UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE ECONOMIA AGRÍCOLA
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA RURAL- PPGER

SELEÇÃO PARA O DOUTORADO ACADÊMICO EM ECONOMIA RURAL
TURMA 2025.1
1ª ETAPA ELIMINATÓRIA EM 08 DE NOVEMBRO DE 2024

INSTRUÇÕES:

- Leia atentamente as questões. A interpretação das questões faz parte da prova.
- As questões valem 2,5 pontos cada. Pontuação máxima igual a DEZ (10,0).
- A cada candidato será entregue a prova e a folha-resposta, que deverá ser obrigatoriamente identificada somente com o número de inscrição, de forma legível e devolvida ao final junto com a prova.
- A prova é individual, não sendo permitida conversa entre os candidatos após o seu início.
- A folha-resposta terá que respondida com caneta esferográfica azul ou preta.
- Não será permitida utilização de calculadora, celulares ou qualquer outro aparelho eletrônico.
- Ao final da prova, o candidato não poderá levar consigo a prova e nem os respectivos rascunhos, toda documentação utilizada deverá ser entregue aos fiscais.
- A realização da prova será das 8:30h às 11:30h.
- Ao terminar a prova, entregue ao fiscal este caderno, as folhas respostas e os rascunhos.
- Os dois últimos candidatos ao entregarem a prova, devem deixar juntos o recinto da avaliação, após assinatura confirmando esse fato.

TEORIA ECONÔMICA

QUESTÃO 1: Considere uma empresa rural que possui uma função de produção igual a $Y = X_1^{\alpha} X_2^{\beta}$. Encontre:

a) As quantidades ótimas dos insumos X_1 e X_2 que minimizam os custos da empresa (1,5 PONTO).

Resposta

O Problema de Minimização dos Custos (PMC) é dado por:

Min $C = w_1 X_1 + w_2 X_2$

sujeita a $Y = X_1^{\alpha} X_2^{\beta}$

Montando as Condições de Primeira Ordem (CPO), temos:

A função Lagrangiana:

$$L = w_1 X_1 + w_2 X_2 + \lambda[Y - X_1^{\alpha} X_2^{\beta}]$$

$$\frac{\partial L}{\partial X_1} = w_1 - \lambda \alpha X_1^{\alpha-1} X_2^{\beta} = 0 \quad => \lambda = \frac{w_1}{\alpha X_1^{\alpha-1} X_2^{\beta}} \qquad \text{(I)}$$

$$\frac{\partial L}{\partial X_2} = w_2 - \lambda \beta X_1^{\alpha} X_2^{\beta-1} = 0 \quad => \lambda = \frac{w_2}{\beta X_1^{\alpha} X_2^{\beta-1}} \qquad \text{(II)}$$

$$\frac{\partial L}{\partial \lambda} = Y - X_1^{\alpha} X_2^{\beta} = 0 \qquad \text{(III)}$$

Igualando (I) com (II), temos:

$$\frac{w_1}{\alpha X_1^{\alpha-1} X_2^{\beta}} = \frac{w_2}{\beta X_1^{\alpha} X_2^{\beta-1}} \quad => \frac{w_1}{w_2} = \frac{\alpha X_1^{\alpha-1} X_2^{\beta}}{\beta X_1^{\alpha} X_2^{\beta-1}}$$

$$\frac{w_1}{w_2} = \frac{\alpha X_1^{-1}}{\beta X_2^{-1}} \quad => \frac{w_1}{w_2} = \frac{\alpha X_2}{\beta X_1}$$

$$X_1 = \frac{w_2 \alpha X_2}{w_1 \beta} \qquad (IV)$$

$$X_2 = \frac{w_1 \beta X_1}{w_2 \alpha} \qquad (V)$$

Substituindo (V) em (III), temos:

$$Y = X_1^{\alpha} X_2^{\beta}$$

$$Y = X_1^{\alpha}\left(\frac{w_1 \beta X_1}{w_2 \alpha}\right)^{\beta} => X_1^{\alpha}.X_1^{\beta}\left(\frac{w_1}{w_2}\right)^{\beta}\left(\frac{\beta}{\alpha}\right)^{\beta}$$

