Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”

Quadrados latinos balanceados para a vizinhança – planejamento e análise de dados sensoriais por meio da ADQ

Paula da Fonte Sanches

Dissertação apresentada para obtenção do título de Mestre em Ciências. Área de concentração: Estatística e Experimentação Agronômica

Piracicaba
2009

Paula da Fonte Sanches
Bacharel em Matemática

Quadrados latinos balanceados para a vizinhança – planejamento e análise de dados sensoriais por meio da ADQ

Orientador:
Prof . Dr. **SILVIO SANDOVAL ZOCCHI**

Dissertação apresentada para obtenção do título de Mestre em Ciências. Área de concentração: Estatística e Experimentação Agronômica

Piracicaba
2009

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA E DOCUMENTAÇÃO - ESALQ/USP

Sanches, Paula da Fonte
Quadrados latinos balanceados para a vizinhança - planejamento e análise de dados sensoriais por meio da ADQ / Paula da Fonte Sanches. - - Piracicaba, 2009.
102 p. : il.

Dissertação (Mestrado) - - Escola Superior de Agricultura "Luiz de Queiroz", 2009.
Bibliografia.

1. Análise de variância 2. Análise sensorial de alimentos 3. Estatística 4. Quadrados latino I. Título

CDD 519.535
S211q

"Permitida a cópia total ou parcial deste documento, desde que citada a fonte – O autor"

Dedicatória

A

Deus,

Jamais teria conseguido realizar este trabalho sem a

Sua graça.

Dedico este trabalho aos meus pais Paulo e Cleusa, por serem pessoas igualmente belas e admiráveis em essência, pelos estímulos que me impulsionaram a buscar vida nova a cada dia, meus agradecimentos por terem aceito se privar de minha companhia pelos estudos, concedendo a mim a oportunidade de me realizar ainda mais.

AGRADECIMENTOS

Agradeço a Deus pela oportunidade e pelo privilégio de tamanha experiência e, ao frequentar este curso, perceber e atentar para a relevância de temas que não faziam parte, em profundidade, de minha vida.

Aos meus irmãos Fernanda e Vitor, pela acolhida, desabafos e amor incondicional.

Ao meu Orientador Prof. Dr. Silvio Sandoval Zocchi, por seu profundo conhecimento e sabedoria, dos quais espero haver absorvido um pouco. Seu apoio, carinho e dedicação, mesmo em momentos difíceis, foram de suma importância à construção e conclusão de um texto coerente, claro e correto.

Aos funcionários, em especial Solange, Luciane, Eduardo, Jorge, Rosni e Expedita, pelas palavras de conforto, preocupação com os alunos e pela imensa boa vontade.

Aos professores do departamento, aos quais reitero grande parcela do meu conhecimento; em especial ao Prof. Dr. Décio Barbin, pela paciência, pelas palavras, pelo carinho, dedicação e entusiasmo demonstrado ao longo do curso.

Ao Prof. Dr. Antônio Francisco Iemma, pelo apoio, incentivo e amizade.

Ao meu querido amigo e companheiro Elton, que tanto me ajudou, incentivou, calou-se quando necessário e me confortou com palavras doces de carinho; por todo o apoio e ajuda recebida nesta jornada.

Aos amigos de pós graduação, pelas discussões sobre o andamento desta dissertação, em especial aos meus amigos, Cássio, Vanderly, Guilherme, Paula, Mariana e Michele, pela espontaneidade e alegria na troca de informações e materiais numa rara demonstração de amizade e solidariedade.

Enfim, agradeço a todos colegas de turma do Mestrado e aos demais idealizadores, coordenadores e funcionários da ESALQ.

À Coordenadoria para o Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de estudo.

SUMÁRIO

RESUMO 9
ABSTRACT 11
LISTA DE FIGURAS 13
LISTA DE TABELAS 15
1 INTRODUÇÃO 17
2 DESENVOLVIMENTO 19
2.1 Revisão de Literatura 19
3 MATERIAL E MÉTODOS 29
3.1 Material 29
3.2 Métodos 31
3.2.1 Planejamento 31
3.2.2 Procedimento de aleatorização para quadrados latinos balanceados para vizinhança 40
3.3 Modelo 41
4 RESULTADOS E DISCUSSÃO 53
4.1 Estudo de simulação 53
4.2 Experimento para a análise sensorial das aguardentes de cana-de-açúcar (cachaças). 57
5 CONCLUSÕES 61
REFERÊNCIAS 63
APÊNDICES 65

RESUMO

Quadrados latinos balanceados para a vizinhança - planejamento e análise de dados sensoriais obtidos por meio da ADQ

