima<sup>4</sup>

<sup>1</sup>Mestre em geografia, UFPB, João Pessoa, Paraíba, Brasil. <sup>2</sup>Doutor em Geografia, Prof. Adjunto (DGEOC/UFPB).

<sup>3</sup>Doutor em Geografia, Prof. Adjunto (DGEOC/UFPB). <sup>4</sup>Doutor em Estatística, Prof. Adjunto (DE/UFPB).

Artigo recebido em 02/12/2012 e aceito em 20/03/2013

### RESUMO

O trabalho teve como objetivo principal analisar a produção agropecuária e sua correlação com a dinâmica climática no município de Caicó/RN, localizado na região semiárida, contribuindo para um melhor planejamento econômico e para o conhecimento do clima como elemento integrado da organização do espaço geográfico. No estudo adotou-se quatro variáveis respostas da produção agropecuária: produção de carne de sol, produção de leite, produção de feijão e produção de milho. A análise de correlação definiu as variáveis que puderam ser utilizadas para ajudar a prever as variáveis respostas. Correlacionando os dados dos elementos climáticos com a agricultura e a pecuária, foi observado que as variáveis correlacionadas de forma mais significativa com as variáveis respostas foram a precipitação, o índice de aridez, a temperatura e a umidade, além do número de cabeças bovinas e o número de vacas ordenhadas para a pecuária e a área plantada e área colhida para a agricultura. Quanto aos modelos de previsão, estes apresentaram um bom ajuste aos dados observados, sendo possível pensar em utilizá-los para fazer previsões futuras à medida que o histórico de dados for sendo incrementado com outras variáveis explicativas.

Palavras-chave: Produção Agropecuária, Dinâmica Climática, Caicó/RN.

## Farming and Agricultural Production and Correlation with Climate Dynamics in Caicó-RN<sup>2</sup>

### ABSTRACT

This work has the objective of analysing the farming and agricultural production and its correlation with climate dynamics in Caicó/RN, located in a semiarid region, contributing to a better economical planning as well as to the knowledge of the climate as an integrated element for the organization of geographic space. The study adopted four response variables of farming and agricultural production: sun-dried meat production, milk production, beans production and corn production. Correlation analysis identified the variables that could be used to help predict the response variables. Correlating the climate element data with agriculture and farming, it was observed that the variables more significantly correlated with the response variables were rainfall, dryness rate, temperature and humidity, in addition to the number of cattle and the number of milked cows for farming and the planted area and the harvested area for agriculture. The predicted models proved to be adequate for the observed data, making it possible to consider the use of them for future predictions as the data report is being incremented with other explanatory variables.

Keywords: Farming Production, Climate Dynamics, Caicó/RN.

\* E-mail para correspondência:  
[joselma.geografia@gmail.com](mailto:joselma.geografia@gmail.com) (Lucena, J. A.).

<sup>1</sup> O presente trabalho foi extraído da dissertação de mestrado de Joselma Araújo de Lucena.

<sup>2</sup> This paper was extracted from Joselma Araújo de Lucena's dissertation for a Master Degree.

## Introdução

A atividade agropecuária assume papel relevante para a sobrevivência da população em todo o mundo. Quanto ao estudo geográfico do clima e sua relação com essa atividade econômica, a análise na perspectiva da organização do espaço agrícola deve partir de uma concepção de clima como insumo nos processos naturais e de produção. Neste sentido, segundo Monteiro (1976), o clima apresenta diferentes maneiras de influenciar e condicionar o espaço, assumindo importante papel como insumo, tanto em áreas rurais como em ambientes urbanos, sendo comum a irregularidade dos fenômenos atmosféricos ocorrerem com mais frequência do que os considerados padrões habituais e normais.

Na concepção de Santos (1979), são vários os fatores naturais que norteiam o setor agrícola. O fator climático demonstra influência na quantidade produzida, envolvendo estudos de planejamento agrícola e econômico de grande importância para a sociedade. Desse modo, a análise das relações existentes entre elementos climáticos ao longo dos anos e a produção e rendimento de colheitas constitui-se em um importante campo de estudo.

Como afirma Sant' Anna Neto (1998), as irregularidades temporais do clima apresentam forte impacto nas atividades agrícolas, pois interfere na fenologia das plantas e dos cultivos, oferecendo ou não as condições necessárias e exigências de calor e

água no ritmo e período adequado. Ainda de acordo com o mesmo autor, ao se considerar o clima como insumo na produção agrícola, pretende-se afirmar que o seu papel é de regulador do processo.

De acordo com Braido (2010), os elementos climáticos combinados com as características do solo de determinada região podem contribuir para potencializar a produção de alimentos. No entanto, problemas relacionados com eventos climáticos extremos, como secas prolongadas ou chuvas excessivas, geram impactos negativos sobre a economia e sobre a vida da população das regiões afetadas.

Angelotti (2011) explica que elementos do clima como temperatura, precipitação pluviométrica, radiação solar, umidade relativa, umidade do solo, entre outros, afetam diretamente a agricultura. Neste sentido, com a variabilidade de elementos do clima e a ocorrência de eventos extremos (secas, cheias ou ainda o aumento na frequência de ondas de calor), geram consequências econômicas, sociais e ambientais negativas nas diversas regiões do Brasil.

Em se tratando da produção da agricultura de sequeiro, como o desenvolvido do semiárido nordestino, segundo Sabourin (2009), quer na forma de subsistência com cultivos alimentares e pequenos animais, quer na forma mista para o autoconsumo e inserção nos mercados local e regional, este é muito

dependente das precipitações, dos solos e da vegetação natural. Em casos de seca prolongada, com anos sucessivos de déficit pluviométrico, o sistema de produção familiar fica bem mais dependente do meio ambiente e dos recursos naturais.

