5 – Métodos estatísticos para a estimação do volume

Os métodos estatísticos também constituem uma maneira indireta de se obter o volume, com a peculiaridade de empregar como ferramenta principal a estatística.

Com a ferramenta estatística se consegue estimar o volume da árvore por meio de outras variáveis da mesma, que apresentam correlação com o volume, dentre as quais destacam-se o diâmetro a altura do peito (DAP) e a altura total (h).

A principal ferramenta estatística empregada na mensuração florestal para estudar as relações do volume com outras variáveis da árvore é a análise de regressão.

5.1 - Análise de regressão

5.1.1 - Regressão linear simples

O modelo de regressão definido como um modelo estatístico, difere em conceito de um modelo matemático por apresentar um termo denominado erro aleatório.

Modelo matemático	Modelo de regressão
$Y = \beta_0 + \beta_1 X$	$Y = \beta_0 + \beta_1 X + \varepsilon$

Modelo matemático **Modelo de regressão**

$$Y = \beta_0 + \beta_1 X$$

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

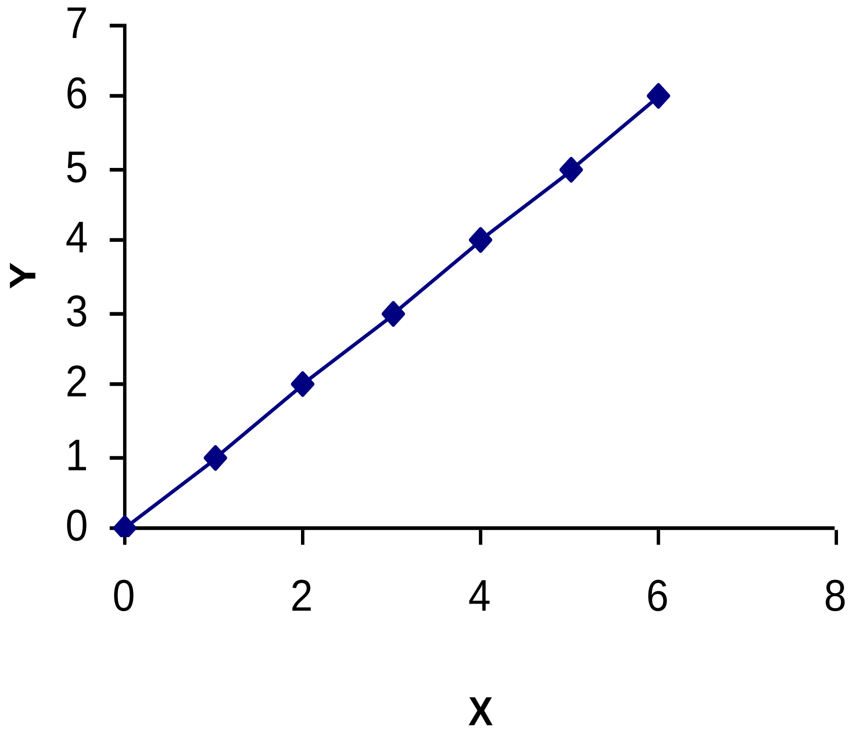

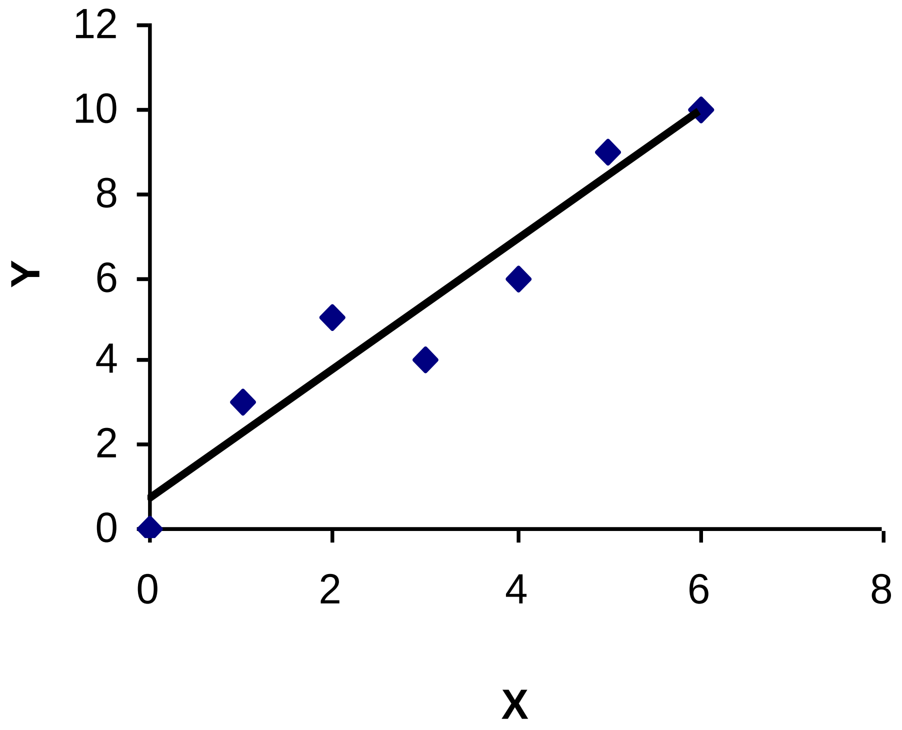

$\Rightarrow$ O método de mínimos quadrados ordinários

Este é um método de estimação muito empregado para estimar parâmetros de modelos de regressão. Seu objetivo principal consiste em minimizar a soma de quadrados dos erros, tal como será demonstrado a seguir:

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \qquad \textbf{(1)}$$

$$\varepsilon_i = Y_i - \beta_0 - \beta_1 X_i \qquad \textbf{(2)}$$