As avaliações sensoriais tomam cada vez mais sua posição de importância dentro dos centros produtores e vendedores de alimentos e de outros produtos. Nestes, o objetivo final dos trabalhos realizados nas áreas de desenvolvimento, produção e 'marketing' é o consumidor, cuja avaliação se baseia, principalmente, na aceitabilidade e custos dos produtos. Nesses experimentos, uma série de tratamentos é dada para cada provador, e um problema relevante é que a variável resposta dependa não só do tratamento aplicado atualmente, mas também do anterior seguido a ele, chamados de efeitos residuais. Visando uma melhor qualidade do produto, análises cada vez mais rigorosas são exigidas. Assim, um método frequêntemente utilizado é o da análise descritiva, que tem por objetivo descrever e avaliar a intensidade dos atributos sensoriais dos produtos avaliados, orientando eventuais modificações das características das mesmas a fim de atender às exigências do consumidor. Realizada por pessoas treinadas, com habilidade de discriminar, recebendo o nome de análise descritiva quantitativa (ADQ). Consequentemente, dadas as limitações quanto ao número de provas sucessivas de degustação e presença frequente de efeitos residuais, o planejamento e análise dos experimentos para ADQ adquirem importância fundamental. Assim, de modo a resolver o problema apresentado, Williams (1949) apresentou os delineamentos quadrados latinos balanceados para vizinhança que, de forma geral, garantem que os efeitos residuais dos tratamentos não exerçam influência sobre a comparação dos efeitos dos tratamentos. Métodos adequados de construção, aleatorização e análise, utilizando o método ADQ de tais delineamentos são descritos e adaptados para o problema. São apresentados, analisados e discutidos, ainda, os resultados de um experimento de análise sensorial de diferentes cachaças, planejado e conduzido pela autora. Assim, com os resultados obtidos, concluiu-se que, para o planejamento de ensaios para a análise descritiva quantitativa (ADQ), os quadrados latinos balanceados para vizinhança, com a última coluna repetida, são uma alternativa importante.

Palavras-chaves: Delineamento quadrado latino; Vizinhança balanceada; Carry-over; Análise sensorial; ADQ; Efeitos residuais

ABSTRACT

Latin squares balanced for the neighborhood - planning and analysis of sensory data obtained by the QDA.

The sensory evaluations are increasingly taking its position of importance within the centers producers and sellers of food and other products. In these, the ultimate goal of the work in the areas of development, production and 'marketing' is the consumer, whose evaluation is based mainly on the acceptability and cost of products. In these experiments, a series of treatments is given to each panelist, and a major problem is that the response depends not only on the treatment currently applied, but on the former followed by him. For a better quality product, analyzes increasingly stringent are required. Therefore, a method often used is descriptive analysis, which aims to describe and evaluate the intensity of sensory attributes of the products evaluated, guiding future modifications of the same characteristics in order to meet consumer demands.Performed by trained people, with ability to discriminate, receiving the name of quantitative descriptive analysis (QDA). Therefore, given the limitations on the number of successive tasting trials and frequent presence of residual effects, planning and analysing the experiments for QDA are fundamentaly important. Thus, in order to solve the problem presented, Williams (1949) presented the Latin square design balanced for neighborhood that, in general, ensuring that the residual effects of the treatments do not influence the comparison of treatment effects. Appropriate methods of construction, randomization and analysis, using the method of QDA such designs are described and adapted to the problem. Are presented, analyzed and discussed, yet, the results of an experiment of sensory analysis of different brandy, planned and conducted by the author. So with these results, we concluded that, for the planning of tests to quantitative descriptive analysis (QDA), the Latin squares balanced for neighborhoods, and repeated the last column, are an important alternative.

Keywords: Latin square design; Balanced neighborhood; Carry-over; Sensory analysis; QDA; Residual effects

LISTA DE FIGURAS

Figura 1 - Delineamentos em blocos incompletos balanceados para 10 provadores (blocos) e 5 tratamentos (0, 1, 2, 3 e 4) com 3 tratamentos por bloco, sem a aleatorização das ordens dos tratamentos (a) e após a aleatorização (b), mostrando a sequência de tratamentos por provador 25

Figura 2 - Delineamentos rotativos para 4 tratamentos, formado por três quadrados latinos 4×4 (a) e para 5 tratamentos, formado por dois quadrados latinos 5×5 (b), ambos sem aleatorização dos provadores 28

Figura 3 - Sequência da análise sensorial das cachaças 31

Figura 4 - Exemplo da ficha fornecida aos degustadores 31

Figura 5 - Quadrado latino balanceado para vizinhança para $t = 6$ tratamentos e esquema para obtenção das linhas do mesmo a partir da primeira em que os números em negrito correspondem aos tratamentos que precedem o tratamento 0 e os números sublinhados, precedidos pelo mesmo 33