Na opinião de Porto (2009), existe todo um aparato tecnológico compatível com as condições ecológicas da região Nordeste do Brasil, entretanto, a produção agrícola de sequeiro do semiárido nordestino continua sujeita a violentas flutuações, desencadeadas por adversidades climáticas, o que demonstra que um dos principais objetivos originais da política de desenvolvimento regional – fortalecer a economia da região semiárida

contra os efeitos da seca – ainda está por ser exercido. No contexto das mudanças climáticas globais o enfrentamento da tendência em que a agricultura no semiárido se apresenta, cria a necessidade de instauração de transformações no estilo do desenvolvimento rural da região.

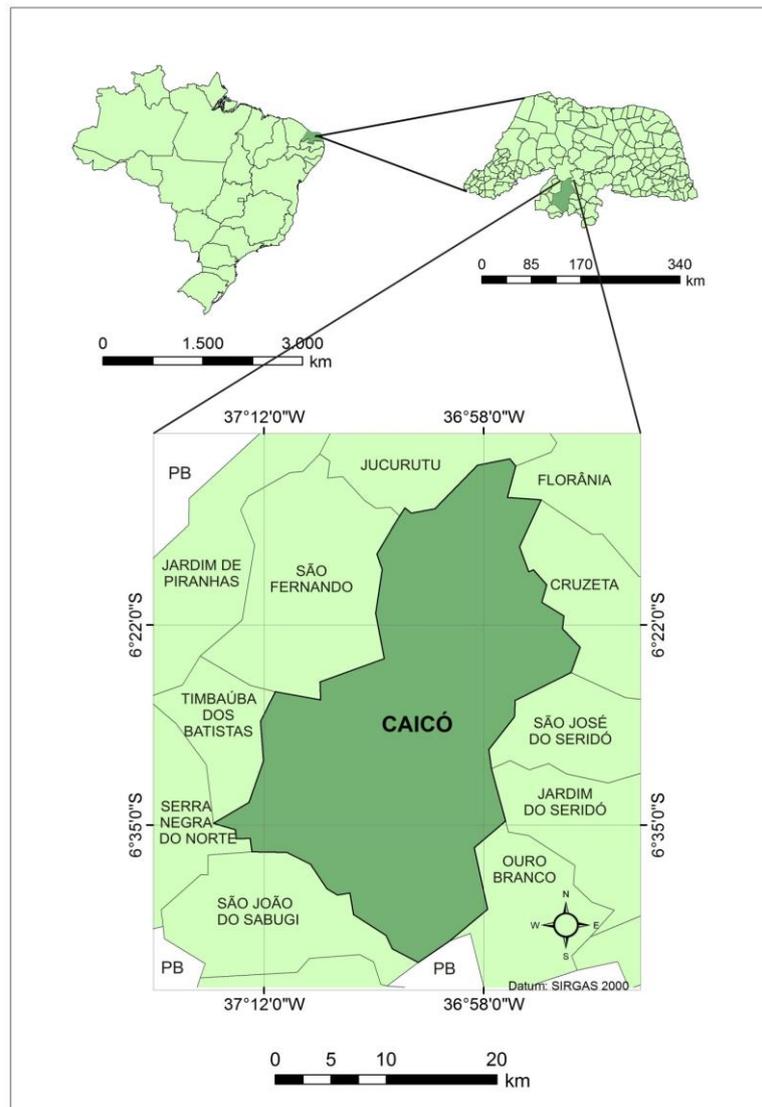
Embasados nessa perspectiva, foi investigada neste estudo a produção agropecuária e sua correlação com a dinâmica climática no município de Caicó, localizado na parte semiárida do Rio Grande do Norte, contribuindo para um melhor planejamento econômico na região e para o conhecimento do clima como elemento integrado da organização do espaço geográfico.

## **Material e Métodos**

### **Área de Estudo**

O município de Caicó, Figura 01, insere-se no semiárido potiguar, na Microrregião do Seridó Ocidental, conforme classificação adotada pelo IBGE (2012). Do

ponto de vista do quadro físico dominante, essa região é caracterizada pela escassez e instabilidade das chuvas, elevada temperatura, baixa umidade e uma paisagem marcada pela vegetação de caatinga.



**Figura 01.** Localização geográfica do município de Caicó/RN.

Fonte: Organizado pela autora.

O estudo proposto tem por base uma série de dados dos elementos climáticos (temperatura, precipitação, umidade e índice de aridez) coletados da Estação Climatológica do Seridó, com Latitude  $06^{\circ}28'S$ , Longitude  $37^{\circ}05'W$  e Altitude 169,85 m, administrada pelo Instituto Nacional de Meteorologia e dados da pesquisa municipal da produção de feijão e milho e da produção de leite e carne de sol disponível no Instituto Brasileiro de Geografia e Estatística, no período de 15 anos (1996 a 2010). A partir daí, com a utilização

da planilha eletrônica Microsoft Excel 2007 e o software para análises estatísticas – SPSS (Statistical Package for Social Sciences), estes dados passaram a ser tratados utilizando-se algumas técnicas estatísticas, descrito abaixo:  
Análise de Regressão

A produção agrícola e pecuarista foram correlacionadas com a dinâmica climática por meio de regressão linear. De acordo com Toledo e Ovalle (2008, p.424), “a análise de regressão tem por objetivo descrever através de um modelo matemático,

a relação existente entre variáveis, a partir de n observações dessas variáveis”.

Análise de Regressão é uma técnica de modelagem utilizada para analisar a relação entre uma variável dependente Y (também chamada de variável resposta) e uma ou mais variáveis independentes X<sub>1</sub>, X<sub>2</sub>, X<sub>3</sub>, ..., X<sub>k</sub>, também conhecidas como variáveis explicativas ou preditoras. O objetivo dessa técnica é identificar (estimar) uma função que descreve, o mais próximo possível, a relação entre essas variáveis e assim prever o valor que a variável dependente (Y) irá assumir para um determinado valor da variável independente X (TOLEDO; OVALLE, 2008).