$$\sum_{i=1}^{n} \varepsilon_i^2 = \sum_{i=1}^{n} \left(Y_i - \beta_0 - \beta_1 X_i\right)^2 \qquad \textbf{(3)}$$

$$\frac{\partial \sum_{i=1}^{n} \varepsilon_i^2}{\partial \beta_0} = 2\sum_{i=1}^{n}\left(Y_i - \beta_0 - \beta_1 X_i\right)\left(-1\right) = 0 \qquad \textbf{(4)}$$

$$\frac{\partial \sum_{i=1}^{n} \varepsilon_i^2}{\partial \beta_1} = 2\sum_{i=1}^{n}\left(Y_i - \beta_0 - \beta_1 X_i\right)\left(-X_i\right) = 0 \qquad \textbf{(5)}$$

Dividindo-se (4) e (5) por -2, tem-se:

$$\begin{cases} \sum_{i=1}^{n}\left(Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i\right) = 0 \\ \sum_{i=1}^{n}\left(Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i\right) X_i = 0 \end{cases} \qquad \begin{cases} \sum_{i=1}^{n} Y_i - n\hat{\beta}_0 - \hat{\beta}_1 \sum_{i=1}^{n} X_i = 0 \\ \sum_{i=1}^{n} X_i Y_i - \hat{\beta}_0 \sum_{i=1}^{n} X_i - \hat{\beta}_1 \sum_{i=1}^{n} X_i^2 = 0 \end{cases}$$

$$\begin{cases} \sum_{i=1}^{n} Y_i - n\hat{\beta}_0 - \hat{\beta}_1 \sum_{i=1}^{n} X_i = 0 & \textbf{(6)} \\ \sum_{i=1}^{n} X_i Y_i - \hat{\beta}_0 \sum_{i=1}^{n} X_i - \hat{\beta}_1 \sum_{i=1}^{n} X_i^2 = 0 & \textbf{(7)} \end{cases}$$

$$\hat{\beta}_0 = \frac{\sum_{i=1}^{n} Y_i}{n} - \hat{\beta}_1 \frac{\sum_{i=1}^{n} X_i}{n}$$

$$\boxed{\hat{\beta}_0 = \overline{Y} - \hat{\beta}_1 \overline{X}} \qquad \textbf{(8)}$$

Substituindo (8) em (7) e desenvolvendo a expressão, tem-se:

$$\hat{\beta}_1 = \frac{\sum_{i=1}^{n} X_i Y_i - \frac{\sum_{i=1}^{n} X_i \sum_{i=1}^{n} Y_i}{n}}{\sum_{i=1}^{n} X_i^2 - \frac{\left(\sum_{i=1}^{n} X_i\right)^2}{n}} \qquad \textbf{(9)}$$