$$\left(X_1^{\alpha+\beta}\right)^{\frac{1}{\alpha+\beta}} = \left(Y\left(\frac{w_2}{w_1}\right)^{\beta}\left(\frac{\alpha}{\beta}\right)^{\beta}\right)^{\frac{1}{\alpha+\beta}}$$

$$X_1^*(w_1, w_2, Y) = Y^{\frac{1}{\alpha+\beta}}\left(\frac{w_2}{w_1}\right)^{\frac{\beta}{\alpha+\beta}}\left(\frac{\alpha}{\beta}\right)^{\frac{\beta}{\alpha+\beta}}$$

$$X_1^*(w_1, w_2, Y) = \left[Y\left(\frac{\alpha}{\beta}\frac{w_2}{w_1}\right)^{\beta}\right]^{\frac{1}{\alpha+\beta}}$$

Substituindo (IV) em (III), temos:

$$X_2^*(w_1, w_2, Y) = \left[Y\left(\frac{\beta}{\alpha}\frac{w_1}{w_2}\right)^{\alpha}\right]^{\frac{1}{\alpha+\beta}}$$

Quantidades ótimas de X_1^* e X_2^* que minimizam os custos:

$$X_1^*(w_1, w_2, Y) = \left[Y\left(\frac{\alpha}{\beta}\frac{w_2}{w_1}\right)^{\beta}\right]^{\frac{1}{\alpha+\beta}}$$

$$X_2^*(w_1, w_2, Y) = \left[Y\left(\frac{\beta}{\alpha}\frac{w_1}{w_2}\right)^{\alpha}\right]^{\frac{1}{\alpha+\beta}}$$

b) A função custo da empresa (1,0 PONTO)

Resposta

A função custo resulta em:

$$C(w_1, w_2, Y) = w_1 X_1^*(w_1, w_2, Y) + w_2 X_2^*(w_1, w_2, Y)$$

$$C(w_1, w_2, Y) = w_1.\left[Y\left(\frac{\alpha}{\beta}\frac{w_2}{w_1}\right)^{\beta}\right]^{\frac{1}{\alpha+\beta}} + w_2.\left[Y\left(\frac{\beta}{\alpha}\frac{w_1}{w_2}\right)^{\alpha}\right]^{\frac{1}{\alpha+\beta}}$$

QUESTÃO 2: A função de utilidade do consumidor é dada por $U(q_1, q_2) = q_1 q_2 - 3{q_2}^2$, sujeita a uma restrição orçamentária de $10q_1 + 15q_2 = 180$. O poder de decisão do consumidor está relacionado ao consumo dos bens q_1 e q_2. A partir destas informações, responda os itens a seguir:

a) Qual a Taxa Marginal de Substituição (TMS) quando $q_1 = 15$ e $q_2 = 2$? (0,5 PONTO)

Resposta

Taxa Marginal de Substituição (TMS)

$$TMS = -\frac{UMg_{q_1}}{UMg_{q_2}} = -\frac{q_2}{q_1 - 6q_2}$$

Como $q_1 = 15$ e $q_2 = 2$, temos:

$$TMS = -\frac{2}{15 - 6(2)} = -\frac{2}{3}$$

b) Monte o problema de maximização da utilidade do consumidor e encontre as quantidades de q_1 e q_2 e sua utilidade máxima. (1,5 PONTO)

Resposta:

Problema de maximização da utilidade do consumidor:
Condições de Primeira Ordem (CPO)
Função Lagrangiana

$$L = q_1 q_2 - 3{q_2}^2 + \lambda[180 - 10q_1 - 15q_2]$$

$$\frac{\partial L}{\partial q_1} = q_2 - 10\lambda = 0 \quad => \lambda = \frac{q_2}{10} \qquad \text{(I)}$$

$$\frac{\partial L}{\partial q_2} = q_1 - 6q_2 - 15\lambda = 0 \quad => \lambda = \frac{q_1 - 6q_2}{15} \qquad \text{(II)}$$

$$\frac{\partial L}{\partial \lambda} = 180 - 10q_1 - 15q_2 = 0 \qquad \text{(III)}$$