O modelo de regressão poderá ser escrito genericamente como, equação 1:

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon_i$$

Em que o termo  $\varepsilon_i$  representa uma perturbação aleatória em cada observação na função ou o erro da aproximação. O número de variáveis independentes varia de uma aplicação para outra, quando se tem apenas uma variável independente chama-se Modelo de Regressão Linear Simples; quando se tem mais de uma variável independente chama-se de Modelo de Regressão Linear Múltipla.

#### Modelo de Regressão Linear Simples

Como já falado anteriormente, diz-se que o modelo de previsão é linear simples quando existe apenas uma variável explicativa para ajudar a prever a variável resposta. E a

função que expressa esse modelo é, equação 2:

$$Y_i = \beta_0 + \beta_1 X_1 + \varepsilon_i$$

em que,

$\beta_0$  é conhecido como intercepto da reta de regressão (previsão). É como se fosse a média da variável resposta;

$\beta_1$  é denominado o coeficiente angular ou inclinação reta de regressão. Representa o acréscimo (ou decréscimo se seu sinal for negativo) que a variável resposta sofre quando uma unidade é adicionada à variável explicativa X<sub>1</sub>;

Uma vez escolhido o modelo de regressão, deve-se estimar seus parâmetros. Neste caso, os coeficientes da equação da reta, ou seja,  $\beta_0$  e  $\beta_1$ . Isso pode ser feito a partir da aplicação do Método dos Mínimos Quadrados. Segundo Moore et al (2006), “a reta de regressão de mínimos quadrados de y em função de x é a reta que faz com que a soma dos quadrados das distâncias verticais entre os pontos referentes aos dados e essa reta seja a menor possível.”

Tirando a média sobre a equação acima, temos a equação 3:

$$\bar{Y} = \beta_0 + \beta_1 \bar{X}$$

uma vez que a média dos erros é zero.

Subtraindo as duas equações, temos a equação 4:

$$(Y_i - \bar{Y}) = (\beta_0 - \beta_0) + \beta_1(X_i - \bar{X}) + \varepsilon_i$$

Chamando de  $y_i$  e  $x_i$  as diferenças centradas nas médias,  $(Y_i - \bar{Y})$  e  $(X_i - \bar{X})$  respectivamente, temos a equação 5:

$$y_i = \beta_1 x_i + \varepsilon_i$$

ou ainda, a equação 6:

$$\varepsilon_i = (y_i - \beta_1 x_i)$$

Fazendo a soma dos quadrados dos erros, equação 7:

$$\sum \varepsilon_i^2 = \sum (y_i - \beta_1 x_i)^2$$

Como o objetivo é estimar uma equação que minimize os erros, devemos então derivar a equação acima em relação a  $\beta_1$  e igualar a zero. E como não se tem os verdadeiros valores e sim uma amostra, ou seja, o valor a ser determinado é um estimador do verdadeiro valor populacional, a nova nomenclatura para  $\beta_1$  será  $\hat{\beta}_1$ .

Assim, os valores ótimos de  $\beta_0$  e  $\beta_1$  que minimizam os erros são respectivamente, equação 8 e 9:

$$\hat{\beta}_1 = \frac{\sum x_i y_i}{\sum x_i^2}$$

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$$

Sendo que a equação de estimativa será dada por, equação 10:

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i$$

### Modelo de Regressão Linear Múltiplo

Para se trabalhar com o modelo de regressão linear múltiplo, isto é, contendo  $k$  variáveis explicativas, são utilizados os mesmos princípios apresentados para o modelo linear simples, sendo que agora se emprega uma linguagem matricial.

### Premissas do Modelo de Regressão

Para que os resultados de um modelo de regressão sejam válidos, é necessário que os erros aleatórios ( $\varepsilon_i$ ) sejam provenientes de uma Distribuição Normal com média ( $\mu$ ) zero e variância ( $\sigma^2$ ) constante, ou seja,  $\varepsilon_i \sim N(\mu = 0; \sigma^2)$ .

Em outras palavras, em um modelo de regressão, espera-se que as distâncias entre os valores das variáveis resposta observada ( $Y_i$ ) e prevista ( $\hat{Y}_i$ ), que nesse caso representam os erros aleatórios ou de medição ( $\varepsilon_i$ ), tenham valor esperado zero (ou seja, que em média os erros sejam anulados) e com uma variabilidade fixa, constante, chamada aqui de  $\sigma^2$ .

Nesse trabalho, as duas premissas sobre os erros aleatórios foram testadas com o intuito de validar os resultados da análise de regressão.

### Análise de Correlação e Modelo de Previsão

Para se montar um modelo de previsão, é necessário escolher o “melhor”

conjunto de variáveis preditoras, ou seja, é fundamental eleger as variáveis explicativas que influenciam ou são correlacionadas com a variável resposta. Nesse caso, será de posse desse conjunto de variáveis explicativas que conseguiremos fazer boas previsões.

A ferramenta estatística que se presta a esse papel é a Análise de Correlação e o Coeficiente de Correlação de Pearson ( $\rho$ ) é o melhor representante dessa classe. O Coeficiente de Correlação é uma medida entre -1 e 1, sendo o primeiro valor a correlação

inversa perfeita e o segundo valor a correlação direta perfeita.

Portanto, a construção de um modelo de previsão só se faz pertinente se e somente se existirem variáveis explicativas correlacionadas com a variável resposta. Por isso, foi feito inicialmente uma análise de correlação para se identificar quais são os melhores conjuntos de variáveis preditoras para cada modelo de previsão proposto no trabalho.

**Resultados e Discussão**

No estudo da relação dos dados climáticos com os dados de produção agropecuária no município de Caicó/RN, adotou-se quatro variáveis resposta, considerando a importância destas para a subsistência de parte da população local: (a) Produção de Carne de Sol, (b) Produção de Leite, (c) Produção de Feijão e (d) Produção de Milho. Para cada uma dessas variáveis existem diversas variáveis explicativas e a análise de correlação que segue definiu quais dessas variáveis puderam ser utilizadas para ajudar a prever as variáveis respostas.