EQUAÇÃO DE REGRESSÃO AJUSTADA

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X \qquad \textbf{(10)}$$

ANÁLISE DE VARIÂNCIA DA REGRESSÃO (ANOVA)

FV	GL	SQ	QM	FCalc.
Regressão	p	$\sum_{i=1}^{n}\left(\hat{Y}_i - \overline{Y}\right)^2$	SQReg/GLReg (V_1)	V_1/V_2
Resíduo	$n - p - 1$	$\sum_{i=1}^{n}\left(Y_i - \hat{Y}\right)^2$	SQRes/GLRes (V_2)	
Total	$n - 1$	$\sum_{i=1}^{n}\left(Y_i - \overline{Y}\right)^2$		

Em que:

n = número total de dados;

p = número de variáveis independentes do modelo;

Y_i = valores observados para Y;

$\hat{Y}$ = valores estimados de Y pela regressão;

$\overline{Y}$ = valor médio de Y.

Cálculo da soma de quadrados:

- Soma de Quadrados do Total (SQTot)

$$SQTot = \sum_{i=1}^{n} Y_i^2 - \frac{\left(\sum_{i=1}^{n} Y_i\right)^2}{n}$$

- Soma de Quadrados da Regressão (SQReg)

$$SQ\,Re\,g = \hat{\beta}_1^2 \left(\sum_{i=1}^{n} X_i^2 - \frac{\left(\sum_{i=1}^{n} X_i\right)^2}{n} \right) \qquad \text{ou}$$

$$SQReg = \hat{\beta}_1 \left(\sum_{i=1}^{n} X_i Y_i - \frac{\left(\sum_{i=1}^{n} X_i\right)\left(\sum_{i=1}^{n} Y_i\right)}{n} \right)$$

- Soma de Quadrados do Resíduo (SQRes)

$$SQRes = SQTot - SQReg$$

As hipóteses estatísticas testadas pelo teste F

$$\begin{cases} H_0 : \beta_1 = 0 \\ H_1 : \beta_1 \neq 0 \end{cases}$$

Se o valor de F calculado for menor do que o valor tabelado obtido em uma tabela de F a um determinado nível de probabilidade α com (1; n – 2) graus de liberdade, não se rejeita H_0.

Em termos práticos, se F calculado > F tabelado, então a regressão existe, ou seja, variações ocorridas em Y podem ser explicadas pelas variações ocorridas em X de acordo com a equação ajustada em um nível α de significância.

⇒ Medidas de precisão da equação ajustada:

- Coeficiente de Determinação (R^2): Informa a percentagem da variação dos dados observados em torno da média que está sendo explicada pela equação ajustada.

$$R^2(\%) = \frac{SQReg}{SQTot}100 \quad \Rightarrow \quad 0 < R^2 \leq 100$$

- Erro Padrão da Estimativa ($S_{y.x}$): Indica o erro médio absoluto cometido, na unidade original da variável, associado ao uso da equação.

$$S_{y.x} = \pm\sqrt{QMRes}$$

- Erro Padrão Relativo ($S_{y.x\ (\%)}$): Diferente do erro padrão da estimativa, o erro padrão relativo indica o erro médio relativo da variável associado ao uso da equação.

$$S_{y.x}(\%) = \pm\frac{S_{y.x}}{\overline{\overline{Y}}}100$$

5.1.2 - Regressão linear múltipla

O modelo de regressão linear múltipla:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + ... + \beta_k X_{ni} + \varepsilon_i$$

No estudo dos modelos de **regressão linear simples** pôde-se observar que o que caracteriza este tipo de modelo é a **existência de apenas uma variável independente X**. Para os modelos de **regressão linear múltipla**, pode-se considerar **mais de uma variável independente X**.

