



UNIVERSIDADE FEDERAL DO PARANÁ  
SETOR DE CIÊNCIAS EXATAS  
DEPARTAMENTO DE ESTATÍSTICA  
CURSO DE ESTATÍSTICA

**Janaina dos Santos**  
**Raul Valdera Junior**

**UM ESTUDO APLICADO DE MODELOS NÃO LINEARES A  
REDUÇÃO DE ADSTRINGÊNCIA DE CAQUI**

**CURITIBA**  
**2013**

**Janaina dos Santos  
Raul Valdera Junior**

**UM ESTUDO APLICADO DE MODELOS NÃO LINEARES A  
REDUÇÃO DE ADSTRINGÊNCIA DE CAQUI**

Trabalho de Conclusão de Curso apresentado à disciplina Laboratório de Estatística do Curso de Graduação em Estatística da Universidade Federal do Paraná, como exigência parcial para obtenção do grau de Bacharel em Estatística.

Orientador: Prof. Dr. Walmes Marques Zeviani

**CURITIBA  
2013**

## **AGRADECIMENTOS – JANAINA DOS SANTOS**

Agradeço primeiramente a Deus por iluminar e abençoar meu caminho.

Aos meus pais, Joaquim e Maria Lucia, por tudo que fizeram e fazem por mim, inclusive me buscar na universidade todos os dias, pelo carinho, apoio, compreensão e ensinamentos que servirão para a vida toda.

Aos meus irmãos e seus respectivos cônjuges, por toda força. Também aos meus sobrinhos, Samuel e Maria Eduarda, apesar de tão pequeno ainda, me ajudaram a ter momentos alegres mesmo nos mais complicados.

Ao meu namorado, Paulo, por toda paciência, apoio e compreensão.

Aos amigos, nestes anos de graduação, pela motivação e amizade.

A minha vó e demais familiares pela confiança depositada em mim.

Ao nosso orientador professor Dr. Walmes Marques Zeviani, por toda paciência e ensinamentos transmitidos.

A mestrandia Jessica Welinski, por conceder o banco de dados.

Ao professor Dr. Jomar Antonio Camarinha Filho por aceitar o nosso convite a participar da banca deste trabalho.

Obrigada a todos que contribuíram para a conclusão desta etapa, mesmo não estando citados aqui.

## **AGRADECIMENTOS – RAUL VALDERA JUNIOR**

Primeiramente a Deus pelo dom da vida, pois sem Ele eu nada seria.

Aos meus pais, Raul e Claudete, meus maiores exemplos, pela educação que me foi dada e pelo apoio mesmo diante dos momentos mais difíceis.

A minha noiva Suelen, pela paciência, apoio e compreensão durante todo o decorrer do curso.

Ao meu irmão, João Eduardo, pelo apoio e compreensão.

Ao nosso orientador Professor Dr. Walmes Marques Zeviani, pelos ensinamentos compartilhados, a paciência e incentivo que tornaram possível a conclusão deste trabalho.

A minha dupla, Janaina, pela paciência e trabalho em equipe durante os últimos meses.

Aos nossos amigos, pelo companheirismo, incentivo e apoio nos bons e maus momentos.

A mestranda Jessica Welinski, pelo auxílio e por nos ceder os dados utilizados neste trabalho.

Ao Professor Dr. Jomar Antonio Camarinha Filho, pela disponibilidade em participar da banca deste trabalho.

A todos que, mesmo não estando citados aqui, também contribuíram para a conclusão desta etapa e para a formação da pessoa que sou hoje.

“A verdadeira viagem de descobrimento não consiste em procurar novas paisagens, mas em ter novos olhos”.

Marcel Proust

## RESUMO

### Um Estudo Aplicado de Modelos Não Lineares a Redução de Adstringência de Caqui

O caqui (*Diospyros kaki* L.), na maioria de suas variedades, antes do consumo necessita passar por um processo de redução de adstringência, no qual transformam-se com o tempo de armazenamento, através de uma reação química, de taninos solúveis para insolúveis. Para tanto, o método de exposição ao álcool etílico acondicionado ou não a uma temperatura de 5°C, foi utilizado. Nota-se, então, que a relação do conteúdo de tanino e o tempo de armazenamento é não linear decrescente. Percebe-se também, que a variância diminuiu ao longo do período de armazenamento junto com a média, tornando inválida / não verificada a suposição de variâncias homogêneas. Caso esta suposição seja negligenciada, as inferências podem não representar de maneira adequada o comportamento do conteúdo de tanino. Tendo como objetivo estabelecer um modelo que estime essa redução com base nos fatores descritos, ajustaram-se modelos não lineares que levam em consideração tanto a modelagem da média quanto variância. Desta maneira, verificou-se que dentre os modelos ajustados, os que consideraram variância heterogênea, de fato, apresentaram melhores medidas de ajuste. Quando estes modelos foram comparados entre si, constatou-se que, quando foi possível o ajuste, o modelo considerando decaimento potência para média e potência para variância apresentou melhor qualidade de ajuste.

**Palavras-chave:** Caqui. Adstringência. Modelo Não Linear. Variância Heterogênea.

## LISTA DE FIGURAS

|  |    |
|--|----|
| Figura 1 – Valores observados e curva ajustada. Segmentos de reta verticais ligando observações à curva representam os resíduos.....   | 7  |
| Figura 2 – Valores observados do conteúdo de tanino em função dos dias após exposição ao álcool. Segmentos de reta unem as médias amostrais. Nas tarjas os sufixos s e n indicam exposição ao resfriamento ou não e os prefixos 12h, 24h, 36h e 48h indicam o tempo de exposição ao tratamento ..... | 11 |
| Figura 3 – Esquema da combinação entre modelos para média e variância. ....  | 12 |
| Figura 4 – Média amostral em função da variância amostral. ....  | 16 |
| Figura 5 – Valores para log-verossimilhanças dos modelos ajustados divididos por caselas. Barras indicam modelos para média e as cores das barras indicam os modelos de variância para cada média.....   | 17 |
| Figura 6 – Intervalos de confiança para os parâmetros .....  | 18 |
| Figura 7 – Valores preditos pelos modelos ajustados.....   | 20 |
| Figura 8 – Quantis observados dos resíduos padronizados em função dos quantis teóricos de uma variável aleatória normal padrão segmentados por casela.....   | 21 |
| Figura 9 – Resíduos padronizados em função dos valores preditos.....   | 22 |
| Figura 10 – Bandas de confiança para os ajustes referentes à casela 12h.N.....   | 23 |

## SUMÁRIO

|  |    |
|--|----|
| <b>1 INTRODUÇÃO</b> .....                          | 1  |
| <b>2 REVISÃO DE LITERATURA</b> .....               | 2  |
| 2.1 CAQUI .....                                    | 2  |
| 2.2 ADSTRINGÊNCIA .....                            | 2  |
| 2.3 REGRESSÃO NÃO LINEAR: CONCEITOS INICIAIS ..... | 3  |
| 2.3.1 Variância Heterogênea .....                  | 5  |
| 2.4 ESTIMAÇÃO .....                                | 6  |
| 2.5 ANÁLISE DE RESÍDUOS .....                      | 7  |
| 2.6 INTERVALOS DE CONFIANÇA .....                  | 8  |
| <b>3 MATERIAL E MÉTODOS</b> .....                  | 9  |
| 3.1 MATERIAL .....                                 | 9  |
| 3.1.1 Conjunto de Dados .....                      | 9  |
| 3.1.2 Recursos Computacionais .....                | 9  |
| 3.2 MÉTODOS .....                                  | 9  |
| 3.2.1 Especificação dos Modelos .....              | 9  |
| 3.2.2 Medidas para Avaliação dos Modelos .....     | 13 |
| <b>4 RESULTADOS E DISCUSSÃO</b> .....              | 15 |
| 4.1 ANÁLISE EXPLORATÓRIA .....                     | 15 |
| <b>5 CONCLUSÃO</b> .....                           | 24 |
| <b>REFERÊNCIAS</b> .....                           | 25 |
| <b>ANEXOS</b> .....                                | 27 |



## 1 INTRODUÇÃO

A produção de caqui no Brasil é essencialmente para consumo *in natura*. No entanto, um dos principais problemas após a colheita do fruto é que o mesmo possui uma substância adstringente que “amarra a boca”, quando consumido não completamente maduro, chamada tanino. Para que isso não aconteça, faz-se necessário que essa substância se reduza de maneira mais rápida, mantendo a durabilidade e a qualidade do fruto, através, neste caso, do tratamento com vapor de álcool etílico e a exposição, ou não, ao resfriamento.

O conteúdo de tanino decresce de forma não linear com o tempo sugerindo, então, o ajuste de modelos que descrevam o conteúdo de tanino como função do tempo, utilizando uma abordagem de regressão não linear. Tais modelos preferencialmente se apoiam (ou representam) tal relação por meio de parâmetros com interpretação biológica, não sendo estritamente teóricos, como ocorre na modelagem baseada em regressão linear, por exemplo.

Não raramente, em curvas de crescimento, acúmulo e liberação, tipicamente descritas por modelos não lineares, apresentam também uma relação não nula entre média e variância, podendo assim ser analisada a possibilidade da modelagem conjunta entre média e variância, assumindo como pressuposto de que esta variância não é constante (heterogênea).

Ao considerar a suposição de variância homogênea, em casos como este, se não for atendida, pode levar ao comprometimento/invalidação das inferências a serem obtidas, bem como as conclusões baseadas nas mesmas.

Assim, o presente estudo tem por objetivo propor e avaliar modelos não lineares para a média do conteúdo de tanino em função do período de armazenamento, considerando a relação não nula entre a média e a variância. E portanto corroborar, por meio de medidas usuais de qualidade de ajuste, a real necessidade deste tipo de modelagem.

## 2 REVISÃO DE LITERATURA

### 2.1 CAQUI

Originário da Ásia, o caqui pertence à família botânica Ebenaceae. Segundo Brackmann (2003), a *Diospyros kaki* (caquizeiro), é a espécie que apresenta a maior importância econômica do gênero *Diospyros*. Essa espécie foi introduzida no Brasil a partir da década de 1890, nas regiões Sul e Sudeste, pelos imigrantes asiáticos.

Este fruto caracteriza-se por ser uma baga com forma e tamanho bastante variável entre as cultivares, podendo ser de forma arredondada até quase quadrangular e globoso até achatado (BIASI, 2009). A massa deste fruto, em cultivares de frutos grandes, pode atingir cerca de 500g, mas normalmente os frutos possuem de 250 a 350g (BIASI, 2009).

As cultivares de caqui comercializadas no Brasil, podem ser classificadas em três categorias com relação à adstringência e cor da polpa: “Shibugaki” – apresentam frutos com polpa sempre taninosa (adstringente) e de cor amarela, independente da presença ou não de sementes; “Amagaki” – a polpa dos frutos é amarela e não apresenta tanino, contendo ou não sementes; “Variável” – frutos destas cultivares, quando oriundos de flores não polinizadas e, por isso, sem sementes, apresentam polpa amarela e rica em taninos, necessitando de destanização (BRACKMANN, 2003).

Com base nessa classificação, este estudo foi realizado com o caqui da cultivar Kakimel, pertencente ao grupo “Shibugaki”.

### 2.2 ADSTRINGÊNCIA

Um dos maiores problemas após a colheita do fruto é a remoção da sua adstringência, pois este componente é o que “amarra a boca” quando consumido não completamente maduro.

Essa adstringência deve-se à presença de uma substância chamada de tanino. Estes, por sua vez, segundo EDAGI e KLUGE (2009), são classificados como galotaninos, elagitaninos (taninos hidrolisáveis) e os taninos condensados (não hidrolisáveis), formados por polímeros de proantocianidinas. Existem também os

“não-classificados” que são conhecidos como taninos complexos ou flavoelagitanino.

Para o presente estudo, foram analisados os taninos galotaninos, que são polímeros de ácido gálico encontrados em diversas frutas como o caqui e a banana (EDAGI e KLUGE, 2009).

Com o intuito de reduzir a adstringência no fruto, um dos principais tratamentos utilizados é a aplicação de álcool etílico, condicionado ao armazenamento do mesmo em câmaras BOD (*Biochemical Oxygen Demand*), sendo estas câmaras que propiciam o controle da temperatura e níveis de evaporação do etanol, caso contrário, poderá acelerar o amolecimento da polpa. Ao aplicar estes tratamentos os níveis de taninos solúveis decrescem consideravelmente, alcançando níveis imperceptíveis para o consumo humano (ITTAH, 1993).

O presente estudo tem a intenção de contribuir para melhor conhecimento do assunto, com enfoque analítico na relação tanino-tempo, descritos na Seção 3.