A Tabela 01 mostra os coeficientes de correlação de Pearson para as variáveis explicativas que puderam ajudar na previsão da produção de Carne de Sol. As células em negrito (e marcadas com asterisco) indicam que a correlação é significativa ao nível de, pelo menos, 5%.

**Tabela 01.** Coeficientes de Correlação de Pearson para as variáveis que se interrelacionam com a produção de Carne de Sol.

VARIÁVEIS	Produção de Carne de Sol	Temperatura	Umidade	Precipitação	Índice de Aridez	Bovinos (Cabeças)
Produção de Carne de Sol	1,000					
Temperatura	-0,486	1,000				

Umidade	0,413	<b>-0,780**</b>	1,000			
Precipitação	<b>0,542*</b>	<b>-0,771**</b>	<b>0,567</b>	1,000		
Índice de Aridez	<b>0,543*</b>	<b>-0,768**</b>	<b>0,570*</b>	<b>0,999**</b>	1,000	
Bovinos (Cabeças)	<b>1,000**</b>	-0,486	0,413	<b>0,542*</b>	<b>0,543*</b>	1,000

\* Correlações significantes ao nível de 5%

\*\* Correlações significantes ao nível de 1%

Fonte: Elaborado por Joab de Oliveira Lima.

Observou-se na tabela 1 que as variáveis correlacionadas de forma mais significativa com a produção de Carne de Sol são a Precipitação, o Índice de Aridez e o Número de Cabeças Bovinas, sendo que esta última apresentou uma correlação perfeita com a variável resposta. Isso é explicado pelo fato de termos estimado a produção de Carne (variável resposta) como sendo uma proporção 50% do peso de um boi padrão de 200Kg (no estudo foi considerado que os bovinos pesavam essa medida, de acordo com informações pessoais obtidas na Associação de Carne de Sol e Queijo de Coalho do Seridó/RN). Portanto, o número de cabeças bovinas não foi considerado no modelo de previsão, pois de certo modo essa variável é uma réplica perfeita da variável resposta.

Além disso, observou-se ainda como as variáveis Temperatura, Umidade, Precipitação e Índice de Aridez estão autocorrelacionadas. Isso quer dizer que, de alguma forma, uma dessas variáveis já contém parte das informações das outras. Dentro da filosofia de modelo de regressão,

chamamos isso de “Multicolinearidade”. A multicolinearidade é observada quando as variáveis preditoras são autocorrelacionadas. Para a construção do modelo de regressão, essa característica poderá ser prejudicial para as estimativas para a variável resposta, uma vez que, mantendo essas variáveis juntas no modelo final, poderemos ter uma espécie de efeito duplicado para os valores previstos da variável resposta. Para contornar isso, deixou-se que o software para análises estatísticas – SPSS (Statistical Package for Social Sciences) escolhesse quais das variáveis permanecessem no modelo final de previsão.

A Tabela 02 mostra os coeficientes de correlação de Pearson para as variáveis explicativas que puderam ajudar na previsão da produção de Leite. Verificou-se que as variáveis correlacionadas, de forma mais significativa, com a produção de Leite são a Precipitação, o Índice de Aridez e o Número de Vacas Ordenhadas.

**Tabela 02.** Coeficientes de Correlação de Pearson para as variáveis que se interrelacionam com a produção de Leite.

VARIÁVEIS	Produção de Leite	Temperatura	Umidade	Precipitação	Índice de Aridez	Vacas Ordenhadas
Produção de Leite	1,000					
Temperatura	0,356	1,000				
Umidade	0,049	<b>-0,780**</b>	1,000			
Precipitação	<b>0,535*</b>	<b>-0,771**</b>	<b>0,567</b>	1,000		
Índice de Aridez	<b>0,529*</b>	<b>-0,768**</b>	<b>0,570*</b>	<b>0,999**</b>	1,000	
Vacas Ordenhadas	<b>0,882**</b>	-0,308	-0,065	<b>0,593*</b>	<b>0,589*</b>	1,000

Fonte: Elaborado por Joab de Oliveira Lima.

A Tabela 03 mostra os coeficientes de correlação de Pearson para as variáveis explicativas que puderam ajudar na previsão da produção de Feijão. Constatou-se que as variáveis correlacionadas de forma mais significativa com a produção de Feijão são a

Temperatura, a Umidade, a Área Plantada e a Área Colhida.

**Tabela 03.** Coeficientes de Correlação de Pearson para as variáveis que se interrelacionam com a produção de Feijão.

VARIÁVEIS	Produção de Feijão	Temperatura	Umidade	Precipitação	Índice de Aridez	Área Plantada (Feijão)	Área Colhida (Feijão)
Produção de Feijão	1,000						
Temperatura	<b>-0,570*</b>	1,000					
Umidade	<b>0,621*</b>	<b>-0,780**</b>	1,000				
Precipitação	0,381	<b>-0,771**</b>	<b>0,567*</b>	1,000			
Índice de Aridez	0,378	<b>-0,768**</b>	<b>0,570*</b>	<b>0,999**</b>	1,000		

Área Plantada (Feijão)	<b>0,523*</b>	-0,090	0,224	-0,236	-0,228	1,000	
Área Colhida (Feijão)	<b>0,964**</b>	<b>-0,586*</b>	<b>0,570*</b>	0,413	0,412	<b>0,602*</b>	1,000

Fonte: Elaborado por Joab de Oliveira Lima.

A Tabela 04 mostra os coeficientes de correlação de Pearson para as variáveis explicativas que puderam ajudar na previsão da produção de Milho. Observou-se que as variáveis correlacionadas, de forma mais

significativa, com a produção de Milho são a Temperatura, a Umidade, e a Área Colhida.