Representação matricial do modelo:

$$Y = X\beta + \varepsilon$$

$$\begin{vmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{vmatrix} = \begin{vmatrix} 1 & X_{11} & X_{21} & \cdots & X_{k1} \\ 1 & X_{12} & X_{22} & \cdots & X_{k2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & X_{1n} & X_{2n} & \cdots & X_{kn} \end{vmatrix} \begin{vmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{vmatrix} + \begin{vmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{vmatrix}$$

Em que:

Y = vetor dos valores observados para Y;
X = matriz dos valores observados ou fixados para as X_i variáveis independentes;
β = vetor dos parâmetros do modelo;
ε = vetor dos erros aleatórios.

$$Y = X\beta + \varepsilon \qquad \textbf{(11)}$$

$$\varepsilon = Y - X\beta \qquad \textbf{(12)}$$

Sabendo-se, contudo, que a soma dos desvios em relação a um valor médio é nula, tem-se que:

$$\varepsilon'\varepsilon = (Y - X\beta)'(Y - X\beta) \qquad \textbf{(13)}$$

Derivando a matriz de erros ($\varepsilon'\varepsilon$) em relação a β, tem-se:

$$\frac{\partial(\varepsilon'\varepsilon)}{\partial\beta} = (X'X)\hat{\beta} - X'Y = 0 \Rightarrow (X'X)\hat{\beta} = X'Y \qquad \textbf{(14)}$$

Pré-multiplicando ambos os lados da expressão **(14)** por $(X'X)^{-1}$, tem-se:

$$(X'X)^{-1}(X'X)\hat{\beta} = (X'X)^{-1}X'Y \Rightarrow \boxed{\hat{\beta} = (X'X)^{-1}X'Y}$$

ANÁLISE DE VARIÂNCIA DA REGRESSÃO (ANOVA)

FV	GL	SQ	QM	FCalc.
Regressão	p	$\hat{\beta}'X'Y - C$	SQReg/GLReg (V_1)	V_1/V_2
Resíduo	$n - p - 1$	$Y'Y - \hat{\beta}'X'Y$	SQRes/GLRes (V_2)	
Total	$n - 1$	$Y'Y - C$		

$$\boxed{F_{tab}(\alpha\ \%;\ p\ \ e\ \ n-p-1\ gl)}$$

As hipóteses estatísticas testadas pelo teste F

$$\begin{cases} H_0 : \beta_i = 0 \\ H_1 : \beta_i \neq 0 \end{cases}$$

Se o valor de F calculado for menor do que o valor tabelado obtido em uma tabela de F a um determinado nível de probabilidade α com (p; n – p – 1) graus de liberdade, não se rejeita H_0.

Uma vez efetuada a análise de variância, todas as medidas de precisão apresentadas no item anterior podem ser calculadas e interpretadas aqui da mesma maneira. Entre elas, tem-se: o Coeficiente de Determinação (R^2), o Erro Padrão da Estimativa ($S_{y.x}$) e o Erro Padrão Relativo ($S_{y.x\ (\%)}$).

5.2 – Tabelas e equações de volume

De acordo com FINGER (1992), a tabela de volume pode ser definida como uma relação gráfica ou numérica expressa por diversos tipos de equações sendo capaz de exprimir o volume total ou parcial de uma árvore em função de variáveis independentes como o diâmetro, altura, fator de forma etc.

5.2.1 – Tabela de volume local

✓ Neste tipo de tabela o volume é função apenas de uma variável independente, normalmente o **diâmetro,** que em geral coincide com o DAP.

- ✓Aplica-se a pequenas áreas florestais em que haja alta correlação entre o diâmetro e a altura.

- ✓Aplica-se também em situações em que é difícil de se medir a altura, como é o caso de algumas florestas da região amazônica, procurando-se, então, obter o volume em função apenas do diâmetro.

- ✓Em geral, tem uso reduzido no meio florestal, dado que é difícil encontrar povoamentos florestais em que apenas uma variável, no caso o diâmetro, possa explicar as variações ocorridas no volume.

Tabela de volume local $\Rightarrow$ $v = f(d)$

Autor	Modelo
Kopezy – Gehrhardt	$v = \beta_o + \beta_1 d^2 + \varepsilon$
Dissescu – Meyer	$v = \beta_1 d + \beta_2 d^2 + \varepsilon$
Hohenald – Krernm	$v = \beta_o + \beta_1 d + \beta_2 d^2 + \varepsilon$
Husch	$\ln(v) = \beta_o + \beta_1 \log(d) + \varepsilon$
Brenac	$\ln(v) = \beta_o + \beta_1 \ln(d) + \beta_2 (1/d) + \varepsilon$

Fonte: Loestsch et al. (1973)

5.2.2 - Tabela de volume regional

- ✓ Neste tipo de tabela, o diâmetro não está tão fortemente correlacionado com a altura.