## 2.3 REGRESSÃO NÃO LINEAR: CONCEITOS INICIAIS

Uma das situações mais comuns na análise estatística é a de dados que consistem em respostas observadas  $y_i$  conhecidas por serem dependentes de suas  $k$ -dimensional variáveis  $x_i$  (GALLANT, 1975). Como por exemplo:

$$Y_i = \beta_0 + \beta_1 x_i + e_i. \quad (1)$$

Generalizando, pode-se escrever os modelos lineares da seguinte forma:

$$f(x, \beta) = x' \beta = \beta_0 + \sum_{i=1}^p x_i \beta_i \quad (2)$$

podendo ser linear se as derivadas em relação aos parâmetros da função (1), não dependem de nenhum parâmetro  $\beta_i$ , por exemplo:

$$\begin{aligned} \partial(\beta_0 + \beta_1 x_i) / \partial \beta_0 &= 1 \\ \partial(\beta_0 + \beta_1 x_i) / \partial \beta_1 &= x_i. \end{aligned} \quad (3)$$

Um modelo é não linear se ao menos uma das derivadas da função de média com os respectivos parâmetros depender de pelo menos um desses parâmetros (SCHABENBERGER e PIERCE, 2002). Por exemplo, o modelo:

$$Y_i = \beta_0 (1 + e^{\beta_1 x_i}) + e_i \quad (4)$$

é não linear pois as derivadas,

$$\begin{aligned} \partial(\beta_0(1 + e^{\beta_1 x_i})) / \partial \beta_0 &= 1 + e^{\beta_1 x_i} \\ \partial(\beta_0(1 + e^{\beta_1 x_i})) / \partial \beta_1 &= \beta_0 x_i e^{\beta_1 x_i} \end{aligned} \quad (5)$$

dependem de pelo menos um dos parâmetros do modelo.

Pode-se dizer, no entanto, que a ideia entre modelos lineares e não lineares é semelhante, visto que em ambos o modelo é construído a fim de explicar uma variável resposta ( $y$ ) por meio de uma função que envolve parâmetros e covariáveis.

Algumas transformações podem ser realizadas na tentativa de tornar linear a relação entre duas variáveis (GALLANT, 1975). Todavia, linearidade refere-se à relação linear dos parâmetros, não com as covariáveis ( $x_i$ ). Transformações das covariáveis como  $e^x$ ,  $\ln(x)$ ,  $1/x$  e  $\sqrt{x}$ , por exemplo, não mudam a forma linear do modelo, embora irão afetar o grau da curvatura visto no diagrama de dispersão de  $y$  como função de  $x$ . No caso dos modelos polinomiais, apesar de suas covariáveis serem elevadas à potências crescentes, sua relação ainda é linear (SCHABENBERGER e PIERCE, 2002), pois as derivadas das funções em relação aos seus respectivos parâmetros, dependem apenas das covariáveis.

Ao utilizar uma tentativa de linearização de um modelo não linear, na prática, busca-se uma forma menos complexa de se estimar os parâmetros. O inconveniente de tais transformações, entretanto, é que além dos parâmetros perderem sua interpretação intrínseca, pode-se alterar a estrutura e a distribuição do erro ( $e_i$ ), ou seja, se os erros do modelo original satisfizerem as suposições usuais de normalidade, independência e homogeneidade da variância, os erros do modelo, em geral, não satisfarão tais suposições (KHURI e CORNELL, 1987). Caso não seja possível obter uma reparametrização, que será abordada na Seção 3, ou uma transformação apropriada que reduza o modelo a forma linear, tem-se os chamados modelos “intrinsecamente não lineares” (MAZUCHELI e ACHCAR, 2002).

Modelos de regressão não linear são utilizados quando há algum conhecimento preliminar sobre a relação entre variáveis existentes (ZEVIANI, 2013). Como exemplo da área biológica, processos de crescimento, decaimento, nascimento, mortalidade e desenvolvimento, raramente são relacionados linearmente às variáveis explicativas.

Além desta vantagem, pelo fato dos modelos não lineares terem normalmente

uma clara interpretação dos parâmetros, eles podem ser utilizados mesmo quando uma aproximação linear se ajusta bem (SEBER e WILD, 1989), induzindo a modelos mais parcimoniosos. Tais ajustes, também proporcionam valores preditos mais realistas para variável resposta mesmo que esta esteja fora do domínio observado (PINHEIRO e BATES, 2000).

Por outro lado, os parâmetros dos modelos não lineares são estimados de forma iterativa na qual são exigidos os valores iniciais, diferentemente dos lineares que são ajustados de forma mais simples e a estimação é direta (SEBER e WILD, 1989).

### 2.3.1 Variância Heterogênea

De maneira geral, regressão não linear assume que a dispersão (desvio-padrão dos resíduos) é a mesma ao longo de toda a curva, sendo este pressuposto de variância uniforme chamado de homocedasticidade (MOTULSKY e CHRISTOPOULOS, 2004). Esta, como outras pressuposições do modelo necessitam ser satisfeitas para validação do modelo, como por exemplo: a) a esperança da função estar correta; b) a resposta ser a função esperança mais erro aleatório; c) o desvio-padrão ser constante (sem relação com a média); d) os erros aleatórios ter distribuição normal com média zero e variância  $\sigma^2$ ; e) os erros aleatórios são identicamente distribuídos (BATES e WATTS, 1988). Caso a suposição de variância constante não seja válida, diz-se que a mesma é heterogênea.

É preciso escolher uma função de variância para representar a relação da variância com a média ou outra variável. Em alguns casos, essa escolha pode ser feita com embasamento teórico. Frequentemente, todavia, têm-se apenas indicações qualitativas sendo a de que a variância das observações cresce de acordo com sua esperança, ou a relação entre a variância e sua esperança pode ser retratada por uma parábola, por exemplo. Em ambos os casos, a escolha do modelo é baseada nos resíduos dentro de uma coleção restrita de possíveis modelos (HUET, A, *et al.*, 2003).

Assim sendo, ao verificar-se a ocorrência da violação do pressuposto de homogeneidade da variância e mesmo assim conduzir a análise, ignorando essas

características, pode ser extremamente prejudicial, podendo invalidar completamente a análise. Isso se dá ao fato de que a heterogeneidade de variância geralmente não afeta tanto as estimativas de  $\hat{\beta}$ , mas se ignorada pode induzir a intervalos de confiança para os parâmetros fora da cobertura nominal (CARROLL e RUPPERT, 1988).

## 2.4 ESTIMAÇÃO

Inferência em um modelo estatístico envolve estimação e predição bem como associar incerteza à esses valores (estimados e preditos), além de conduzir testes de hipóteses.

A verossimilhança, sendo o principal método de estimação utilizado para os modelos sugeridos à base de dados, que pode ser aplicada para estimar parâmetros de qualquer modelo de distribuição de probabilidades, tanto discretas como contínuas. Neste estudo serão estimados os parâmetros para variável resposta contínua, o conteúdo de tanino solúvel liberado, através dos modelos não lineares sugeridos na seção 3.

Se para a variável resposta for considerada uma distribuição Gaussiana de variância constante, o modelo pode ser escrito da seguinte forma:

$$Y \sim Normal(\mu(x), \sigma^2)$$

sendo o preditor da média escrito por:

$$\mu(x) = f(x, \beta)$$

Porém, se o pressuposto de variância constante não for atendido, a inferência estatística a partir desta especificação de modelo acima se torna viesada. Então, para que se consiga atender os pressupostos citados anteriormente, utiliza-se a seguinte função de log-verossimilhança:

$$\ell(\beta, \varphi) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \sum_{i=1}^n \left\{ \log(\eta_{\sigma^2}(z_i, \varphi)) + \frac{(y_i - \eta_{\mu}(x_i, \beta))^2}{\eta_{\sigma^2}(z_i, \varphi)} \right\}, \quad (6)$$

Onde  $\eta_{\mu}(x_i, \beta)$ , considerado para o modelo de média,  $\eta_{\sigma^2}(z_i, \varphi)$  um modelo para variância, que deve ter contra-domínio positivo, porque a variância é maior que zero, e  $z = x$  ou  $z = \mu$  (ZEVIANI, RIBEIRO JR e BONAT, 2013).

## 2.5 ANÁLISE DE RESÍDUOS

Resíduo, por definição, é a distância de um ponto observado até o valor predito, podendo assumir tanto valores positivos quanto negativos. Ao listar-se os resíduos de uma curva particular em forma de uma tabela, seriam usados os mesmos valores de  $x$  como no banco de dados original, porém os valores da resposta  $y$  seriam as distâncias verticais de cada ponto correspondente para a curva (MOTULSKY e CHRISTOPOULOS, 2004).




FIGURA 1 – VALORES OBSERVADOS E CURVA AJUSTADA. SEGMENTOS DE RETA VERTICAIS LIGANDO OBSERVAÇÕES À CURVA REPRESENTAM OS RESÍDUOS.

Seja um modelo geral dado por:

$$y_i = f(x_i, \beta) + \varepsilon_i \quad (7)$$

onde  $\varepsilon_i$  são os erros associados ao modelo, onde se assume que são independentes e identicamente distribuídos (i.i.d.) seguindo uma distribuição  $Normal(0, \sigma^2)$ . Tem-se então que o  $i$ -ésimo resíduo é então definido por  $\hat{\varepsilon}_i = y_i - f(x_i, \hat{\beta})$ , bem como o vetor de resíduos dado por:

$$\hat{\varepsilon}_i = e_i = y_i - \hat{y}_i = y_i - f(\hat{\beta}) \quad (8)$$

Considerando que os resíduos auxiliam na validação dos pressupostos do modelo, estes se tornam relevantes no processo de diagnóstico. Contudo, como os resíduos brutos podem ser significativamente afetados por valores atípicos,

costuma-se padronizá-los, subtraíndo-se a média dos resíduos de cada resíduo bruto e dividindo-os pelo respectivo desvio-padrão, conforme definido abaixo:

$$e_{pi} = \frac{e_i}{\sigma_{e_i}}, \quad (9)$$

onde  $\sigma_{e_i}$  representa o desvio padrão dos resíduos brutos. Desta forma, os resíduos padronizados tem uma distribuição *Normal*(0, 1), em outras palavras, pode-se dizer que aproximadamente 95% dos mesmos encontram-se no intervalo [-2,2] (WEISBERG, 1980).

## 2.6 INTERVALOS DE CONFIANÇA

De uma maneira geral, em uma análise estatística, a interpretação completa dos resultados, bem como a decisão do que fazer na prática, depende de saber os intervalos de confiança (ou erros padrões) dos parâmetros (MOTULSKY e CHRISTOPOULOS, 2004). Para tanto, no estudo em questão foram utilizados intervalos de confiança por meio de uma aproximação quadrática da função de verossimilhança ao redor de  $\hat{\beta}$ , que são conhecidos como intervalos do tipo Wald.



### 3 MATERIAL E MÉTODOS

#### 3.1 MATERIAL

##### 3.1.1 Conjunto de Dados

Os dados para o estudo em questão foram cedidos pela mestrandia em Agronomia da UFPR Jessica Welinski de Oliveira D'angelo, através do Prof. Dr. Walmes Marques Zeviani do Laboratório de Estatística e Geoinformação, também da UFPR. O delineamento experimental foi inteiramente casualizado, com quatro repetições, seguindo um esquema fatorial 4x2x7, sendo quatro períodos de exposição, em horas, ao vapor do álcool: 12, 24, 36 e 48; duas condições de exposição ao frio (temperatura de 5°C): com ou sem; e sete períodos de armazenamento, em dias: 0, logo após tratamento com álcool, 3, 5, 7, 9 e 11; obtendo-se como variável resposta o conteúdo de tanino solúvel ( $\text{mg g}^{-1}$ ), totalizando 183 observações. O período de colheita dos frutos para observação foi no mês de março de 2012, na cidade de Campina Grande do Sul – PR, 25°18'21" de latitude sul 49°03'18" de longitude oeste, a uma altitude de 918 metros, localizado na região metropolitana de Curitiba, em um cultivar de caqui da variedade Kakimel.

##### 3.1.2 Recursos Computacionais

Para a análise dos dados, foi utilizado como ferramenta de auxílio computacional o software R na sua versão 3.0.1 (R CORE TEAM, 2013). Deste, usou-se basicamente a função `gnls` do pacote NLME para ajuste dos modelos, além de recursos gráficos. Para a tabulação dos dados, fez-se uso do Microsoft Office Excel 2010 (MICROSOFT, 2010).

#### 3.2 MÉTODOS

##### 3.2.1 Especificação dos Modelos

Com o objetivo de avaliar a redução da adstringência dos frutos, fez-se um estudo descritivo para verificar como se comportaram as variáveis. A partir desta, sugeriu-se modelos que tentassem explicar seu comportamento, levando em consideração a tendência central e a dispersão observada em gráficos relacionando as variáveis.