Igualando (I) com (II), temos:

$$\frac{q_2}{10} = \frac{q_1 - 6q_2}{15} \quad => \frac{q_2}{q_1 - 6q_2} = \frac{10}{15} \quad => 15q_2 = 10q_1 - 60q_2$$

$$75q_2 = 10q_1 \quad => q_2 = \frac{10q_1}{75} \qquad \text{(IV)}$$

$$q_1 = \frac{75q_2}{10} \qquad \text{(V)}$$

Substituindo (IV) em (III), temos:

$$180 - 10q_1 - 15\left(\frac{10q_1}{75}\right) = 0$$

$$10q_1 + \left(\frac{150q_1}{75}\right) = 180$$

$$10q_1 + 2q_1 = 180$$

$$q_1^* = \frac{180}{12} = 15$$

$$q_1^* = 15\ unidades$$

Substituindo $q_1^* = 15$ em (III), temos:

$$180 - 10(15) - 15q_2 = 0$$

$$q_2^* = \frac{30}{15} = 2$$

$$q_2^* = 2\ unidades$$

Utilidade máxima do consumidor, considerando $q_1^* = 15$ e $q_2^* = 2$.

$$U = q_1 q_2 - 3{q_2}^2$$

$$U = (15)(2) - 3(2)^2 = 18\ unidades$$

Assim, o problema de maximização da utilidade do consumidor permitiu encontrar as quantidades ótimas ($q_1^*\ e\ q_2^*$) e sua utilidade máxima sujeita a uma restrição orçamentária.

c) Qual a utilidade marginal da renda? (0,5 PONTO)

Resposta:

A utilidade marginal da renda é dada por λ, logo:

$$\frac{UMg_{q_1}}{p_1} = \frac{UMg_{q_2}}{p_2} = \lambda$$

Em que, $p_1 = 10$ e $p_2 = 15$, considerando as quantidades ótimas ($q_1^* = 15\ e\ q_2^* = 2$), temos:

$$\lambda = 0{,}2$$

Em resumo, a **utilidade marginal da renda** (λ) reflete o valor de uma unidade adicional de renda em termos de utilidade, assumindo que o consumidor maximiza sua utilidade sujeita à restrição orçamentária.

MÉTODOS QUANTITATIVOS

QUESTÃO 3: Considere um modelo de regressão linear simples, onde estamos interessados em estimar o impacto de uma variável explicativa X sobre uma variável dependente Y. Suponha que temos uma amostra de dados (Y_i, X_i) para $i = 1, 2, \dots, n$, e o modelo é especificado como:

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

onde ε_i é o termo de erro, assumido com média zero e variância constante.

A partir desta especificação, responda:

a) Explique como interpretar $\hat{\beta}_0\ e\ \hat{\beta}_1$ na regressão linear. Como a interpretação desses coeficientes mudaria se X fosse transformado, por exemplo, em uma escala logarítmica? (0,5 PONTO)

Resposta:

- **Interpretação de $\hat{\beta}_0$:** Este é o intercepto do modelo de regressão e representa o valor esperado de Y quando $X = 0$. Ou seja, é a média estimada de Y na ausência do efeito de X.

• **Interpretação de $\hat{\beta}_1$:** Este é o coeficiente angular do modelo e indica a variação esperada em Y para uma unidade adicional em X. Assim, $\hat{\beta}_1$ mede a sensibilidade de Y em relação a X.

• **Transformação logarítmica de X:** Se X fosse transformado em uma escala logarítmica lnX, $\hat{\beta}_1$ passaria a representar uma elasticidade. Especificamente, $\hat{\beta}_1$ agora indicaria a variação percentual esperada em Y resultante de uma variação percentual em X.

b) Quais são as principais hipóteses do modelo de regressão linear? Discuta como a violação da homocedasticidade impacta sobre os estimadores de Mínimos Quadrados Ordinários (MQO). (1,0 PONTO)

Resposta:

As principais hipóteses do modelo de regressão linear clássico são:

1. Linearidade dos parâmetros: A relação entre a variável dependente $(\boldsymbol{Y_i})$ e a variável explicativa $(\boldsymbol{X_i})$ é linear, ou seja, o modelo é linear nos parâmetros. Assim, $\boldsymbol{Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i}$

2. Valores de X fixos ou independentes do termo de erro: valores assumidos pelo regressor X podem ser fixos em amostras repetidas (caso do regressor fixo) ou seus valores podem mudar de acordo com a variável dependente Y (no caso do regressor estocástico). No segundo caso, supõe-se que as variáveis X e o termo de erro são independentes, isto é, $cov(\boldsymbol{X_i}, \boldsymbol{\varepsilon_i}) = \boldsymbol{0}$.