- ✓ Deste modo, este tipo de tabela leva em consideração as variáveis independentes **diâmetro** e **altura** para explicar as variações de volume ocorridas em um determinado povoamento florestal.

- ✓ Sendo assim, esta tabela pode ter um uso mais abrangente do que a tabela de volume local, sendo, portanto, normalmente mais empregada no meio florestal.

Tabela de volume regional $\Rightarrow$ $v = f(d, h)$

Autor	Modelo
Schumacher & Hall	$v = \beta_0 d^{\beta_1} h^{\beta_2} \varepsilon$
Schumacher & Hall	$\ln(v) = \ln(\beta_o) + \beta_1 \ln(d) + \beta_2 \ln(h) + \ln(\varepsilon)$
Spurr (1952)	$v = \beta_1 d^2 h + \varepsilon$
Spurr (1952)	$v = \beta_o + \beta_1 d^2 h + \varepsilon$
Meyer	$v = \beta_o + \beta_1 d + \beta_2 d^2 + \beta_3 dh + \beta_4 d^2 h + \varepsilon$
Ogaya	$v = d^2 (\beta_o + \beta_1 h) + \varepsilon$
Takata	$v = d^2 h / (\beta_o + \beta_1 h) + \varepsilon$

Fonte: Loestsch et al. (1973)

Exemplo de aplicação: (Soares et al., 2007)

Árv	d (cm)	h (m)	v (m^3)	$d^2h = X$	X^2	XY	Y^2
1	8,0	9,7	0,0274	620,8	385392,6	17,0	0,0008
2	27,7	27,6	0,7159	21177,2	448473969,3	15160,8	0,5125
3	23,2	26,5	0,5505	14263,4	203443438,5	7852,0	0,3031
4	17,7	17,4	0,1780	5451,2	29716083,0	970,3	0,0317
5	13,8	12,9	0,1003	2456,7	6035257,0	246,4	0,0101
6	17,0	16,5	0,1852	4768,5	22738592,3	883,1	0,0343
7	18,8	20,3	0,2423	7174,8	51478214,2	1738,5	0,0587
8	8,0	11,6	0,0327	742,4	551157,8	24,3	0,0011
9	15,0	16,7	0,1292	3757,5	14118806,3	485,5	0,0167
10	21,6	21,2	0,3542	9891,1	97833305,3	3503,4	0,1255
11	11,0	12,8	0,0608	1548,8	2398781,4	94,2	0,0037
12	24,2	24,7	0,4368	14465,3	209245135,5	6318,4	0,1908
Soma			**3,0133**	**86317,7**	**1086418133,1**	**37293,8**	**1,2888**

Exemplo de ajuste do modelo de Spurr (1952)

$$v = \beta_0 + \beta_1 \left(d^2 h\right) + \varepsilon$$

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^{n} X_i Y_i - \frac{\sum_{i=1}^{n} X_i \sum_{i=1}^{n} Y_i}{n}}{\sum_{i=1}^{n} X_i^2 - \frac{\left(\sum_{i=1}^{n} X_i\right)^2}{n}}$$

$$\hat{\beta}_1 = \frac{37293{,}8 - \frac{(86317{,}7)(3{,}0133)}{12}}{1086418133{,}1 - \frac{(86317{,}7)^2}{12}} = 0{,}0000336$$

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

$$\hat{\beta}_0 = 0{,}2511 - 0{,}0000336(7193{,}1) = 0{,}0097719$$

$$\hat{v} = 0{,}0097719 + 0{,}0000336\left(d^2h\right)$$

ANÁLISE DE VARIÂNCIA DA REGRESSÃO (ANOVA)

FV	GL	SQ	QM	FCalc
Regressão	1	0,52402	0,52402	645,86**
Resíduo	10	0,00811	0,00081	
Total	11	0,53214		

$$\boxed{F_{tab}(1\ \%;\ 1\ \text{ e } 10\ \text{ gl}) = 10{,}04}$$

O teste F e as medidas de precisão da equação ajustada

- O teste F:

<u>Interpretação</u>: De acordo com este teste, rejeita-se H_0, isto é, as variações ocorridas no volume podem ser explicadas pela variável combinada d^2h, em nível de 1% de probabilidade.