Figura 6 - Quadrados latinos balanceados para vizinhança para $t = 4$ e $t = 6$ tratamentos, e método de obtenção das demais linhas a partir da primeira 35

LISTA DE TABELAS

Tabela 1 - Delineamento em blocos completos ao acaso com 10 blocos, ou provadores, e 5 tratamentos (0, 1, 2, 3 e 4), ou produtos, em diferentes ordens de degustação 24
Tabela 2 - Delineamento quadrado latino sem aleatorização de linhas e colunas, para 5 provadores, $t = 5$ tratamentos e 5 ordens de degustação 26
Tabela 3 - Delineamento formado por dois quadrados latinos considerando que tem-se 5 provadores, 5 tratamentos e 5 ordens de degustação, totalizando 10 provadores, após a aleatorização das linhas e colunas 26
Tabela 4 - Notas de aparência, aroma e sabor de cachaças de diferentes marcas (entre parênteses) emitidas por 10 provadores e no dia 4 de julho de 2009 30
Tabela 5 - Quadrado latino balanceado para a vizinhança com $t = 4$ 36
Tabela 6 - Quadrado latino balanceado para a vizinhança com $t = 6$ 36
Tabela 7 - Linhas iniciais de quadrados latinos balanceados para vizinhança, considerando-se diferentes números pares de tratamentos t 37
Tabela 8 - Delineamento balanceado para vizinhança com $t = 5$ tratamentos formado por dois quadrados latinos cujas primeiras linhas são apresentadas em negrito 38
Tabela 9 - Linhas iniciais para pares de quadrados latinos balanceados para vizinhança, considerando-se diferentes números ímpares de tratamentos t 40
Tabela 10 - Delineamento em quadrado latino balanceado para vizinhança com $t = 3$, em que os números entre parênteses representam os respectivos tratamentos 42
Tabela 11 - Quadro de análise de variância considerando efeito residual de tratamentos ajustado para demais efeitos 50
Tabela 12 - Quadro de análise de variância considerando efeito de tratamentos ajustado para demais efeitos 50
Tabela 13 - Delineamento quadrado latino balanceado para a vizinhança, para $t = 6$ tratamentos e $n = t = 6$ provadores 53

Tabela 14 - Porcentagem dos efeitos significativos ao nível de significância 5% em 10000 conjuntos de dados simulados, considerando-se ou não efeitos diretos e/ou residuais de tratamentos, e os modelos: D = usual, sem efeito residual de tratamento, DR = com ajuste sequencial de efeito direto e residual de tratamento, RD = com ajuste sequencial de efeitos residual e direto de tratamento e MO = ortogonal 56

Tabela 15 - Análises de variâncias das variáveis nota de aparência, aroma e sabor das cachaças considerando-se os modelos com ou sem efeitos residuais de tratamentos 58

Tabela 16 - Notas médias de aparência, aroma e sabor, e resultados do teste de Tukey considerando-se o nível de significância 5% (médias seguidas por pelo menos uma letra em comum não diferem entre si), utilizando-se o modelo com (MER) e sem (MU) efeito residual do tratamento anterior sobre o seguinte . 59

1 INTRODUÇÃO

As avaliações sensoriais tomam cada vez mais sua posição de importância dentro dos centros produtores e vendedores de alimentos e de outros produtos. Nestes, o objetivo final dos trabalhos realizados nas áreas de desenvolvimento, produção e "marketing"é o consumidor, cuja avaliação se baseia, principalmente, na aceitabilidade e custos dos produtos.

Tais avaliações iniciam-se dentro das indústrias, por meio de testes sensoriais que têm por objetivo responder a inúmeras perguntas como: quais são as características sensoriais dos produtos percebidas pelo consumidor? De que modo a qualidade do produto difere de outro? Quais são as consequências de uma modificação no processo, formulação, emba- lagem ou condições de armazenamento nos atributos do produto? Com relação à discriminação entre produtos: será que o consumidor nota a diferença? Quantos consumidores detectariam esta diferença? Estes produtos são diferentes? Qual a magnitude da diferença? Finalmente, em relação à preferência por um produto: quantas pessoas gostam deste produto? O produto é aceitável? Este produto é tão bom como o concorrente? Será que este produto é melhor que o anterior? Quais são as características mais apetecidas? Será o preferido?