Inicialmente, para a média consideraram-se modelos que remetem a comportamentos biológicos que, ao reparametrizá-los ou adaptá-los, se tornam funções monótonas não crescentes. Foram estes:

- Michaelis-Menten

$$E(Y | x) = f(x) = \frac{\lambda x}{(\kappa + x)} \quad (10)$$

- Decaimento Exponencial:

$$E(Y | x) = f(x) = \beta + \alpha e^{(-\kappa x)} \quad (11)$$

- Potência:

$$E(Y | x) = f(x) = \beta + \alpha(x+1)^\kappa \quad (12)$$

Porém para manter a mesma interpretação dos parâmetros em cada um dos modelos fez-se necessário uma reparametrização dos mesmos, resultando nos modelos abaixo descritos. A demonstração completa das reparametrizações encontra-se no Anexo A.

- Decaimento Quociente:

$$E(y | x) = f(x) = \beta + \frac{\alpha}{\left(1 + \frac{x}{\nu}\right)} \quad (13)$$

- Decaimento Exponencial:

$$E(Y | x) = f(x) = \beta + \alpha e^{\left(-\left(\frac{x \log(2)}{\nu}\right)\right)} \quad (14)$$

- Decaimento Potência:

$$E(Y | x) = f(x) = \beta + \alpha(x+1)^{\left(-\left(\frac{\log(2)}{\log(\nu+1)}\right)\right)} \quad (15)$$

Percebe-se então, que as reparametrizações dos modelos Decaimento Exponencial e Potência não alteraram seu comportamento original.

Com isto, pode-se dizer que a assíntota inferior ( $\beta$ ) é o tanino insolúvel ( $\text{mg g}^{-1}$ ); o tanino solúvel ( $\alpha$ ), também medido em ( $\text{mg g}^{-1}$ ), é o conteúdo passível de solubilização de forma que  $\alpha + \beta$  sejam o intercepto (conteúdo total que existe quando o período de armazenamento é de zero dias) e  $v$  é o tempo de meia vida, ou seja, o tempo médio para o nível de tanino solúvel ( $\text{mg g}^{-1}$ ) reduzir a metade do que se é passível de solubilização.

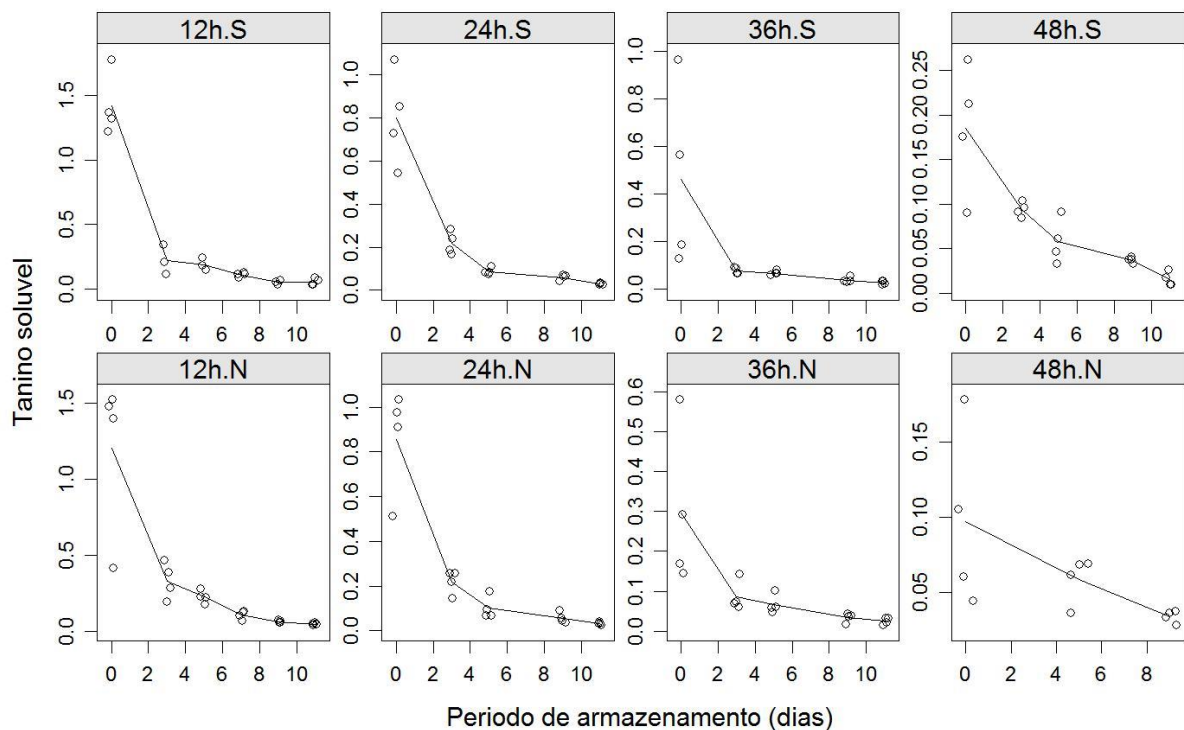


FIGURA 2 – VALORES OBSERVADOS DO CONTEÚDO DE TANINO EM FUNÇÃO DOS DIAS APÓS EXPOSIÇÃO AO ÁLCOOL. SEGMENTOS DE RETA UNEM AS MÉDIAS AMOSTRAIS. NAS TARJAS OS SUFIXOS S E N INDICAM EXPOSIÇÃO AO RESFRIAMENTO OU NÃO E OS PREFIXOS 12H, 24H, 36H E 48H INDICAM O TEMPO DE EXPOSIÇÃO AO TRATAMENTO

Ao observar-se a Figura 2, suspeita-se pela dispersão das observações que a variância pode ser não homogênea. Assim sendo, testaram-se modelos que conjuntamente modelam tanto a média quanto a variância dos níveis de tanino solúvel dos frutos. Para os modelos de variância foram considerados os seguintes:

- Constante:

$$V(Y|z) = g(z) = \sigma^2 \quad (16)$$

- Exponencial:

$$V(Y|z) = g(z) = \sigma^2 e^{2\alpha z} \quad (17)$$

- Potência:

$$V(Y|z) = g(z) = \sigma^2 |z|^{2\delta} \quad (18)$$

Para  $z$  foi considerado a própria média ( $E(Y|x)$ ). O  $\delta$  é o coeficiente da função de variância.

Com os modelos de média e variância definidos, a Figura 3 apresenta uma melhor visualização das combinações dos modelos, por meio de um esquema.

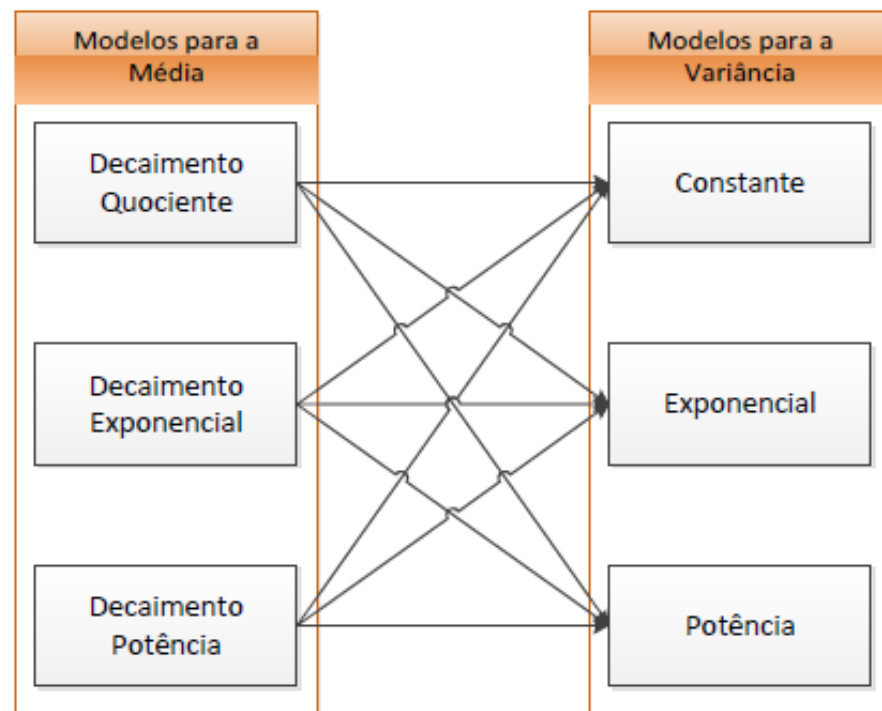


FIGURA 3 – ESQUEMA DA COMBINAÇÃO ENTRE MODELOS PARA MÉDIA E VARIÂNCIA.

Ao observar a Figura 3, foram ajustados três modelos para média combinados com três modelos para variância, totalizando nove modelos para cada uma das combinações dos tipos de tratamento e resfriamento, definidas na Seção 4, totalizando setenta e dois modelos ajustados.

### 3.2.2 Medidas para Avaliação dos Modelos

Com os modelos definidos e seus parâmetros estimados pelo método de máxima verossimilhança, foram utilizadas como medidas de avaliação e comparação o Teste da Razão de Verossimilhanças (TRV) e o Critério de Informação de Akaike (AIC).

O AIC, não é uma lógica de teste de hipóteses, portanto não se define hipótese nula nem se calcula p-valor, mas determina-se qual modelo é provavelmente o mais correto, combinando teoria de máxima verossimilhança, teoria da informação e o conceito de entropia da informação (MOTULSKY e CHRISTOPOULOS, 2004). A fórmula básica é definida por:

$$AIC = N \ln(SS / N) + 2K \quad (19)$$

de forma que  $N$  é o número de observações;  $K$  é o número total de parâmetros estimados no modelo pela regressão, considerando tanto os parâmetros do modelo para média quanto do modelo para variância, e  $SS$  como sendo a soma de quadrados das distâncias verticais entre os pontos e a curva.

Devido o AIC ser um critério de comparação entre modelos, isso significa que não se pode interpretar um único valor de AIC (MOTULSKY e CHRISTOPOULOS, 2004), sendo seu menor valor referente ao modelo mais coerente entre os comparados.

Para este estudo, o AIC foi utilizado na comparação dentre os modelos ajustados para média, deviado a estes não poderem ser comparados pelo TRV por não se tratarem de modelos aninhados.

Sendo assim, diferentemente do AIC, o Teste de Razão de Verossimilhanças (TRV) pode ser usado apenas para modelos aninhados, o que se torna uma limitação para esse critério, porém não deixando de ser igualmente válido quando esta premissa é satisfeita, calculando-se pela igualdade:

$$\xi_{RV} = 2[L(\hat{\beta}) - L(\beta_0)] \quad (20)$$

onde  $\hat{\beta}$  é a máxima verossimilhança de  $\beta$ , maximizando então  $L(\beta)$ ; e  $L(\beta_0)$  é o valor da máxima verossimilhança levando em consideração a hipótese nula. A estatística

TRV tem distribuição aproximada  $\chi_r^2$  quando a  $H_0$  é verdadeira (GALLANT, 1975), sendo os graus de liberdade denotados por  $r$  e obtidos a partir da diferença entre o número de parâmetros dos dois modelos aninhados. No presente trabalho, este teste foi aplicado na avaliação entre os modelos de variância, condicionados ao mesmo modelo para média, tornando-os aninhados. Desta forma, quando comparado o modelo de variância Constante com cada um dos outros modelos sugeridos (Exponencial e Potência), resulta assim na diferença de um parâmetro entre os modelos, fato este que corresponde a um grau de liberdade na distribuição aproximada  $\chi^2$ .

## 4 RESULTADOS E DISCUSSÃO

### 4.1 ANÁLISE EXPLORATÓRIA

Com o objetivo de estabelecer modelos estatísticos que estimem a quantidade de tanino solúvel em caquis da cultivar Kakimel, baseando-se no seu tratamento aplicado, dias de resfriamento e exposição ou não ao frio, primeiramente dividiu-se a base de dados de modo a formar oito caselas distintas, que, por sua vez, foram submetidas a cada um dos nove modelos mencionados na Seção 3. Adotou-se uma nomenclatura para cada casela visando a facilidade de visualização e entendimento (Tabela 1), de maneira que 12h, 24h, 36h e 48h se remetem aos tratamentos e N e S à exposição ou não ao frio.