**Tabela 04.** Coeficientes de Correlação de Pearson para as variáveis que se interrelacionam com a produção de Milho.

VARIÁVEIS	Produção de Milho	Temperatura	Umidade	Precipitação	Índice de Aridez	Área Plantada (Milho)	Área Colhida (Milho)
Produção de Milho	1,000						
Temperatura	<b>-0,597*</b>	1,000					
Umidade	<b>0,751**</b>	<b>-0,780**</b>	1,000				
Precipitação	0,417	<b>-0,771**</b>	<b>0,567*</b>	1,000			
Índice de Aridez	0,414	<b>-0,768**</b>	<b>0,570*</b>	<b>0,999**</b>	1,000		
Área Plantada (Milho)	0,485	-0,054	0,272	-0,227	-0,219	1,000	
Área Colhida (Milho)	<b>0,950**</b>	<b>-0,600*</b>	<b>0,682*</b>	0,452	0,453	<b>0,594*</b>	1,000

Fonte: Elaborado por Joab de Oliveira Lima.

Desse modo, a análise de correlação definiu as variáveis explicativas correlacionadas, de forma mais significativa, que foram utilizadas na construção dos modelos de previsão que são mostrados a seguir.

Além do uso das variáveis explicativas já selecionadas, os modelos de previsão

propostos aqui consideraram a Classe Climática e o Nível de Susceptibilidade à Desertificação, ambas as medidas provenientes de uma categorização do Índice de Aridez, Tabela 05. Ao lado da variável “Classe Climática” foram criadas duas outras variáveis indicadoras (*CClima1* e *CClima2*). A primeira delas indica o clima “Semiárido”,

enquanto que a segunda indica o clima “Subúmido Seco”. De maneira semelhante, as variáveis indicadoras *Desert1* e *Desert2* apontam para uma susceptibilidade à desertificação “Alta” e “Moderada” respectivamente.

Para as variáveis categóricas “Classe Climática” e “Nível de Susceptibilidade à

Desertificação”, as categorias-base (*baseline*) foram “Árido” e “Muito Alta”, respectivamente.

**Tabela 05.** Construção das variáveis Classe Climática e o Nível de Susceptibilidade à Desertificação.

	Ano	TempMedia	UmidadeMedia	Precipitacao	Indice_Aridez	Classe_Climatica	CClima1	CClima2	Suscept_Desert	Desert1	Desert2
1	1996	27,36	70,20	882,00	,49	Semiárido	1	0	Alta	1	0
2	1997	28,10	65,47	377,80	,20	Árido	0	0	Muito Alta	0	0
3	1998	29,29	61,51	189,10	,09	Árido	0	0	Muito Alta	0	0
4	1999	28,57	58,88	361,40	,19	Árido	0	0	Muito Alta	0	0
5	2000	27,62	71,70	737,90	,40	Semiárido	1	0	Alta	1	0
6	2001	30,06	55,69	364,20	,19	Árido	0	0	Muito Alta	0	0
7	2002	27,64	69,85	638,40	,35	Semiárido	1	0	Alta	1	0
8	2003	28,56	57,89	405,20	,21	Semiárido	1	0	Alta	1	0
9	2004	27,72	62,32	787,50	,43	Semiárido	1	0	Alta	1	0
10	2005	28,66	57,18	495,50	,26	Semiárido	1	0	Alta	1	0
11	2006	28,03	63,18	727,80	,40	Semiárido	1	0	Alta	1	0
12	2007	28,42	58,16	633,40	,34	Semiárido	1	0	Alta	1	0
13	2008	27,72	63,56	903,60	,51	Subúmido Seco	0	1	Moderado	0	1
14	2009	27,72	67,50	1054,90	,60	Subúmido Seco	0	1	Moderado	0	1
15	2010	28,12	63,07	688,50	,37	Semiárido	1	0	Alta	1	0

Fonte: Dados fornecidos pela Estação Climatológica do Seridó – UFRN/CERES  
Elaborado por Joab de Oliveira Lima.

Os resultados para os modelos de previsão finais, que são mostrados a seguir, são aqueles cujas premissas já foram verificadas e validadas.

- Modelo 1: Previsão da produção de carne de sol – a Tabela 6a revela que apenas a variável “Índice de Aridez” se mostrou realmente importante na Produção da Carne de Sol.

**Tabela 6a.** Estimativas dos parâmetros do modelo de previsão de Produção de Carne de Sol.

Coefficientes do Modelo	Estimativa	Estatística t	Valor-p
Intercepto	1694,784	10,894	0,0000
Índice de Aridez	1000,584	2,332	0,0364

$R^2$  ajustado = 0,543

Fonte: Elaborado por Joab de Oliveira Lima.

Observamos ainda que o ajuste que é proposto apresentou um Coeficiente de

Determinação Ajustado ( $R^2$  ajustado) muito baixo, indicando que os valores previstos

ainda estão um pouco distante dos valores observados. A figura 02a ilustra esse comentário.

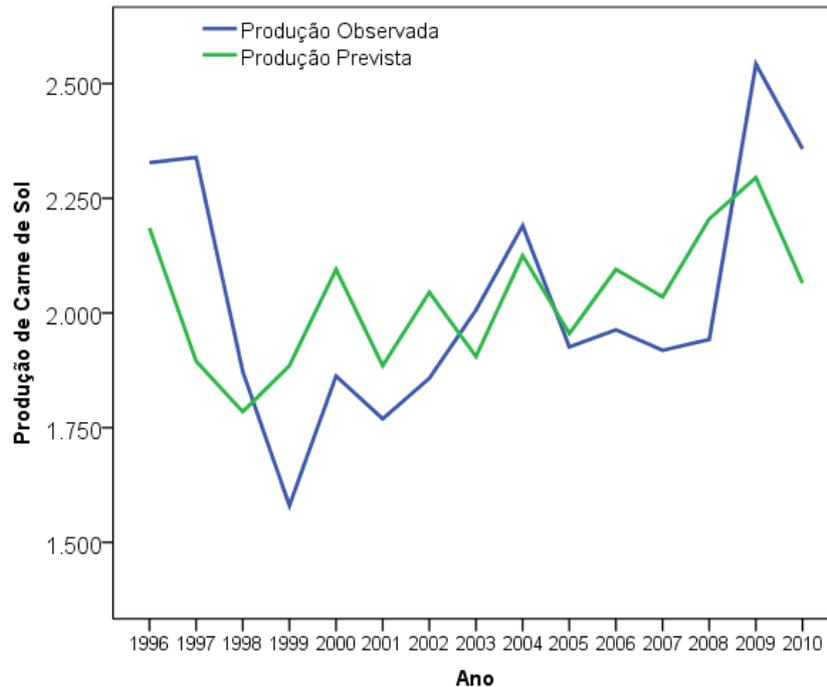


Figura 02a: Modelo de previsão para a produção de Carne de Sol  
 Fonte: Elaborado por Joab de Oliveira Lima.