- Coeficiente de Determinação (R^2):

$$R^2(\%) = \frac{0{,}52402}{0{,}53214}100 = 98{,}47$$

<u>Interpretação</u>: A equação ajustada explica 98,47% das variações ocorridas no volume.

- Erro padrão das estimativa ($S_{y.x}$):

$$S_{y.x} = \pm \sqrt{QM\,Resíduo} = \pm \sqrt{0{,}00081} = \pm 0{,}02846\ m^3$$

Interpretação: o erro médio associado ao uso da equação ajustada é de ± 0,02846 m^3.

- Erro padrão relativo($S_{y.x}$(%)):

$$S_{y.x}(\%) = \pm \frac{0{,}02846}{0{,}25111} 100 = \pm 11{,}33$$

Interpretação: o erro médio associado ao uso da equação ajustada é de ± 11,33%.

Exemplo de ajuste do modelo de Schumacher e Hall

$$v = \beta_0 d^{\beta_1} h^{\beta_2} \varepsilon$$

$$\ln(v) = \ln(\beta_o) + \beta_1 \ln(d) + \beta_2 \ln(h) + \ln(\varepsilon)$$

Fazendo $Y = \ln(v)$; $X_1 = \ln(d)$; $X_2 = \ln(h)$, vem:

$$Y = \alpha_0 + \beta_1 X_1 + \beta_2 X_2 + \delta$$

$$\Downarrow$$

Modelo de regressão linear múltipla

Para ajustar o modelo de Schumacher e Hall linearizado tomemos como base os dados de Soares et al. (2007)

Árv	d (cm)	h (m)	v (m^3)	ln(d) (X_1)	ln(h) (X_2)	ln (v) (Y)
1	8,0	9,7	0,0274	2,07944154	2,27212589	-3,59721227
2	27,7	27,6	0,7159	3,32143241	3,31781577	-0,33421479
3	23,2	26,5	0,5505	3,14415228	3,27714473	-0,59692832
4	17,7	17,4	0,1780	2,87356464	2,85647021	-1,72597173
5	13,8	12,9	0,1003	2,62466859	2,55722731	-2,29958958
6	17,0	16,5	0,1852	2,83321334	2,80336038	-1,68631896
7	18,8	20,3	0,2423	2,93385687	3,01062089	-1,41757865
8	8,0	11,6	0,0327	2,07944154	2,45100510	-3,42038020
9	15,0	16,7	0,1292	2,70805020	2,81540872	-2,04639369
10	21,6	21,2	0,3542	3,07269331	3,05400118	-1,03789355
11	11,0	12,8	0,0608	2,39789527	2,54944517	-2,80016549
12	24,2	24,7	0,4368	3,18635263	3,20680324	-0,82827985
Soma				**33,25476264**	**34,17142859**	**-21,79092708**

Árv	X_1^2	X_2^2	$X_1 X_2$	$X_1 Y$	$X_2 Y$
1	4,32407713	5,16255604	4,72475295	-7,48019262	-8,17331910
2	11,03191328	11,00790150	11,01990085	-1,11007183	-1,10886309
3	9,88569355	10,73967760	10,30384208	-1,87683355	-1,95622051
4	8,25737374	8,15942204	8,20825178	-4,95969133	-4,93018682
5	6,88888522	6,53941152	6,71187421	-6,03566056	-5,88057329
6	8,02709785	7,85882943	7,94251804	-4,77770137	-4,72735975
7	8,60751613	9,06383812	8,83273077	-4,15897286	-4,26779189
8	4,32407713	6,00742599	5,09672182	-7,11248068	-8,38336931
9	7,33353589	7,92652626	7,62426815	-5,54173684	-5,76143463
10	9,44144421	9,32692322	9,38400901	-3,18912858	-3,16972814
11	5,74990174	6,49967068	6,11330252	-6,71450359	-7,13886839
12	10,15284310	10,28358704	10,21800596	-2,63919170	-2,65613052
Soma	**94,02435883**	**98,57576943**	**96,18017807**	**-55,59616551**	**-58,15384545**

$$\hat{\beta} = (X'X)^{-1}X'Y$$

$$\hat{\beta} = \begin{bmatrix} \hat{\alpha}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} \qquad (X'X) = \begin{bmatrix} n & \sum_{i=1}^{n} X_1 & \sum_{i=1}^{n} X_2 \\ \sum_{i=1}^{n} X_1 & \sum_{i=1}^{n} X_1^2 & \sum_{i=1}^{n} X_1 X_2 \\ \sum_{i=1}^{n} X_2 & \sum_{i=1}^{n} X_2 X_1 & \sum_{i=1}^{n} X_2^2 \end{bmatrix} \qquad X'Y = \begin{bmatrix} \sum_{i=1}^{n} Y \\ \sum_{i=1}^{n} X_1 Y \\ \sum_{i=1}^{n} X_2 Y \end{bmatrix}$$