TABELA 1 – DEFINIÇÃO DAS CASELAS PELA COMBINAÇÃO DO TEMPO DE EXPOSIÇÃO AO ÁLCOOL COM A OPÇÃO DE RESFRIAMENTO

| Tratamentos<br>(exposição ao álcool) | Resfriamento |       |
|--------------------------------------|--------------|-------|
|                                      | Sim          | Não   |
| 12 horas                             | 12h.S        | 12h.N |
| 24 horas                             | 24h.S        | 24h.N |
| 36 horas                             | 36h.S        | 36h.N |
| 48 horas                             | 48h.S        | 48h.N |

Para estudo em questão, contudo, não foram levadas em consideração diferentes concentrações de álcool, pois independente da concentração testada, esta induz decréscimo nos níveis de tanino a partir de 48 horas após o tratamento nas variedades Mikado e Rama Forte (SHIMIZU, CONEGLIAN e BRIANÇON, 2002).

Para a realização da modelagem propriamente dita, foi realizada uma higienização que consistiu em remover observações consideradas atípicas. Estas, por sua vez, decorrentes principalmente pelo uso de reagentes de outro fabricante. Como consequência, a casela 48h.N sofreu modificação no seu comportamento, até então não-linear, devido à retirada das observações citadas.

Com o tratamento da base de dados já realizado, observa-se ainda, na Figura 2, que independentemente da combinação entre tratamentos e se foi aplicado resfriamento ou não, os níveis de tanino solúvel decrescem. Nota-se também que,

nas combinações que envolvem o tratamento 1 e tratamento 2, os níveis iniciais de tanino solúvel são superiores aos demais. Tornando-se, então, nítida a redução da adstringência, fator este que torna o etanol um agente destanizador de grande potencial, pois segundo SEYMOUR et al (1993), o tratamento com etanol resultou em frutos contendo, aproximadamente, 13 vezes mais substâncias insolúveis que os frutos não tratados.

Antes de se iniciar os ajustes de modelos, este trabalho visa também estudar a relação presente entre a média e a variância dos dados para, então, estabelecer modelos mais precisos. Tal relação pode ser vista na Figura 4.




FIGURA 4 – MÉDIA AMOSTRAL EM FUNÇÃO DA VARIÂNCIA AMOSTRAL.

Ao se observar a Figura 2, supõe-se que haja uma relação não-nula entre a média e a variância das observações. Baseando-se nesta suposição, a Figura 4 mostra que existe uma relação entre média e variância que na escala log-log é linear e positiva. Portanto, a suposição de relação nula entre média e variância não é atendida.

Tendo em vista que a necessidade da modelagem para a variância tornou-se eminente, foram propostas as nove combinações de modelos para cada casela, conforme descrito na Seção 3, e após o ajuste, tem início a fase de comparação entre os mesmos.



Os modelos foram ajustados aos dados sendo os parâmetros estimados por máxima verossimilhança. Não foi obtida convergência para todos os modelos conforme mostra a Figura 5 que representa o valor da log-verossimilhança em função dos modelos ajustados.

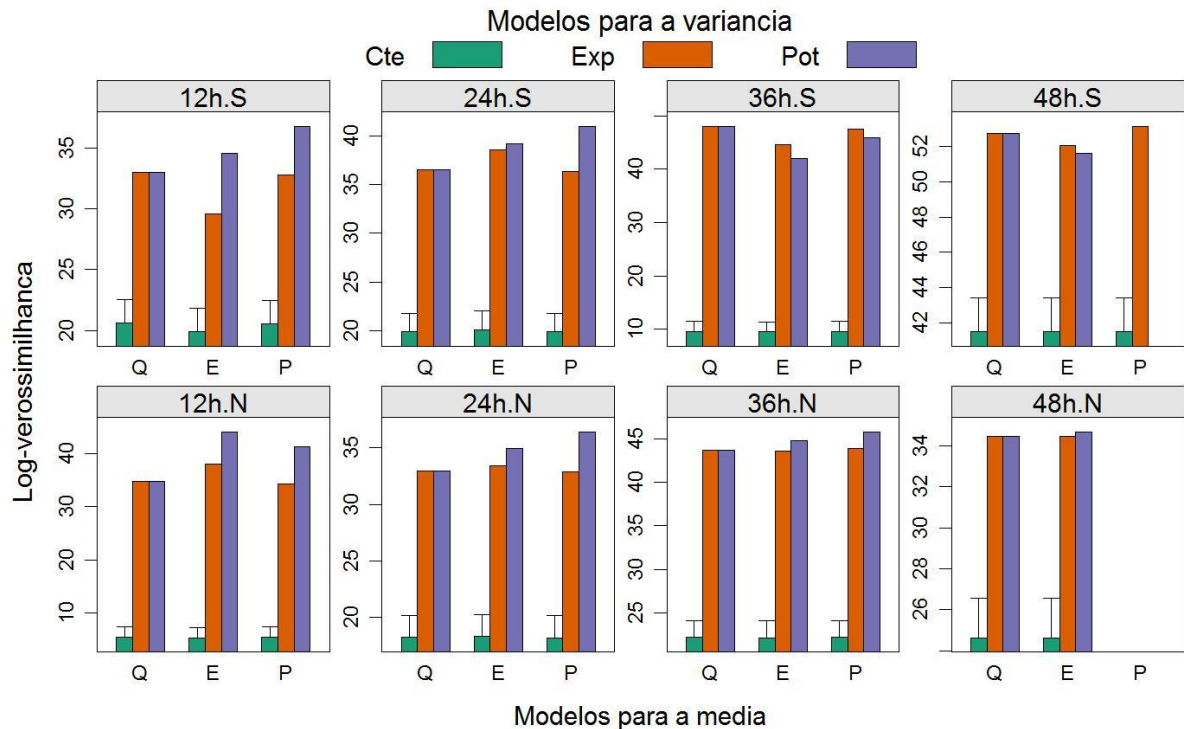


FIGURA 5 – VALORES PARA LOG-VEROSSIMILHANÇAS DOS MODELOS AJUSTADOS DIVIDIDOS POR CASELAS. BARRAS INDICAM MODELOS PARA MÉDIA E AS CORES DAS BARRAS INDICAM OS MODELOS DE VARIÂNCIA PARA CADA MÉDIA.

Pode-se observar, na Figura 5, que dos modelos propostos para a casela 48h.N, apenas os modelos quociente (Q) e decaimento exponencial (E) convergiram, levando em consideração as três suposições de variância já citadas. Nota-se, por exemplo, que os modelos de variância exponencial e potência tiveram uma diferença significativa se comparados com o modelo constante, por meio do Teste de Razão de Verossimilhanças. Para que não haja diferença significativa entre os modelos propostos para variância, os ajustes para variância constante precisariam atingir uma log-verossimilhança aproximada de, no mínimo, 27 para a casela em questão, correspondendo a metade do valor do  $\chi_1^2$  com um nível de significância de 5%, ao considerar 1 grau de liberdade.




FIGURA 6 – INTERVALOS DE CONFIANÇA PARA OS PARÂMETROS

Além dos modelos ajustados, a análise dos intervalos de confiança para os três parâmetros presentes em cada um dos modelos também é válida. Ao observá-los, na Figura 6, verifica-se que a maioria dos intervalos referentes à assíntota inferior (B) estão em torno do valor zero, indicando que todo tanino é solubilizável.

Quanto ao tanino solúvel total (A), nota-se uma relação negativa do mesmo com o período de exposição ao álcool, ou seja, quanto maior o período de exposição ao vapor de álcool etílico (em horas), menor o nível de tanino solúvel total. Já em relação ao parâmetro de meia-vida (V), foi observado que alguns intervalos contendo o valor zero. Isso decorre do fato de que os intervalos de Wald são simétricos por construção diferentemente dos intervalos da verossimilhança, que para o parâmetro V, poderiam deixar de conter o valor zero em alguns casos. Os demais, por outro lado, são superiores a zero, porém próximos. **De maneira geral, nota-se que, quando não há a modelagem da variância (modelo constante), percebe-se que seus intervalos tornam-se maiores, pois deixa-se de considerar uma dispersão maior no início do período de armazenamento, resultando em uma perda da precisão dos mesmos, pois a dispersão reduz conforme a média.** Ao referir-se aos parâmetros do tratamento quatro, entretanto, identifica-se um comportamento distinto aos demais tratamentos na maior parte dos intervalos de confiança, sendo este devido ao menor tamanho de amostra.

Com os intervalos de confiança analisados, calculam-se os valores preditos pelo modelo para analisar o comportamento dos mesmos graficamente (Figura 7). Independentemente do modelo sugerido, todos são decrescentes. Nota-se ainda que, graficamente, não há diferenças relevantes entre os modelos aplicados, porém na Figura 5 verifica-se a existência de diferenças significativas entre os mesmos, quando se utiliza a log-verossimilhança como critério de avaliação.

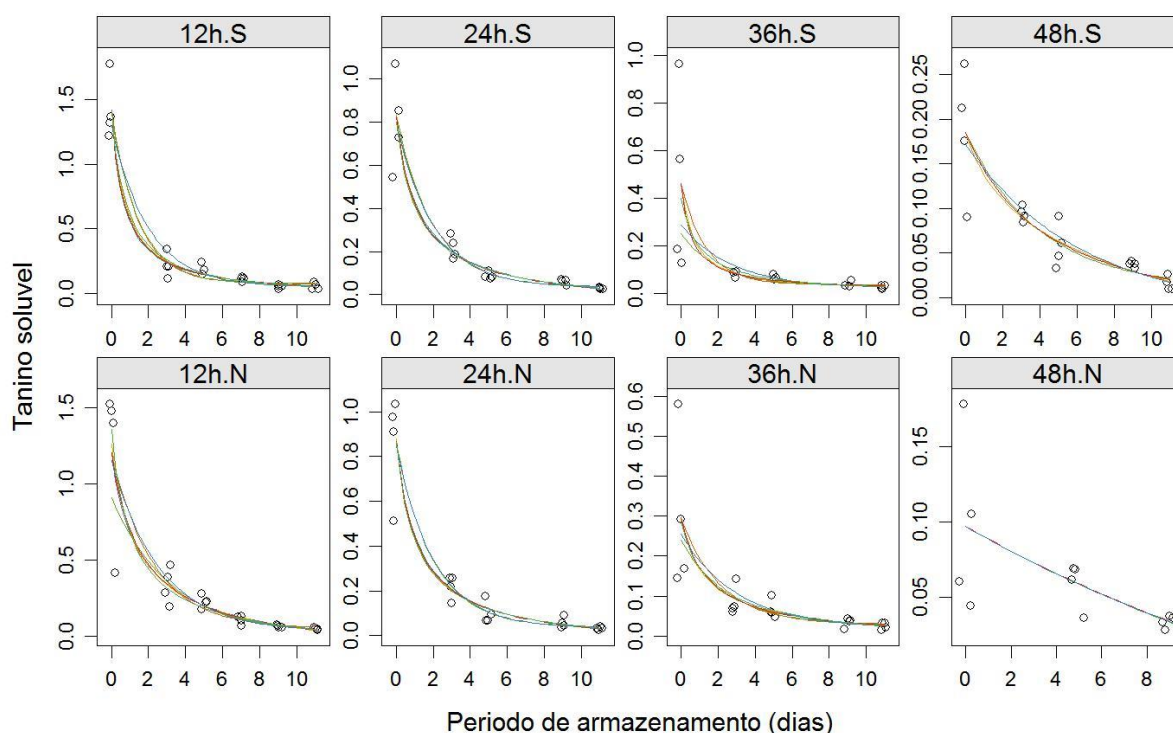


FIGURA 7 – VALORES PREDITOS PELOS MODELOS AJUSTADOS.

Isso deve-se ao fato de que o julgamento visual, no gráfico da Figura 7, é capaz apenas de verificar o ajuste da média, ignorando-se que verossimilhança considera o ajuste dos dados incluindo a especificação de variância. Por isso é válida a análise do gráfico dos resíduos padronizados pelos valores preditos.

Visando verificar os pressupostos assumidos para o ajuste de modelos não lineares bem como as diferenças descritas acima, são apresentadas na Figura 8 uma visão dos resíduos padronizados por casela e por combinação de modelos (média vs. variância).

Tem-se então, com base na Figura 8, que o pressuposto de que cada resíduo padronizado deve seguir uma  $Normal(0, \sigma^2)$  (BATES e WATTS, 1988) foi atendido. Contudo, para demonstrar como se comportam cada um dos modelos sugeridos para variância, é apresentado na Figura 9 as raízes dos valores absolutos dos resíduos pela log dos valores preditos.

Percebe-se que para o modelo de variância constante, há uma relação visível entre a média e a variância dos dados. Quando a modelagem da variância é utilizada, sendo elas exponencial e potência, a relação citada para a variância constante deixa de ser notada. Tais ajustes levam, por fim, às bandas de confiança, apresentadas na Figura 10.