3. Valor médio do termo de erro $\boldsymbol{\varepsilon_i}$ é zero: dado o valor de $\boldsymbol{X_i}$, o valor médio ou esperado, do termo de erro aleatório $\boldsymbol{\varepsilon_i}$ é zero. Simbolicamente, temos:
$E(\boldsymbol{\varepsilon_i}|\boldsymbol{X_i}) = \boldsymbol{0}$
ou, se X é não estocástico, $E(\boldsymbol{\varepsilon_i})$=**0**

4. Homocedasticidade ou variância constante de $\boldsymbol{\varepsilon_i}$: A variância do termo de erro é a mesma independentemente do valor de X. Logo,

$$\boldsymbol{Var(\varepsilon_i) = \sigma^2}$$

5. Não há autocorrelação entre os termos de erro: considerando quaisquer dois valores de X, X_i e X_j, com i ≠ j, a correlação entre quaisquer dois $\boldsymbol{\varepsilon_i}$ e $\boldsymbol{\varepsilon_j}$ (i ≠ j) é zero. Simbolicamente,
$cov(\boldsymbol{\varepsilon_i}, \boldsymbol{\varepsilon_j} \mid X_i \text{ e } X_j) = 0$
$cov(\boldsymbol{\varepsilon_i}, \boldsymbol{\varepsilon_j}) = \boldsymbol{0}$ se X for não estocástica

6. O número de observações deve ser maior que o número de parâmetros a serem estimados.

7. Variabilidade dos valores de X: os valores de X em uma amostra não devem ser os mesmos.

8. O erro tem distribuição normal: $\boldsymbol{\varepsilon_i \sim N(0, \sigma^2)}$.

9. Não há multicolinearidade perfeita, ou seja, não há relações lineares perfeitas entre as variáveis explicativas.

A homoscedasticidade garante que os estimadores de MQO sejam eficientes, ou seja, que tenham a menor variância possível. Quando essa hipótese é violada, ocorre **heterocedasticidade**, em que a variância dos erros $\boldsymbol{\varepsilon_i}$ não é constante.

Os principais impactos da heterocedasticidade são:

1. Estimadores ainda não viesados: Os estimadores de MQO para β_0 e β_1 continuam sendo não viesados; eles ainda estarão centrados nos valores verdadeiros populacionais.

2. Perda de eficiência: Os estimadores não são mais eficientes, ou seja, não possuem a menor variância possível.

3. Erros padrão incorretos: Os erros padrão dos coeficientes estimados serão incorretos. Isso compromete os intervalos de confiança e testes de hipóteses, como o teste t. Com heterocedasticidade, os erros padrão são frequentemente subestimados.

4. Impacto nos testes de hipóteses: A presença de heterocedasticidade afeta os testes de hipóteses e as inferências. Como os erros padrão dos estimadores estão incorretos, os valores da estatística t e p-valores são prejudicados, dificultando a interpretação da significância estatística dos coeficientes.

c) Sob quais condições o estimador $\hat{\beta}_1$ será viesado? (0,5 PONTO)
Resposta:

O estimador $\hat{\beta}_1$ em um modelo de regressão linear será viesado quando as condições fundamentais para a validade do estimador de Mínimos Quadrados Ordinários (MQO) não forem atendidas. A seguir estão as principais condições que, se violadas, resultam em viés no estimador $\hat{\beta}_1$:

1. Correlação entre o erro e a variável explicativa:

Se houver correlação entre X e ε, ocorre viés. Isso é comum em casos onde uma variável omitida (que afeta tanto Y quanto X) não foi incluída no modelo ou quando há simultaneidade (onde X é simultaneamente determinado com Y).

2. Erro de especificação do modelo:

Omissão de variáveis importantes que afetam Y pode resultar em viés, pois a falta de variáveis relevantes pode fazer com que X capte indiretamente o efeito das variáveis omitidas.

3. Endogeneidade:

Se X for endógeno (por exemplo, se X for influenciado por Y), o estimador será viesado. A endogeneidade surge, por exemplo, em modelos onde há simultaneidade entre X e Y ou quando existem variáveis omitidas que afetam tanto X quanto Y.