Uma alternativa para tentar melhorar as previsões é considerar, mesmo não sendo significativas, outras variáveis, tais como

Temperatura, Umidade e Precipitação. Esses resultados estão na Tabela 06b.

**Tabela 06b.** Estimativas dos parâmetros do modelo de previsão de Produção de Carne de Sol.

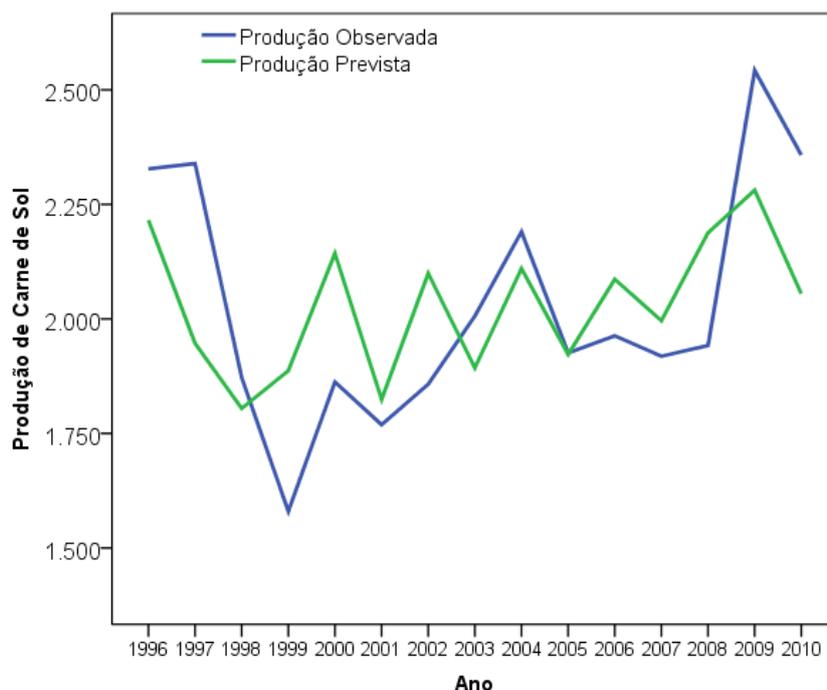
Coeficientes do Modelo	Estimativa	Estatística t	Valor-p
Intercepto	2247,243	0,313	0,7610
Temperatura	-29,091	-0,14	0,8912
Umidade	5,777	0,254	0,8049
Precipitação	-0,429	-0,051	0,9607
Índice de Aridez	1505,577	0,104	0,9189

$R^2$  ajustado = 0,559

Fonte: Elaborado por Joab de Oliveira Lima.

Observamos agora que todas as variáveis explicativas, incluindo o Índice de Aridez, não se mostraram importantes ( $\text{Valor-p} \leq 0,05$ ) na previsão da produção de Carne

de Sol e, além disso, que o  $R^2$  ajustado melhorou muito pouco. A figura 02b ilustra esse comentário.



A figura 02b: Modelo de previsão alternativo para a produção de Carne de Sol.  
 Fonte: Elaborado por Joab de Oliveira Lima.

- Modelo 2: Previsão da produção de leite – a partir de agora, foi mantida a estratégia de deixar no modelo final, mesmo não sendo significativas aquelas variáveis que apresentam correlações significativas com a variável resposta. Sendo assim, a Tabela 07

mostra as estimativas dos parâmetros do modelo de previsão de leite, tendo apenas o Número de Vacas Ordenhadas como fator significativo ( $\text{Valor-p} \leq 0,05$ ) no processo de previsão.

**Tabela 07.** Estimativas dos parâmetros do modelo de previsão de Produção de Leite.

Coeficientes do Modelo	Estimativa	Estatística t	Valor-p
Intercepto	2143,947	1,346	0,2055
Precipitação	15,998	0,534	0,6036
Índice de Aridez	-27053,81	-0,53	0,6065
Vacas Ordenhadas	0,77	4,886	<b>0,0005</b>

$R^2$  ajustado = 0,885

Fonte: Elaborado por Joab de Oliveira Lima.

Esse modelo se mostrou mais ajustado ( $R^2$  na ordem de 0,885) que o modelo de previsão de carne, indicando que os valores

previstos estão mais próximos dos valores observados, conforme a figura 03.