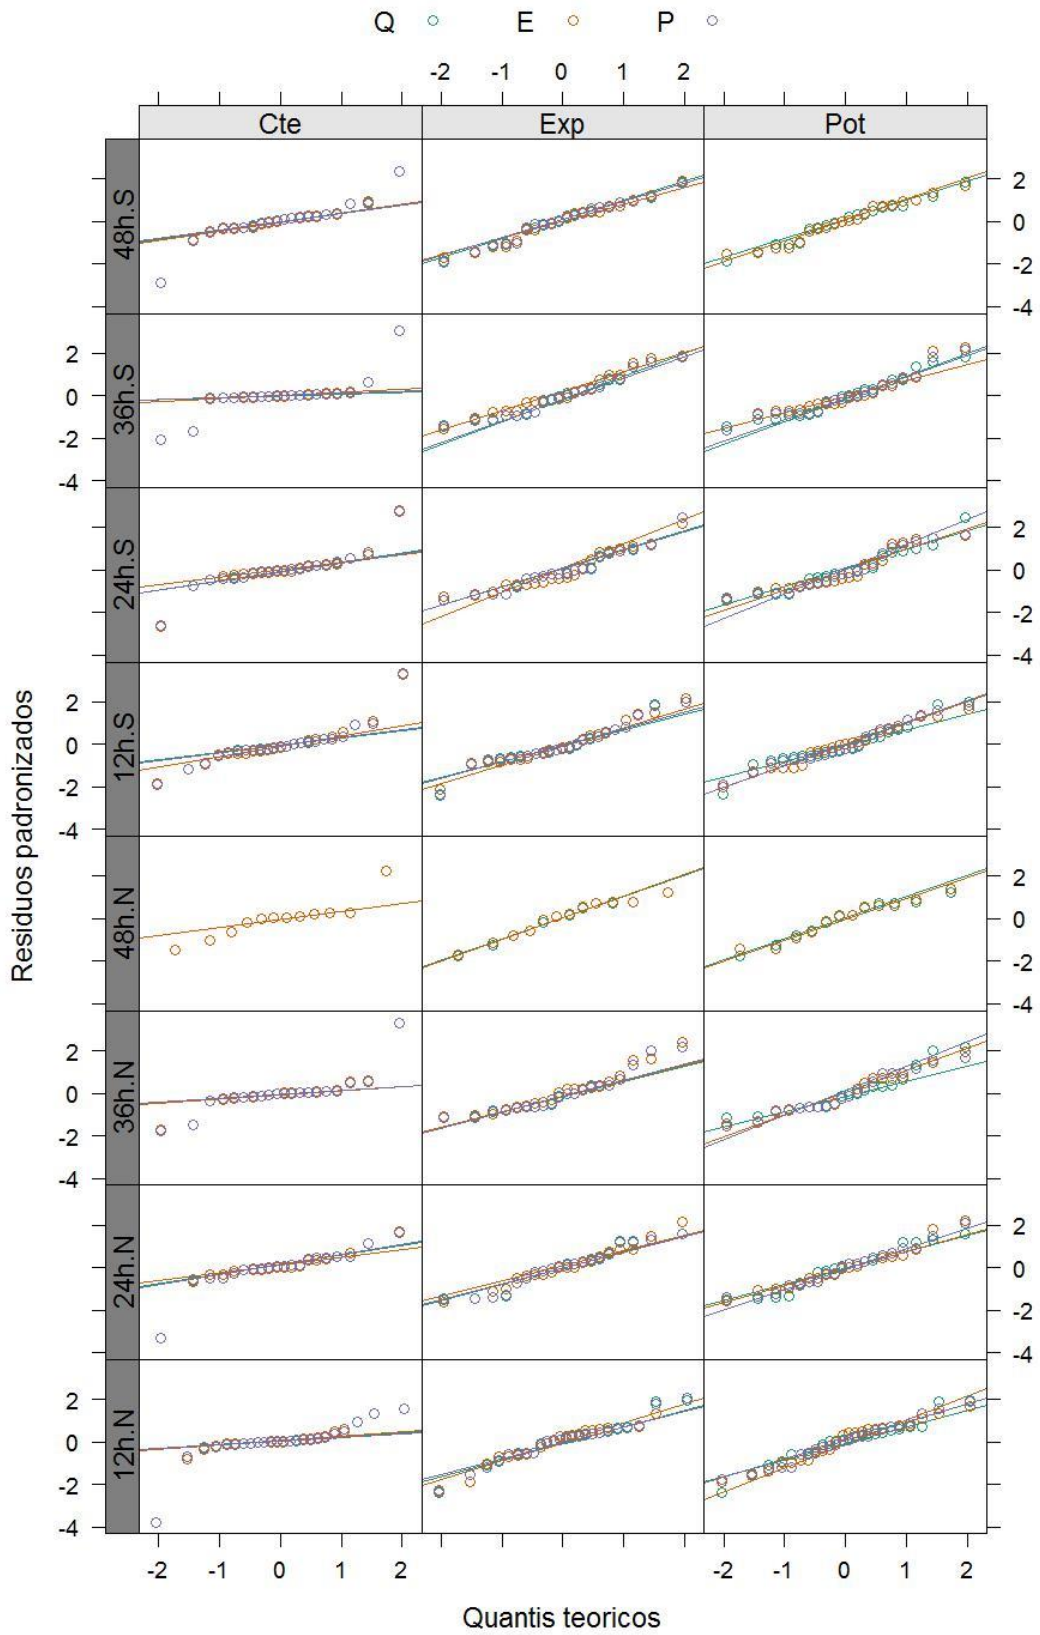


FIGURA 8 – QUANTIS OBSERVADOS DOS RESÍDUOS PADRONIZADOS EM FUNÇÃO DOS QUANTIS TEÓRICOS DE UMA VARIÁVEL ALEATÓRIA NORMAL PADRÃO SEGMENTADOS POR CASELA.



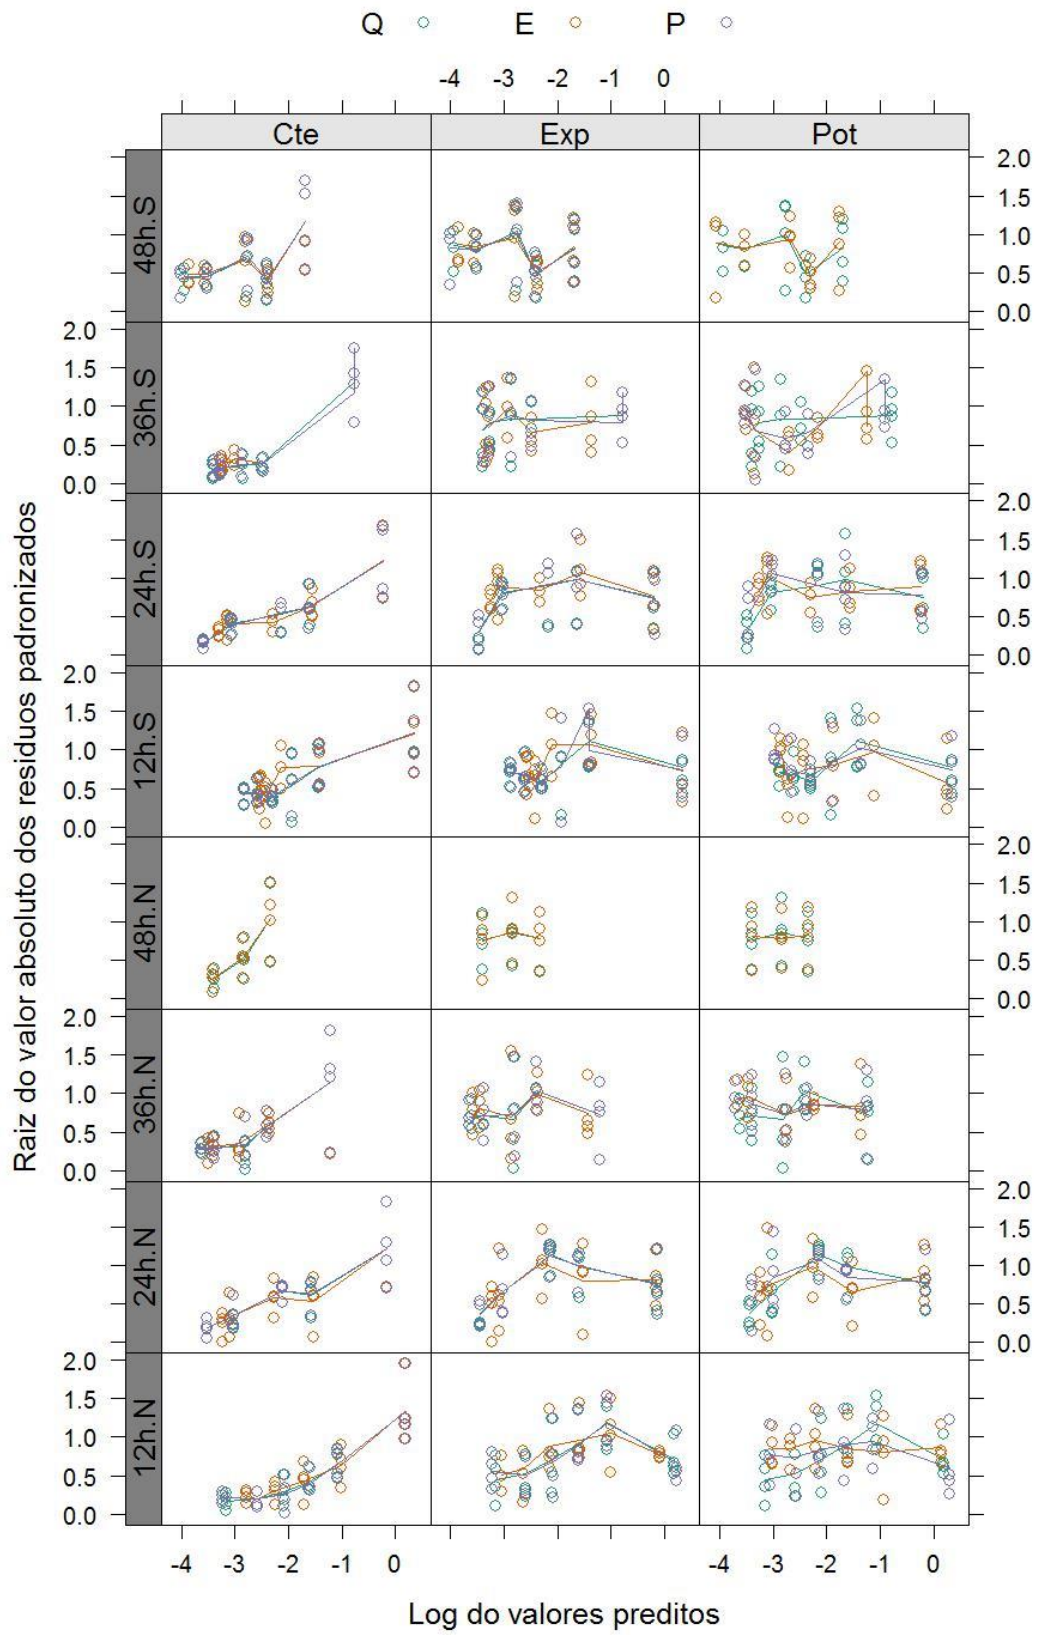


FIGURA 9 – RESÍDUOS PADRONIZADOS EM FUNÇÃO DOS VALORES PREDITOS.

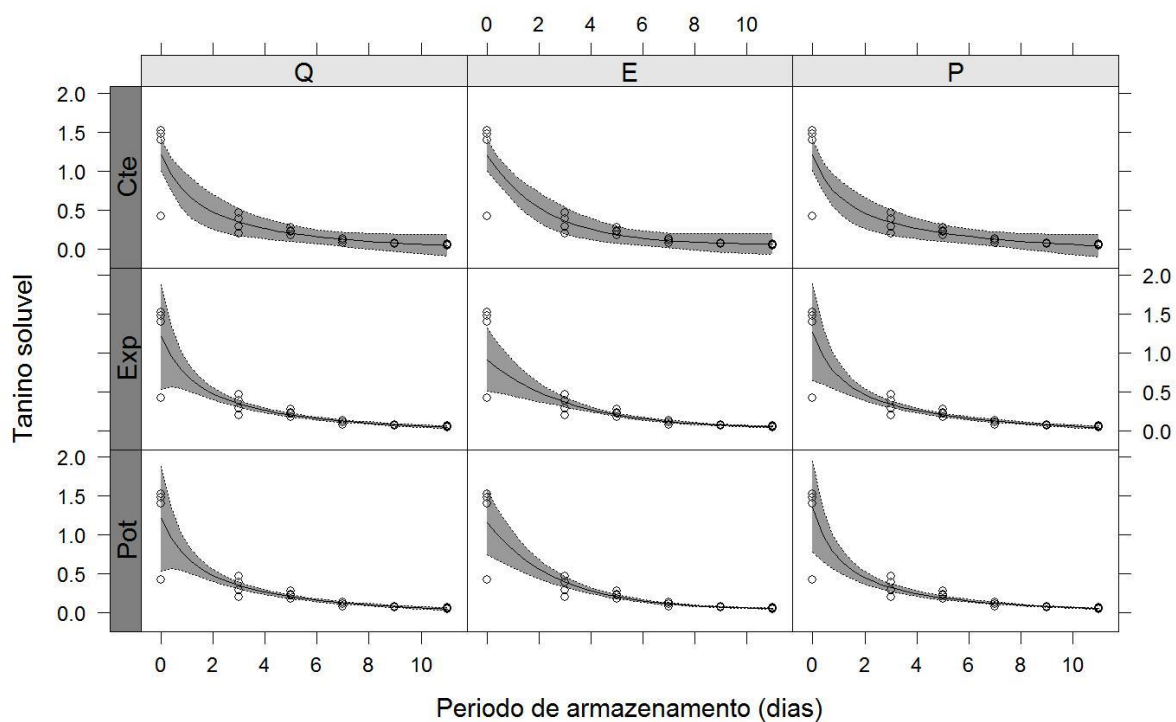


FIGURA 10 – BANDAS DE CONFIANÇA PARA OS AJUSTES REFERENTES À CASELA 12H.N.