4. Erro de medida na variável explicativa:

Quando X é medida com erro, isso introduz viés no estimador $\hat{\beta}_1$. Esse problema ocorre comumente em estudos empíricos onde as variáveis são obtidas a partir de dados de levantamentos ou aproximações.

d) Defina o problema da multicolinearidade no contexto de regressões múltiplas. Como ela afeta a interpretação dos coeficientes estimados e a precisão dos testes de hipóteses? (0,5 PONTO)

Há multicolinearidade em um modelo de regressão múltipla quando duas ou mais variáveis independentes são fortemente relacionadas linearmente entre si.

Consequências da multicolinearidade

A existência de uma colinearidade exata entre duas ou mais variáveis independentes torna impossível a obtenção dos coeficientes dos parâmetros por Mínimos Quadrado Ordinários (MQO). Por sua vez, na presença de multicolinearidade os estimadores de MQO continuam sendo os Melhores Estimadores Lineares Não Viesados (MELNV). O problema é que a multicolinearidade torna muitas vezes as estimativas dos coeficientes dos parâmetros (β's) insignificantes, já que cada um pressupõe, por definição, a variação em Y dada uma variação unitária em X, mantendo-se constantes as demais informações. Ou seja, se duas variáveis independentes são fortemente correlacionadas, será muito difícil haver variação em uma sem que haja em outra.

Quando há multicolinearidade, torna-se difícil identificar o impacto individual de cada variável explicativa sobre a variável dependente. Os principais problemas decorrentes da multicolinearidade incluem:

1. Dificuldade de interpretação dos coeficientes:

Como as variáveis explicativas estão altamente correlacionadas, o modelo tem dificuldade em distinguir os efeitos individuais de cada variável. Isso torna os coeficientes estimados instáveis e pode levar a resultados incorretos, como sinais opostos ao esperado ou valores muito amplos ou pequenos.
Em termos práticos, se duas variáveis estão altamente correlacionadas, é difícil dizer o quanto cada uma delas impacta a variável dependente de forma independente, já que ambas podem estar captando efeitos semelhantes.

2. Comprometimento dos testes de hipóteses:

Com multicolinearidade, os testes de significância (como o teste t para cada coeficiente) são menos precisos, o que aumenta a probabilidade de rejeitar hipóteses nulas incorretamente. Isso significa que as variáveis explicativas podem aparecer como não significativas (ou ter um p-valor alto) mesmo que, na realidade, tenham um efeito importante sobre a variável dependente.

Dessa forma, a multicolinearidade enfraquece o poder dos testes estatísticos, especialmente os testes de hipóteses para os coeficientes individuais.

QUESTÃO 4: Um economista rural realizou uma pesquisa para entender os fatores que podem afetar o valor bruto da produção (VBP) de pequenos produtores de milho. Ele usou um modelo de regressão linear para mensurar os efeitos das variáveis explicativas sobre o indicador citado, com transformação logarítmica e o uso do Método de Mínimos Quadrados Ordinários. O modelo estimado é dado por:

$$\boldsymbol{ln\ VBP = 10{,}8 + 0{,}62 lnPrecip - 1{,}82 \ln Temp + 0{,}46 \ln Prod - 0{,}27 lnP + \varepsilon_i}$$

Em que:

$\boldsymbol{ln\ VBP}$ **é o valor bruto da produção (em reais por hectare);**

$\boldsymbol{lnPrecip}$ **é a precipitação pluviométrica (em milímetros);**

ln $\boldsymbol{Temp}$ **é a temperatura média (em graus Celsius);**

ln $\boldsymbol{Prod}$ **é a produtividade (kg/hectare);**

$\boldsymbol{lnP}$ **é o preço médio (reais);**

$\boldsymbol{\varepsilon_i}$ **é o termo de erro aleatório.**

Coeficiente de determinação (R^2) e o coeficiente de determinação ajustado são 0,8047 e 0,7848, respectivamente.

As variáveis explicativas apresentam $p < 0,05$.

Estatística F: 141.035

Com base nos resultados do modelo, responda as seguintes alternativas:

a) Interprete os coeficientes e explique como cada variável influencia o valor bruto da produção de milho (1,0 PONTO).