As matrizes do sistema de equações ficaram assim definidas:

$$\hat{\beta} = \begin{bmatrix} 12 & 33{,}25476264 & 34{,}17142859 \\ 33{,}25476264 & 94{,}02435883 & 96{,}18017807 \\ 34{,}17142859 & 96{,}18017807 & 98{,}57576944 \end{bmatrix}^{-1} \begin{bmatrix} -21{,}79092708 \\ -55{,}5961655 \\ -58{,}15384545 \end{bmatrix}$$

Procedendo-se a inversão da matriz (X'X) e a multiplicação pelo vetor X'Y, obtém-se as seguintes estimativas para os parâmetros do modelo:

$$\hat{\beta} = \begin{bmatrix} -9{,}590713385 \\ +1{,}748280173 \\ +1{,}028900248 \end{bmatrix} = \begin{bmatrix} \hat{\alpha}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix}$$

Lembrando que $\hat{\alpha}_0 = \ln\left(\hat{\beta}_0\right)$, desta forma, a equação de volume fica assim definida:

$$\boxed{\widehat{\ln(v)} = -9{,}59071 + 1{,}74828 \ln(d) + 1{,}02890 \ln(h)}$$

$$SQTotal = \sum Y^2 - \frac{\left(\sum Y\right)^2}{n} = 52,0191757 - 39,57037525 = 12,44880045$$

$$SQreg = \begin{bmatrix} -9,590713358 & 1,748280173 & 1,028900248 \end{bmatrix} \begin{bmatrix} -21,79092708 \\ -55,5961655 \\ -58,15384545 \end{bmatrix} - 39,57037526 = 12,38798032$$

$$SQ\,Res = SQTotal - SQ\,Reg = 0,06082015$$

FV	GL	SQ	QM	Fcalc
Regressão	2	12,38798032	6,193990162	916,57*
Resíduo	9	0,06082015	0,006757794	
Total	11	12,44880047		

$$F_{tab}(5\%\ ,2\ \text{e}\ 9\ gl) = 4,26$$

O teste F e as medidas de precisão da equação ajustada

- O teste F:

<u>Interpretação</u>: De acordo com este teste, rejeita-se H_0, isto é, as variações ocorridas no ln(v) podem ser explicadas por pelo menos uma das variáveis ln(d) e ln(h), em nível de 5% de probabilidade.

- Coeficiente de Determinação (R^2):

$$R^2(\%) = \frac{12{,}38798032}{12{,}44880045} 100 = 99{,}51\%$$

<u>Interpretação</u>: A equação ajustada explica 99,51% das variações ocorridas no ln(v). ⇨ **<u>Problema!!!</u>**

- Erro padrão das estimativa ($S_{y.x}$):

$$S_{y.x} = \pm\sqrt{QMResíduo} = \pm\sqrt{0{,}006757794} = \pm 0{,}082206\,\ln(m^3)$$

Interpretação: o erro médio associado ao uso da equação ajustada é de **± 0,082206 ln(m³)** ⇨ **Problema!!!**

- Erro padrão relativo($S_{y.x}(\%)$):

$$S_{y.x}(\%) = \pm\frac{0{,}082206}{-1{,}815911}100 = \pm 4{,}53\%$$

Interpretação: o erro médio associado ao uso da equação ajustada é de ± 4,53%.

FIM

Referências

FINGER, C. A. G. Fundamentos de biometria florestal. Santa Maria: UFSM, 1992. 269p.

LOETSCH, F.; ZOEHRER, F.; HALLER, K. E. Forest Inventory. v.2, Munchen: BLV, 1973. 469p.

SOARES, C. P. B.; NETO, F. P.; SOUZA, A. L. Dendrometria e Inventário Florestal. Viçosa: Editora UFV, 2007. 276p.