De acordo com a Figura 10, observa-se as bandas de confiança dos nove modelos avaliados para a casela 12h.H. Nota-se que, nos modelos que não envolvem variância constante, as bandas de confiança se tornam mais precisas ao longo do período de armazenamento, de forma que traduzem de maneira mais assertiva o comportamento do conteúdo de tanino solúvel ao longo do período de armazenamento. Por outro lado, os modelos de variância constante desconsideram essa dispersão, principalmente nos primeiros e nos últimos dias do período de armazenamento. De forma geral, quando é modelada a variância, a precisão dos intervalos de confiança varia conforme sua média.

## 5 CONCLUSÃO

Ao utilizar-se tratamentos relacionados com a exposição dos frutos ao vapor de álcool etílico, a variância mostrou-se heterogênea ao longo dos períodos de armazenamento. Diante de tal comportamento, tornaram-se plausíveis análises envolvendo modelos combinados, tentando ajustar tanto a média quanto a variância dos níveis de tanino solúvel. Assim sendo, ao comparar-se os modelos ajustados, verificou-se que modelos que consideram a modelagem da variância em conjunto com a média são mais adequados, ao passo que modelos considerando a variância como constante, pois as estimações são baseadas em suposições inválidas. Observou-se ainda que quando foi possível o ajuste de um modelo, considerando potência para a média e potência para a variância, este a obteve as melhores medidas de ajuste, utilizando como critérios o Critério de Informação de Akaike e o Teste de Razão de Verossimilhanças.



## REFERÊNCIAS

- BATES, D. M.; WATTS, D. G. **Nonlinear regression analysis and its applications**. New York: J. Wiley, 1988.
- BERTHOUEX, P. M.; BROWN, L. C. **Statistics for environmental engineers**. 2. ed. Boca Raton: Lewis Publishers/CRC Press, 2002.
- BIASI, L. A. **Cultura do Caquizeiro**. II Encontro de Fruticultura dos Campos Gerais. Ponta Grossa. UEPG, 2009, 9p. Disponível em: [http://www.uepg.br/uepg\\_departamentos/defito/htm/labiovegetal/Caqui.pdf](http://www.uepg.br/uepg_departamentos/defito/htm/labiovegetal/Caqui.pdf).
- BRACKMANN, A. Capa/A produção, o consumo e a qualidade do caqui no Brasil. **Revista Brasileira de Fruticultura**, v. 25, n. 1, abr 2003. ISSN 0100-2945. Disponível em: <http://www.scielo.br/pdf/rbf/v25n1/a01v25n1.pdf>.
- CARROLL, R. J.; RUPPERT, D. **Transformation and Weighting in Regression**. New York: Chapman and Hall, 1988.
- DRAPER, N.; SMITH, H. **Applied regression analysis**. 3. ed. New York: Wiley-Interscience, 1998.
- EDAGI, F. K.; KLUGE, R. A. Remoção de adstringência de caqui: um enfoque bioquímico, fisiológico e tecnológico. **Ciência Rural**, 39, mar-abr 2009. p. 585-594.
- GALLANT, A. R. Nonlinear Regression. **The American Statistician**, v. 29, n. 2, p. 73-81, Mai 1975. Disponível em: <http://www.jstor.org/stable/2683268>.
- GELMAN, A.; HILL, J. **Data Analysis Using Regression and Multilevel/Hierarchical Models**. Cambridge University Press, 2006.
- HUET, S. et al. **Statistical tools for nonlinear regression: a practical guide with S-PLUS and R examples**. 2. ed. Springer, 2003.
- ITTAH, Y. . Sugar content changes in persimmon fruits (*Diospyros kaki* L.) during artificial ripening with CO<sub>2</sub>: a possible connection to deastringency mechanisms. **Food Chemistry**, v. 48, n. 1, p. 25 - 29, 1993.
- KHURI, A. I.; CORNELL, J. A. **Response Surface: Designs and analyses**. New York: Marcel Dekker, Inc., 1987.
- LIM, C.; SEN, P. K.; PEDDADA, S. D. Accounting for Uncertainty in Heteroscedasticity in Nonlinear Regression. **Journal of Statistical Planning and Inference**, n. 142, 2012. p. 1047-1062.
- MAZUCHELI, J.; ACHCAR, J. A. Algumas Considerações em Regressão Não Linear. **Acta Scientiarum**, Maringá, v. 24, n. 6, p. 1761-1770, 2002.

MOTULSKY, H.; CHRISTOPOULOS, A. **Fitting Models to Biological Data Using Linear and Nonlinear Regression: A Practical Guide to Curve Fitting**. Oxford University Press, 2004. Disponível em: <http://books.google.com.br/books?id=tlsh56pl0IC>.

PINHEIRO, J. C.; BATES, D. M. **Mixed Effects Models in S and S-Plus**. Springer, 2000.

RAWLINGS, J. O.; PANTULA, S. G.; DICKEY, D. A. **Applied Regression Analysis: A Research Tool**. 2. ed. Springer, 1998.

RITZ, C.; STREIBIG, J. C. **Nonlinear regression with R**. 1. ed. New York: Springer, 2008.

ROBINSON, A. P.; HAMANN, J. D. **Forest analytics with R**. 1. ed. New York: Springer, 2011.

SCHABENBERGER, O.; PIERCE, F. J. **Contemporary statistical models for the plant and soil Sciences**. 1. ed. Boca Raton: CRC Press, 2002.

SEBER, G. A. F.; WILD, C. J. **Nonlinear regression**. New York: J. Wiley, 1989.

SEYMOUR, G. B. **Biochemistry of fruit ripening**. London: Chapman & Hall, 1993. p. 151-186.

SHEATHER, S. **A modern Approach to Regression with R**. 1. ed. Springer, 2009.

SHIMIZU, M. K.; CONEGLIAN, R. C. C.; BRIANÇON, R. N. AVALIAÇÃO DO EFEITO DE DIFERENTES CONCENTRAÇÕES DE ÁLCOOL NA. **Agronomia**, 36, 2002. p. 11-16.

VENABLES, W. N.; RIPLEY, B. D. **Modern applied statistics with S**. 4. ed. New York: Springer, 2002.

WEISBERG, S. **Applied Linear Regression**. New York: John Wiley & Sons, 1980.

WEISBERG, S. **Applied Linear Regression**. 3. ed. Hoboken: J. Wiley, 2005.

ZEVIANI, W. M. **Um Procedimento para Obter Parametrizações Interpretáveis com Aplicações em Modelos de Regressão Não Linear**. Lavras, 2013.

ZEVIANI, W. M.; RIBEIRO JR, P. J.; BONAT, W. H. **Curso em Modelos de Regressão Não Linear**. 58. ed. Campina Grande: RBras, 2013. p. 101.

**ANEXOS**

**ANEXO A** – Demonstração das reparametrizações e transformações dos modelos escolhidos

- Michaelis Menten

$$f(x) = \frac{\lambda x}{(v + x)}$$

$$f(x) = \frac{\lambda}{(v + x)}$$

$$f(x) = \frac{\lambda}{(v + x)} * \frac{1/v}{1/v}$$

$$f(x) = \frac{\lambda/v}{(v/v + x/v)}$$

$$f(x) = \beta + \frac{\alpha}{(1 + \frac{x}{v})}$$

- Decaimento Exponencial

$$\beta + \frac{1}{2}\alpha = \beta + \alpha e^{-\kappa x}$$

$$\frac{1}{2} = e^{-\kappa x}$$

$$\log(1/2) = -\kappa x$$

$$x = -\frac{\log\left(\frac{1}{2}\right)}{\kappa}$$

$$v = -\frac{\log\left(\frac{1}{2}\right)}{\kappa}$$

$$\kappa = -\frac{\log\left(\frac{1}{2}\right)}{v} = \frac{\log(2)}{v}$$

$$\beta + \alpha e^{-\frac{\log(2)x}{v}}$$

- Potência

$$\beta + \frac{1}{2}\alpha = \beta + \alpha(x+1)^{-\kappa}$$

$$\frac{1}{2} = (x+1)^{-\kappa}$$

$$x = \sqrt[-\kappa]{\frac{1}{2}} - 1$$

$$v = \sqrt[-\kappa]{\frac{1}{2}} - 1$$

$$\log(v+1) = \frac{1}{\kappa} \log\left(\frac{1}{2}\right)$$

$$\log(v+1) = \frac{1}{\kappa} \log(2)$$

$$\log(v+1) = \frac{1}{\kappa} \log(2)$$

$$\kappa = \frac{\log(2)}{\log(v+1)}$$

$$\beta + \alpha(x+1)^{-\frac{\log(2)}{\log(v+1)}}$$

**ANEXO B** – Quadro resumo dos modelos ajustados com as estimativas e erros padrões (em parênteses) de cada parâmetro –  
Parte 1