Resposta:

- **Intercepto (10,8)**: Representa o valor esperado de lnVBP quando todas as variáveis explicativas (precipitação, temperatura, produtividade e preço) são iguais a 1 (ou seja, ln(variável)=0). Isso reflete um valor de referência do VBP na ausência dos fatores climáticos e de mercado.
- **lnPrecip (0,62)**: Um aumento de 1% na precipitação está associado a um aumento de aproximadamente 0,62% no valor bruto da produção de milho. Esse coeficiente positivo indica que a precipitação beneficia o rendimento dos pequenos produtores.
- **lnTemp (-1,82)**: Um aumento de 1% na temperatura média resulta em uma diminuição de aproximadamente 1,82% no VBP. Esse efeito negativo sugere que temperaturas mais altas impactam adversamente o VBP, provavelmente reduzindo a produtividade ou afetando a qualidade da produção.
- **lnProd (0,46)**: Um aumento de 1% na produtividade leva a um aumento de aproximadamente 0,46% no VBP. Este coeficiente positivo indica que a maior produtividade contribui para o aumento do valor bruto da produção, sendo uma variável crucial para o resultado financeiro.
- **lnP (-0,27)**: Um aumento de 1% no preço médio do milho está associado a uma redução de aproximadamente 0,27% no VBP, um efeito que pode indicar uma resposta de mercado onde aumentos de preços médios resultam em ajustes negativos na quantidade produzida ou comercializada.

O resultado do modelo mostra que a estimativa a partir das variáveis selecionadas é estatisticamente significante ao nível de significância de 5%.

b) Suponha que, após realizar testes de significância, o coeficiente relacionado a temperatura seja estatisticamente insignificante ao nível de 5%. Discuta o que isso implica para o modelo e para a interpretação das variáveis. O pesquisador deve manter essa variável no modelo? Justifique (0,5 PONTO).

Respostas:

Se o coeficiente de temperatura for insignificante ao nível de 5%, isso indica que, estatisticamente, a temperatura média pode não ter um efeito significativo sobre o VBP na amostra analisada. Isso pode ocorrer devido à baixa variabilidade da temperatura ou à falta de relação com o VBP no contexto específico.

- **Implicações para o modelo**: A presença de uma variável estatisticamente insignificante pode reduzir a precisão do modelo. No entanto, a decisão de manter ou remover a variável depende do contexto. Se a teoria sugere que a temperatura é relevante, o

pesquisador pode optar por mantê-la, mesmo que não seja estatisticamente significativa, pois pode ser importante em outros contextos ou amostras.

- **Decisão de manter ou remover**: Se a variável tem pouca relevância teórica e não melhora o ajuste do modelo, pode ser removida. Caso contrário, o pesquisador pode mantê-la para testar seu efeito em futuras análises com amostras diferentes.

c) Qual é a interpretação econômica do intercepto no modelo apresentado? Em que situação essa interpretação seria válida ou inválida? (0,5 PONTO)

Resposta:

O intercepto de 10,8 representa o logaritmo do VBP quando todas as variáveis explicativas são iguais a zero. Ou seja, a interpretação econômica do intercepto é o efeito médio da variável dependente quando todas as variáveis independentes são iguais a zero

- O intercepto é útil para completar a especificação do modelo, mas não tem significado prático direto.
- Se os valores de referência não forem possíveis ou representativos da realidade dos pequenos produtores de milho, a interpretação direta do intercepto não é útil.

d) Interprete o coeficiente de determinação ajustado e discorra sobre o ajustamento do modelo (0,5 PONTO).

Resposta:

O coeficiente de determinação (R^2) ajustado é uma medida de qualidade do ajustamento da linha de regressão aos dados, dado por:

$$R^2_{ajust} = 1 - \frac{\sum \hat{u}^2 / (n-k)}{\sum y_i^2 / (n-1)}$$

Onde k é o número de parâmetros do modelo (incluindo o intercepto).

No presente modelo, o R^2 ajustado =0,7848 sugere que as variáveis explicativas conseguem explicar cerca de 78,48% da variação no valor bruto da produção de milho, considerando o número de variáveis incluídas.

O R^2 ajustado é útil para avaliar o ajuste do modelo, especialmente em modelos com várias variáveis. Um valor de 78,48% indica um bom ajuste, sugerindo que o modelo explica grande parte da variabilidade no VBP dos pequenos produtores de milho, com uma redução no valor de R^2 para refletir o número de variáveis usadas.