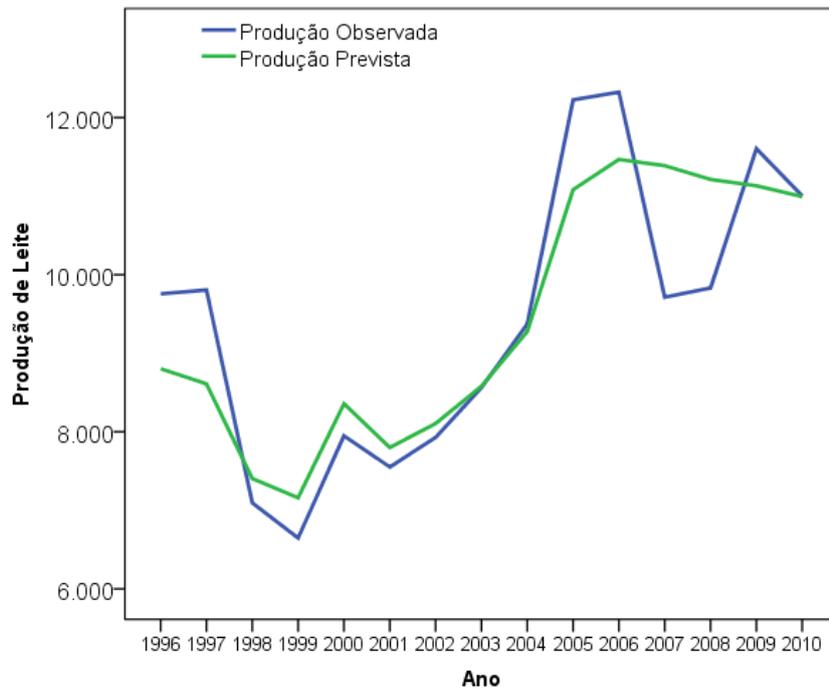


Figura 03: Modelo de previsão para a produção de Leite  
 Fonte: Elaborado por Joab de Oliveira Lima.

- Modelo 3: Previsão da produção de feijão – a Tabela 08 mostra as estimativas dos parâmetros do modelo de previsão de feijão,

tendo apenas a Área Colhida como fator significativo (Valor-p  $\leq 0,05$ ) no processo de previsão.

**Tabela 08.** Estimativas dos parâmetros do modelo de previsão de Produção de Feijão

Coeficientes do Modelo	Estimativa	Estatística t	Valor-p
Intercepto	-869,159	-1,565	0,1486
Temperatura	23,06	1,417	0,1869
Umidade	3,689	1,739	0,1127
Área Plantada	-0,064	-1,277	0,2303
Área Colhida	0,460	8,583	<b>0,0000</b>

$R^2$  ajustado = 0,924

Fonte: Elaborado por Joab de Oliveira Lima.

Esse modelo se mostrou mais ajustado ( $R^2$  na ordem de 0,924), indicando que os

valores previstos estão mais próximos dos valores observados, conforme a figura 04.

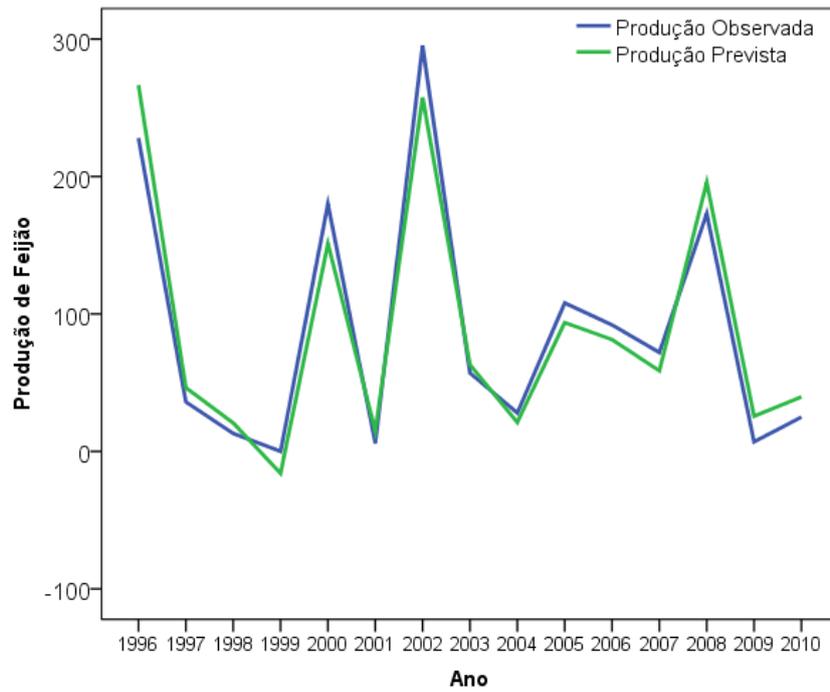


Figura 04: Modelo de previsão para a produção de Feijão.  
 Fonte: Elaborado por Joab de Oliveira Lima.

- Modelo 4: Previsão da produção de milho – a Tabela 09 mostra as estimativas dos parâmetros do modelo de previsão de milho,

tendo apenas a Área Colhida como fator significativo (Valor-p  $\leq 0,05$ ) no processo de previsão.

**Tabela 09.** Estimativas dos parâmetros do modelo de previsão de Produção de Milho.

Coefficientes do Modelo	Estimativa	Estatística t	Valor-p
Intercepto	-1275,987	-1,708	0,1185
Temperatura	31,703	1,45	0,1777
Umidade	6,561	2,129	0,0591
Área Plantada	-0,095	-1,409	0,1892
Área Colhida	0,505	6,78	<b>0,0000</b>

$R^2$  ajustado = 0,915

Fonte: Elaborado por Joab de Oliveira Lima.

Esse modelo se mostrou ajustado ( $R^2$  na ordem de 0,915), como o do feijão, indicando que os valores previstos estão mais

próximos dos valores observados, conforme a figura 05.