| Tratamento | Frio | Média | Variância | LL    | AIC    | BIC    | $\beta$      | $\alpha$    | $u$            |
|------------|------|-------|-----------|-------|--------|--------|--------------|-------------|----------------|
| 12 horas   | N    | Q     | Cte       | 5,48  | -2,97  | 1,75   | -0,13 (0,17) | 1,34 (0,19) | 1,65 (1,02)    |
| 12 horas   | N    | Q     | Exp       | 34,77 | -59,54 | -53,65 | -0,13 (0,04) | 1,34 (0,32) | 1,65 (0,74)    |
| 12 horas   | N    | Q     | Pot       | 41,74 | -73,47 | -67,58 | -0,1 (0,02)  | 1,37 (0,28) | 1,34 (0,44)    |
| 12 horas   | N    | E     | Cte       | 5,38  | -2,75  | 1,96   | 0,05 (0,08)  | 1,15 (0,13) | 1,58 (0,5)     |
| 12 horas   | N    | E     | Exp       | 38,09 | -66,18 | -60,29 | 0,02 (0,02)  | 0,89 (0,19) | 2,18 (0,44)    |
| 12 horas   | N    | E     | Pot       | 44,09 | -78,17 | -72,28 | 0,03 (0,01)  | 1,12 (0,21) | 1,82 (0,21)    |
| 12 horas   | N    | P     | Cte       | 5,49  | -2,97  | 1,74   | -0,25 (0,43) | 1,45 (0,43) | 1,88 (1,93)    |
| 12 horas   | N    | P     | Exp       | 34,26 | -58,52 | -52,63 | -0,21 (0,14) | 1,48 (0,21) | 1,65 (0,93)    |
| 12 horas   | N    | P     | Pot       | 41,33 | -72,67 | -66,78 | -0,12 (0,06) | 1,48 (0,26) | 1,2 (0,39)     |
| 24 horas   | N    | Q     | Cte       | 18,25 | -28,50 | -24,52 | -0,07 (0,08) | 0,92 (0,1)  | 1,26 (0,62)    |
| 24 horas   | N    | Q     | Exp       | 32,98 | -55,96 | -50,98 | -0,06 (0,03) | 0,93 (0,12) | 1,17 (0,32)    |
| 24 horas   | N    | Q     | Pot       | 36,37 | -62,75 | -57,77 | -0,05 (0,02) | 0,91 (0,12) | 1,15 (0,32)    |
| 24 horas   | N    | E     | Cte       | 18,34 | -28,68 | -24,70 | 0,04 (0,04)  | 0,82 (0,07) | 1,37 (0,32)    |
| 24 horas   | N    | E     | Exp       | 33,39 | -56,78 | -51,80 | 0,04 (0,01)  | 0,82 (0,11) | 1,37 (0,17)    |
| 24 horas   | N    | E     | Pot       | 34,93 | -59,85 | -54,88 | 0,04 (0,01)  | 0,81 (0,1)  | 1,41 (0,18)    |
| 24 horas   | N    | P     | Cte       | 18,24 | -28,48 | -24,49 | -0,08 (0,14) | 0,94 (0,15) | 1,26 (0,75)    |
| 24 horas   | N    | P     | Exp       | 32,87 | -55,74 | -50,77 | -0,07 (0,05) | 0,94 (0,11) | 1,14 (0,32)    |
| 24 horas   | N    | P     | Pot       | 36,38 | -62,76 | -57,78 | -0,06 (0,04) | 0,93 (0,11) | 1,13 (0,32)    |
| 36 horas   | N    | Q     | Cte       | 22,21 | -36,42 | -32,43 | -0,01 (0,07) | 0,3 (0,08)  | 1,45 (1,71)    |
| 36 horas   | N    | Q     | Exp       | 43,71 | -77,42 | -72,44 | -0,01 (0,02) | 0,3 (0,1)   | 1,45 (0,92)    |
| 36 horas   | N    | Q     | Pot       | 45,68 | -81,36 | -76,39 | -0,02 (0,02) | 0,31 (0,08) | 1,8 (1,04)     |
| 36 horas   | N    | E     | Cte       | 22,15 | -36,31 | -32,32 | 0,03 (0,03)  | 0,27 (0,05) | 1,49 (0,86)    |
| 36 horas   | N    | E     | Exp       | 43,56 | -77,12 | -72,14 | 0,02 (0,01)  | 0,21 (0,09) | 1,81 (0,68)    |
| 36 horas   | N    | E     | Pot       | 44,75 | -79,50 | -74,52 | 0,02 (0,01)  | 0,24 (0,07) | 2,09 (0,67)    |
| 36 horas   | N    | P     | Cte       | 22,21 | -36,42 | -32,44 | -0,03 (0,15) | 0,32 (0,15) | 1,57 (2,63)    |
| 36 horas   | N    | P     | Exp       | 43,84 | -77,68 | -72,71 | -0,03 (0,05) | 0,32 (0,07) | 1,57 (1,37)    |
| 36 horas   | N    | P     | Pot       | 45,77 | -81,54 | -76,56 | -0,05 (0,07) | 0,34 (0,06) | 2,12 (2,1)     |
| 48 horas   | N    | Q     | Cte       | 24,64 | -41,28 | -39,34 | -0,25 (2,28) | 0,35 (2,28) | 40,18 (320,75) |
| 48 horas   | N    | Q     | Exp       | 34,48 | -58,95 | -56,53 | -0,25 (1,35) | 0,35 (1,33) | 40,18 (210,46) |
| 48 horas   | N    | Q     | Pot       | 34,67 | -59,34 | -56,91 | -0,25 (1,34) | 0,35 (1,32) | 40,18 (205,92) |
| 48 horas   | N    | E     | Cte       | 24,64 | -41,28 | -39,34 | -0,09 (1,11) | 0,19 (1,11) | 15,33 (108,99) |
| 48 horas   | N    | E     | Exp       | 34,47 | -58,95 | -56,52 | -0,09 (0,66) | 0,19 (0,63) | 15,33 (71,44)  |
| 48 horas   | N    | E     | Pot       | 34,67 | -59,34 | -56,91 | -0,09 (0,67) | 0,19 (0,65) | 15,49 (71,61)  |
| 12 horas   | S    | Q     | Cte       | 20,61 | -33,22 | -28,68 | -0,02 (0,07) | 1,44 (0,08) | 0,67 (0,29)    |

**ANEXO B – Quadro resumo dos modelos ajustados com as estimativas e erros padrões (em parênteses) de cada parâmetro –  
Parte 2**

| Tratamento | Frio | Média | Variância | LL    | AIC    | BIC    | $\beta$       | $\alpha$     | u                   |
|------------|------|-------|-----------|-------|--------|--------|---------------|--------------|---------------------|
| 12 horas   | S    | Q     | Exp       | 32,97 | -55,93 | -50,26 | -0,03 (0,03)  | 1,44 (0,13)  | 0,7 (0,16)          |
| 12 horas   | S    | Q     | Pot       | 36,80 | -63,60 | -57,92 | -0,04 (0,02)  | 1,46 (0,13)  | 0,77 (0,18)         |
| 12 horas   | S    | E     | Cte       | 19,87 | -31,73 | -27,19 | 0,08 (0,03)   | 1,34 (0,06)  | 0,99 (0,19)         |
| 12 horas   | S    | E     | Exp       | 29,57 | -49,14 | -43,46 | 0,08 (0,02)   | 1,31 (0,13)  | 1,04 (0,12)         |
| 12 horas   | S    | E     | Pot       | 34,55 | -59,11 | -53,43 | 0,05 (0,01)   | 1,25 (0,17)  | 1,38 (0,16)         |
| 12 horas   | S    | P     | Cte       | 20,55 | -33,11 | -28,57 | 0 (0,08)      | 1,42 (0,09)  | 0,72 (0,23)         |
| 12 horas   | S    | P     | Exp       | 32,78 | -55,56 | -49,88 | -0,01 (0,04)  | 1,41 (0,13)  | 0,75 (0,13)         |
| 12 horas   | S    | P     | Pot       | 36,75 | -63,51 | -57,83 | -0,03 (0,04)  | 1,43 (0,13)  | 0,82 (0,14)         |
| 24 horas   | S    | Q     | Cte       | 19,88 | -31,76 | -27,77 | -0,07 (0,08)  | 0,87 (0,09)  | 1,36 (0,64)         |
| 24 horas   | S    | Q     | Exp       | 36,52 | -63,04 | -58,06 | -0,05 (0,02)  | 0,88 (0,12)  | 1,19 (0,31)         |
| 24 horas   | S    | Q     | Pot       | 40,91 | -71,83 | -66,85 | -0,05 (0,02)  | 0,86 (0,11)  | 1,23 (0,32)         |
| 24 horas   | S    | E     | Cte       | 20,08 | -32,16 | -28,17 | 0,03 (0,04)   | 0,76 (0,06)  | 1,43 (0,32)         |
| 24 horas   | S    | E     | Exp       | 38,57 | -67,13 | -62,15 | 0,04 (0,01)   | 0,79 (0,11)  | 1,36 (0,15)         |
| 24 horas   | S    | E     | Pot       | 39,19 | -68,37 | -63,39 | 0,04 (0,01)   | 0,76 (0,09)  | 1,42 (0,16)         |
| 24 horas   | S    | P     | Cte       | 19,85 | -31,70 | -27,72 | -0,09 (0,15)  | 0,89 (0,15)  | 1,38 (0,85)         |
| 24 horas   | S    | P     | Exp       | 36,34 | -62,67 | -57,69 | -0,07 (0,04)  | 0,9 (0,11)   | 1,17 (0,33)         |
| 24 horas   | S    | P     | Pot       | 40,99 | -71,98 | -67,00 | -0,07 (0,04)  | 0,87 (0,1)   | 1,25 (0,36)         |
| 36 horas   | S    | Q     | Cte       | 9,55  | -11,10 | -7,12  | 0,01 (0,1)    | 0,45 (0,13)  | 0,57 (1,36)         |
| 36 horas   | S    | Q     | Exp       | 48,04 | -86,07 | -81,09 | 0,01 (0,01)   | 0,45 (0,18)  | 0,57 (0,31)         |
| 36 horas   | S    | Q     | Pot       | 46,37 | -82,74 | -77,76 | 0 (0,01)      | 0,44 (0,15)  | 0,84 (0,44)         |
| 36 horas   | S    | E     | Cte       | 9,52  | -11,04 | -7,06  | 0,04 (0,05)   | 0,42 (0,1)   | 0,93 (0,91)         |
| 36 horas   | S    | E     | Exp       | 44,59 | -79,17 | -74,19 | 0,03 (0,01)   | 0,22 (0,14)  | 1,38 (0,58)         |
| 36 horas   | S    | E     | Pot       | 42,07 | -74,14 | -69,17 | 0,02 (0,01)   | 0,26 (0,13)  | 1,9 (0,72)          |
| 36 horas   | S    | P     | Cte       | 9,55  | -11,10 | -7,11  | 0,44 (0,14)   | 0,02 (0,11)  | 0,65 (1)            |
| 36 horas   | S    | P     | Exp       | 47,53 | -85,05 | -80,07 | 0,44 (0,17)   | 0,02 (0,01)  | 0,65 (0,22)         |
| 36 horas   | S    | P     | Pot       | 45,94 | -81,88 | -76,90 | 0,41 (0,13)   | 0 (0,02)     | 1 (0,51)            |
| 48 horas   | S    | Q     | Cte       | 41,51 | -75,02 | -71,04 | -0,05 (0,05)  | 0,23 (0,05)  | 4,49 (2,78)         |
| 48 horas   | S    | Q     | Exp       | 52,77 | -95,53 | -90,55 | -0,05 (0,03)  | 0,23 (0,03)  | 4,49 (2,29)         |
| 48 horas   | S    | Q     | Pot       | 52,21 | -94,43 | -89,45 | -0,07 (0,04)  | 0,25 (0,04)  | 6,24 (3,44)         |
| 48 horas   | S    | E     | Cte       | 41,48 | -74,95 | -70,97 | 0,01 (0,02)   | 0,17 (0,03)  | 2,8 (1,09)          |
| 48 horas   | S    | E     | Exp       | 52,05 | -94,10 | -89,12 | 0,01 (0,01)   | 0,17 (0,03)  | 2,8 (0,82)          |
| 48 horas   | S    | E     | Pot       | 51,61 | -93,22 | -88,24 | -0,01 (0,03)  | 0,19 (0,02)  | 4,31 (1,82)         |
| 48 horas   | S    | P     | Cte       | 41,50 | -75,01 | -71,03 | -1,93 (21,48) | 2,11 (21,47) | 1,26E+09 (2,80E+11) |
| 48 horas   | S    | P     | Exp       | 53,14 | -96,29 | -91,31 | -1,93 (17,36) | 2,11 (17,34) | 1,26E+09 (2,30E+11) |

## ANEXO C – Comandos R para ajuste do modelo de regressão linear

```

#-----
# Definicoes da sessao.

rm(list=ls())
require(lattice)
require(latticeExtra)
require(plyr)
require(nlme)

#-----
# Funcoes para a sessao.

prepanel.barchart.errbar <- function(y, sdv, subscripts=subscripts, ...){
  ly <- as.numeric(y+sdv[subscripts])
  list(ylim=range(y, ly, finite=TRUE)) }
panel.barchart.errbar <- function(x, y, subscripts, groups, sdv, box.ratio, ...){
  panel.barchart(x, y, subscripts=subscripts,
    groups=groups, box.ratio=box.ratio, ...)
  d <- 1/(nlevels(groups)+nlevels(groups)/box.ratio)
  g <- (as.numeric(groups[subscripts])-1); g <- (g-median(g))*d
  panel.arrows(as.numeric(x)+g, y, as.numeric(x)+g, y+sdv[subscripts],
    angle=90, length=0.05) }
source("http://dl.dropboxusercontent.com/u/48140237/bandas.R")

#-----
# Estilo.

display.brewer.all()
mycol <- c(brewer.pal(6, "Dark2"), brewer.pal(6, "Set1"))
old.tp <- trellis.par.get()
ps <- list(box.rectangle=list(col=1, fill=c("gray70")),
  box.umbrella=list(col=1, lty=1),
  dot.symbol=list(col=1, pch=19),
  dot.line=list(col="gray50", lty=3),
  plot.symbol=list(col=1, cex=0.7),
  plot.line=list(col=1),
  plot.polygon=list(col="gray80"),
  superpose.line=list(col=mycol),
  superpose.symbol=list(col=mycol),
  superpose.polygon=list(col=mycol),
  strip.background=list(col=c("gray90", "gray50")))
show.settings()
show.settings(ps)
trellis.par.set(ps)

#-----
## require(rpanel)
## source("http://dl.dropboxusercontent.com/u/48140237/rp.nlregression.R")

#-----
# Leitura dos dados.

db <- read.table("base_final.txt", header=TRUE, sep=",")
db <- transform(db, caso= interaction(trat, frio), rept=as.numeric(rept))
attach(db)

#-----
# objeto que guarda valores iniciais para ajuste dos modelos

ch <- structure(list(mQ = structure(c(-0.132, -0.065, -0.008, -0.249,
-0.023, -0.068, 0.011, -0.048, 1.336, 0.923, 0.304, 0.346, 1.441,
0.866, 0.449, 0.233, 1.65, 1.257, 1.452, 40.179, 0.665, 1.361,
0.573, 4.486), .Dim = c(8L, 3L), .Dimnames = list(c("12H.N", "24H.N",
"36H.N", "48H.N", "12H.S", "24H.S", "36H.S", "48H.S"), c("th1", "th2",
"th3"))), mE = structure(c(0.053, 0.037, 0.029, -0.094, 0.079,
0.034, 0.039, 0.009, 1.149, 0.821, 0.266, 0.191, 1.337, 0.765,
0.421, 0.175, 1.582, 1.374, 1.482, 15.489, 0.992, 1.427, 0.937,
2.824), .Dim = c(8L, 3L), .Dimnames = list(c("12H.N", "24H.N",
"36H.N", "48H.N", "12H.S", "24H.S", "36H.S", "48H.S"), c("th1", "th2",
"th3"))), mP = structure(c(-0.246, -0.084, -0.026, 0.001, -0.095,
0.02, -1.93, 1.451, 0.942, 0.321, 1.417, 0.894, 0.44, 2.115,