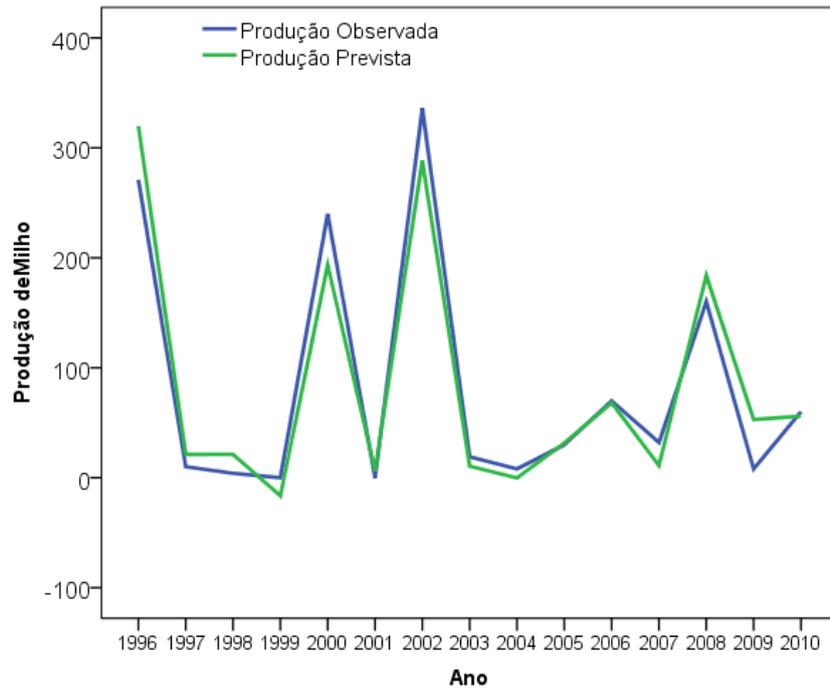


Figura 05: Modelo de previsão para a produção de Milho.  
 Fonte: Elaborado por Joab de Oliveira Lima.

## Conclusões

Além da dinâmica do clima, outros fatores interferem na produção agropecuária, por esta razão fica evidente que a análise não explica toda a produção. Todavia, os resultados apresentados, mesmo não abrangendo uma análise total, contribuem para o conhecimento da dinâmica climática da região e para o planejamento das atividades agropecuárias.

Na correlação dos dados dos elementos climáticos com a agricultura e a pecuária, verificou-se o grau de correlação de cada um. Observou-se que as variáveis correlacionadas de forma mais significativa com a produção de carne de sol são a Precipitação, o Índice de Aridez e o Número de Cabeças Bovinas, sendo que esta última apresentou uma correlação perfeita com a

variável resposta. Na produção do leite, as variáveis correlacionadas de forma mais significativa são a Precipitação, o Índice de Aridez e o Número de Vacas Ordenhadas. Na produção do feijão, as variáveis correlacionadas de forma mais significativa foram a Temperatura, a Umidade, a Área Plantada e a Área Colhida, enquanto na produção do milho foi observado que as variáveis correlacionadas, de forma mais significativa foram a Temperatura, a Umidade, e a Área Colhida.

Quanto aos modelos de previsão desenvolvidos, estes se apresentaram bem ajustados aos dados observados e é possível pensar em utilizá-los para fazer previsões, à medida que o histórico dos dados for sendo

incrementado com outras variáveis explicativas.

Por fim, entendemos que os elementos climáticos podem contribuir para potencializar a produção de alimentos agrícolas e pecuaristas. No entanto, problemas relacionados com eventos climáticos extremos, como secas prolongadas ou chuvas excessivas, geram impactos negativos sobre a economia e sobre a vida da população das

regiões afetadas. Elementos do clima como temperatura, precipitação pluviométrica, umidade relativa e o índice de aridez, afetam diretamente a atividade agropecuária na região semiárida. Neste sentido, a variabilidade de elementos do clima e a ocorrência de eventos extremos podem gerar consequências econômicas, sociais e ambientais negativas.

### Agradecimentos

Os autores agradecem ao Instituto Nacional de Meteorologia por ter gentilmente cedido os dados dos elementos climáticos e ao Instituto Brasileiro de Geografia e Estatística

pelo fornecimento dos dados da pesquisa municipal que contribuíram com informações para realização da pesquisa.

### Referências

- Angelotti, F. (2011). Mudanças climáticas e problemas fitossanitários. In: LIMA, R. C. C. et al. Desertificação e Mudanças Climáticas no Semiárido Brasileiro. Ministério da Ciência, Tecnologia e Inovação. Instituto Nacional do Semiárido – INSA. Campina Grande.
- Braido, L. M. H. (2010). Caracterização edafoclimática e proposta para a determinação do risco de redução de safra na região do Pontal do Paranapanema – SP. Universidade Estadual Paulista. Câmpus de Presidente Prudente. Departamento de Geografia. Dissertação de Mestrado.
- Bruni, A. L. (2009). SPSS aplicado à pesquisa acadêmica. São Paulo: Atlas.
- IBGE. (2012). Instituto Brasileiro de Geografia e Estatística. Disponível em: <www.ibge.gov.br>. Acesso 20.01.2012.
- Monteiro, C. A. F. (1976). Teoria e clima urbano. São Paulo, Série Teses e Monografias, 25 USP/IGEOG.
- Moore, D. S. et al. A prática da estatística empresarial como usar dados para tomar decisões. Rio de Janeiro: LCT, 2006.
- Porto, E. R. (2009). Sistemas Produtivos Dependentes de Chuva: Desempenho e Perspectivas para a Sustentabilidade. In: ANGELOTTI, F. et al. Mudanças Climáticas e Desertificação no Semi-Árido Brasileiro. Ministério da Agricultura, Pecuária e Abastecimento. Empresa Brasileira de Pesquisa Agropecuária. Embrapa Semiárido, Petrolina – PE. Embrapa Informática Agropecuária, Campinas – SP.
- Sabourin, E. (2009). Interações entre População e Recursos Naturais: Evoluções dos Sistemas de Produção. In: ANGELOTTI, F. et al. Mudanças Climáticas e Desertificação no Semi-Árido Brasileiro. Ministério da Agricultura, Pecuária e Abastecimento. Empresa Brasileira de Pesquisa Agropecuária. Embrapa Semiárido, Petrolina – PE. Embrapa Informática Agropecuária, Campinas – SP.
- Sant’anna Neto, J. L. (1998). Clima e organização do espaço. Boletim de geografia. Universidade Estadual de Maringá. Departamento de Geografia. Ano 16 – nº 1.

Santos, M. J. Z. dos. (1979). A importância da variação do regime pluviométrico para a produção canavieira na região de Piracicaba – SP. São Paulo. Série Teses e Monografias, 35 USP/IGEOG.

Toledo, G. L.; Ovalle, I. I. (2008). Estatística Básica. 2ª ed. – 20. reimpr. São Paulo: Atlas.