```



```

1.885, 1.259, 1.578, 0.719, 1.38, 0.65, 1367395738.211), .Dim = c(7L,
3L), .Dimnames = list(c("12H.N", "24H.N", "36H.N", "12H.S", "24H.S",
"36H.S", "48H.S"), c("th1", "th2", "th3"))), .Names = c("mQ", "mE", "mP"))

ch <- lapply(ch, function(i){ colnames(i) <- c("B", "A", "V"); i })

#-----
# Divisao a base geral por caselas

dc <- subset(db, caso=="12H.N")

#-----
# Modelos casela dc.

start <- as.list(ch$mQ["12H.N",])
dc.mm.cte <- gnls(taninosol~B+A/(1+parm/V), start=start, data=dc)
summary(dc.mm.cte)

start <- as.list(coef(dc.mm.cte))
dc.mm.ve <- gnls(taninosol~B+A/(1+parm/V), start=start, data=dc, weights=varExp())
summary(dc.mm.ve)

start <- as.list(coef(dc.mm.ve))
dc.mm.vp <- gnls(taninosol~B+A/(1+parm/V), start=start, data=dc, weights=varPower())
summary(dc.mm.vp)

start <- as.list(coef(dc.mm.vp))
dc.de.cte <- gnls(taninosol~B+A*exp(-(log(2)/V)*parm), start=start, data=dc)
summary(dc.de.cte)

start <- as.list(coef(dc.de.cte))
dc.de.ve <- gnls(taninosol~B+A*exp(-(log(2)/V)*parm), start=start, data=dc, weights=varExp())
summary(dc.de.ve)

start <- as.list(coef(dc.de.ve))
dc.de.vp <- gnls(taninosol~B+A*exp(-(log(2)/V)*parm), start=start, data=dc, weights=varPower())
summary(dc.de.vp)

start <- as.list(coef(dc.de.vp))
dc.pt.cte <- gnls(taninosol~B+A*(parm+1)^(-(log(2)/log(V+1))), start=start, data=dc)
summary(dc.pt.cte)

start <- as.list(coef(dc.pt.cte))
dc.pt.ve <- gnls(taninosol~B+A*(parm+1)^(-(log(2)/log(V+1))), start=start, data=dc, weights=varExp())
summary(dc.pt.ve)

start <- as.list(coef(dc.pt.ve))
dc.pt.vp <- gnls(taninosol~B+A*(parm+1)^(-(log(2)/log(V+1))), start=start, data=dc, weights=varPower())
summary(dc.pt.vp)

#-----
# Lista contendo o ajuste dos modelos.

situ <- expand.grid(modvar=c("Cte", "Exp", "Pot"), modmean=c("Q", "E", "P"), caso=levels(db$caso))
nom <- with(situ, paste(caso, modmean, modvar, sep="."))
situ$nom <- nom
L <- vector(mode="list", length=length(nom))
names(L) <- nom
ls()

L[["12H.N:Q:Cte"]] <- dc.mm.cte
L[["12H.N:E:Cte"]] <- dc.de.cte
L[["12H.N:P:Cte"]] <- dc.pt.cte
L[["12H.N:Q:Exp"]] <- dc.mm.ve
L[["12H.N:E:Exp"]] <- dc.de.ve
L[["12H.N:P:Exp"]] <- dc.pt.ve
L[["12H.N:Q:Pot"]] <- dc.mm.vp
L[["12H.N:E:Pot"]] <- dc.de.vp
L[["12H.N:P:Pot"]] <- dc.pt.vp

notconv <- sapply(L, is.null)
M <- L[!notconv]
ll <- sapply(M, logLik)
ll <- data.frame(nom=names(ll), ll=ll)
varPar <- do.call(c, sapply(M, function(i){ c(unclass(i$modelStruct$varStruct) )))

```

```

varPar <- data.frame(nom=names(varPar), varPar=varPar)
info <- merge(situ, ll, by="nom", all=TRUE)
info <- merge(info, varPar, by="nom", all=TRUE)

#-----
# Graficos.

l <- levels(situ$modvar); nl <- length(l)
key <- list(#x=1, y=1, space="top", title="Modelos para a variancia", cex.title=1.1, text=list(l), columns=nl,
  rectangles=list(col=mycol[1:nl]))
qc <- qchisq(0.95, df=1)/2
situ$llm <- NA
situ$llm[situ$modvar=="Cte"] <- qc

#-----
# Intervalo de confianca para os parametros.

summary(dc.mm.cte)$tTable
qn <- qnorm(0.975)
c0 <- lapply(M, function(i){ c0 <- as.data.frame(summary(i)$tTable[,1:2])
  names(c0) <- c("est","ste")
  c0$lwr <- c0[,1]-qn*c0[,2]
  c0$upr <- c0[,1]+qn*c0[,2]
  c0$param <- rownames(c0)
  c0 })
c0 <- ldply(c0)
names(c0)[1] <- "nom"
icpar <- merge(situ, c0, by="nom", all=TRUE)
icpar$param <- factor(icpar$param, levels=c("B","A","V"))
icpar$nom <- factor(icpar$nom)
with(icpar, tapply(lwr, param, function(x) head(sort(na.omit(x)),3)))
with(icpar, tapply(upr, param, function(x) tail(sort(na.omit(x)),3)))
xlim <- list(c(-1.5,1.5), c(0,3), c(0,11))
segplot(nom~lwr+upr|param, centers=est, data=icpar, layout=c(NA,1),
  draw.bands=FALSE, scales=list(x="free"), xlim=xlim,
  xlab=list(c("Assintota inferior","Tanino soluvel total","Tempo de meia-vida")),
  between=list(x=0.4, y=0.1))+
  layer(panel.abline(v=0, lty=2))+
  layer(panel.abline(h=1:nrow(icpar), lty=3, col="gray50"))

#-----
# Predicao.

p0 <- lapply(M, function(m){ pred <- data.frame(parm=seq(0,11,l=50)) pred$y <- predict(m, newdata=pred) pred })
p0 <- ldply(p0)
names(p0)[1] <- "nom"
pred <- merge(situ, p0, by="nom", all=TRUE)
pred$modelo <- with(pred, interaction(modmean, modvar, drop=TRUE))
xyplot(taninosol~parm|caso, data=db,
  jitter.x=TRUE, scales="free",
  ylab="Tanino soluvel", xlab="Periodo de armazenamento (dias))+
  as.layer(xyplot(y~parm|caso, groups=modelo, data=pred, type="l"))

#-----
# Analise dos residuos.

r0 <- lapply(M, function(m){ data.frame(res=residuals(m), respad=residuals(m, type="pearson"), fitted=fitted(m)) })
r0 <- ldply(r0)
names(r0)[1] <- "nom"
res <- merge(situ, r0, by="nom", all=TRUE)
res$modelo <- with(res, interaction(modmean, modvar, drop=TRUE))
qqmath(~respad|caso, groups=modelo, data=res,
  scales="free", auto.key=list(columns = 3) )
p1 <-
  qqmath(~respad|modvar+caso, groups=modmean, data=res,
    scales="same", auto.key=list(columns=3),
    ylab="Residuos padronizados",
    xlab="Quantis teoricos",
    prepanel=prepanel.qqmathline,
    panel=function(x, ...){
      panel.qqmathline(x, ...)
      panel.qqmath(x, ...)
    })
useOuterStrips(p1)

```

```
p2 <-
  xyplot(sqrt(abs(respad))-log(fitted)|modvar+caso, groups=modmean, data=res,
    scales="same", auto.key=TRUE, type=c("p","a"),
    xlab="Log do valores preditos",
    ylab="Raiz do valor absoluto dos residuos padronizados")
useOuterStrips(p2)
```

```
#-----
# Bandas de confianca
```

```
formula(dc.mm.cte)
formula(dc.de.ve)
formula(dc.pt.vp)
```

```
d3.Q <- deriv3(~B+A/(1+parm/V),
  c("B","A","V"),
  function(parm, B, A, V){NULL})
d3.E <- deriv3(~B+A*exp(-(log(2)/V)*parm),
  c("B","A","V"),
  function(parm, B, A, V){NULL})
d3.P <- deriv3(~B+A*(parm+1)^(-(log(2)/log(V+1))),
  c("B","A","V"),
  function(parm, B, A, V){NULL})
```

```
pband <- function(m, pred, d3){
  der <- do.call(d3, args=c(as.list(pred), as.list(coef(m))))
  F <- attr(der, "gradient")
  U <- chol(vcov(m))
  pred$sse <- sqrt(apply(F%*%t(U), 1, function(x) sum(x^2)))
  tval <- qnorm(p=c(lwr=0.025, fit=0.5, upr=0.975))
  me <- outer(pred$sse, tval, "**")
  pred <- cbind(pred, sweep(me, 1, der, "+"))
  pred
}
```

```
pband(dc.mm.cte, data.frame(parm=0:11), d3=d3.Q)
```

```
iQ <- grep("Q:", names(M))
iE <- grep("E:", names(M))
iP <- grep("P:", names(M))
```

```
pr <- data.frame(parm=seq(0,11,l=30))
```

```
jQ <- lapply(M[iQ], pband, pred=pr, d3=d3.Q)
jE <- lapply(M[iE], pband, pred=pr, d3=d3.E)
jP <- lapply(M[iP], pband, pred=pr, d3=d3.P)
```

```
pb <- c(jQ, jE, jP)
pb <- ldply(pb)
names(pb)[1] <- "nom"
```

```
predb <- merge(situ, pb, by="nom", all=TRUE)
predb$modelo <- with(predb, interaction(modmean, modvar, drop=TRUE))
predb <- predb[with(predb, order(caso, parm)),]
psub <- subset(predb, caso=="12H.N")
```

```
p3 <-
  xyplot(fit~parm|modmean+modvar, col=1, lty=c(1,2,2), as.table=TRUE,
    xlab="Periodo de armazenamento (dias)",
    ylab="Tanino soluvel",
    data=psub, type="l", alpha=0.4,
    prepanel=prepanel.cbH, cty="bands",
    ly=psub$lwr, uy=psub$upr,
    panel=panel.cbH)+
  as.layer(xyplot(taninosol~parm, data=subset(db, caso=="12H.N"),
    jitter.x=FALSE))
useOuterStrips(p3)
```

**ANEXO D** – Tabela com os dados referentes à casela 12h.N, utilizados no Anexo C.

| parm | trat | frio | rept | taninosol |
|------|------|------|------|-----------|
| 0    | 12h  | N    | 1    | 1.4       |
| 0    | 12h  | N    | 2    | 0.417     |
| 0    | 12h  | N    | 3    | 1.522     |
| 0    | 12h  | N    | 4    | 1.48      |
| 3    | 12h  | N    | 1    | 0.194     |
| 3    | 12h  | N    | 2    | 0.466     |
| 3    | 12h  | N    | 3    | 0.284     |
| 3    | 12h  | N    | 4    | 0.386     |
| 5    | 12h  | N    | 1    | 0.222     |
| 5    | 12h  | N    | 2    | 0.229     |
| 5    | 12h  | N    | 3    | 0.278     |
| 5    | 12h  | N    | 4    | 0.178     |
| 7    | 12h  | N    | 1    | 0.071     |
| 7    | 12h  | N    | 2    | 0.126     |
| 7    | 12h  | N    | 3    | 0.133     |
| 7    | 12h  | N    | 4    | 0.103     |
| 9    | 12h  | N    | 1    | 0.077     |
| 9    | 12h  | N    | 2    | 0.058     |
| 9    | 12h  | N    | 3    | 0.072     |
| 9    | 12h  | N    | 4    | 0.058     |
| 11   | 12h  | N    | 1    | 0.058     |
| 11   | 12h  | N    | 2    | 0.043     |
| 11   | 12h  | N    | 3    | 0.046     |
| 11   | 12h  | N    | 4    | 0.052     |