Para responder tais perguntas, um dos métodos frequentemente utilizados é o da análise descritiva, que tem por objetivo descrever e avaliar a intensidade dos atributos sensoriais dos produtos avaliados, orientando eventuais modificações das características das mesmas a fim de atender às exigências do consumidor. Esta pode ser realizada por pessoas treinadas, selecionadas com base na consistência e na habilidade de discriminar, recebendo, neste caso, o nome de análise descritiva quantitativa ou simplesmente, ADQ. Nesta, dadas as limitações fisiológicas dos provadores, é possível entender a sua impossibilidade de comparar muitas amostras numa mesma sessão de análise sensorial, limitando, consequentemente, o número de amostras por sessão. Além disso, como os produtos são avaliados em provas sucessivas de degustação, pode haver influência do efeito residual de um produto sobre a avaliação do seguinte.

Consequentemente, dadas as limitações quanto ao número de provas sucessivas de degustação e presença frequente de efeitos residuais, o planejamento e análise dos experimentos para ADQ adquirem importância fundamental.

Em ensaios de rotação de culturas e ensaios com animais que recebem sequências de tratamentos diferentes, o problema do efeito residual também é bastante comum. Analogamente, nestes casos, o efeito residual de uma cultura sobre a seguinte ou o de um tratamento sobre o subsequênte podem ter consequências graves sobre as conclusões das análises dos resultados obtidos desses ensaios. Assim, de modo a resolver o problema apresentado, Williams (1949) apresentou os delineamentos quadrados latinos balanceados para vizinhança que, de forma geral, fornecem a ordem para a apresentação dos tratamentos para um conjunto de unidades experimentais de modo que cada tratamento ocorra com igual frequência. Desta forma, garantem que os efeitos residuais dos tratamentos não exerçam influência sobre a comparação dos efeitos dos tratamentos. Visando diminuir estes efeitos residuais, neste trabalho, tais delineamentos são descritos e adaptados para o problema de planejamento e análise de experimentos para ADQ.

São apresentados, analisados e discutidos, ainda, os resultados de um experimento de análise sensorial de diferentes cachaças, planejado e conduzido pela autora especialmente para este fim.

2 DESENVOLVIMENTO

2.1 Revisão de Literatura

O consumo de alimentos industrializados e o interesse por parte das indústrias na elaboração desses produtos têm aumentado significativamente no Brasil a partir da década de 70 (SALGADO; CARRER; DANIELI, 2006) e paralelamente, inúmeros métodos estatísticos aplicados à engenharia vêm sendo desenvolvidos.

A estatística aplicada à engenharia é um ramo da estatística utilizada no controle de processos de produtos e serviços, assim como no planejamento de novas estratégias de produção, vendas, etc. Na engenharia de alimentos, é utilizada na análise sensorial, para avaliar a aceitação, pelo público, de um produto manufaturado e na produção, para acompanhar a estabilidade dos processos, por meio de cartas de acompanhamento co- nhecidas como cartas de controle estatístico de processo. É utilizada, ainda, na calibração e análise de equipamentos de medição, assim como na verificação da condição de uso dos meios de medição.

Segundo Bolini (2000), a análise sensorial é uma ciência que utiliza os sentidos humanos (visão, olfato, tato, paladar audição), para avaliar as características de um produto. É uma ferramenta intensamente utilizada pelas indústrias de alimentos, bebidas, cosméticos, perfumes, produtos de limpeza, automóveis e outros produtos, tanto no desenvolvimento como na garantia e otimização da qualidade de seus produtos. É aplicada tanto na pesquisa e desenvolvimento de novos produtos, quanto no controle de qualidade, ou seja: (i) no controle do processo de fabricação, isto é, da matéria-prima, de variações no processamento e de variação de ingredientes; (ii) no controle de produto acabado, de modo a verificar possíveis perdas na qualidade sensorial do produto devido ao armazenamento, determinar limites entre níveis de qualidade, selecionar métodos instrumentais que apresentem boa correlação com atributos sensoriais do alimento; (iii) no controle de mercados por meio de estudos comparativos entre produtos concorrentes e estudos de aceitação.

Para que os resultados da avaliação sensorial sejam confiáveis, muitos fatores precisam ser rigorosamente controlados, envolvendo o laboratório de análise sensorial, os materiais, equipamentos e os provadores, este último, no caso de utilização da metodologia

ADQ.

Uma vez obtidos os resultados de uma análise sensorial, parte-se para a análise estatística, geralmente enfocada nos testes de hipóteses envolvendo diferentes tratamentos. Nesses testes, segundo Lea, Naes e Rodbotten (1998), os provadores podem ser tratados como fixos, isto é, representantes de um conjunto com as mesmas características destes e escolhidos pelo pesquisador, ou como aleatórios, ou seja, representantes de um conjunto aleatório da população dos provadores. Esta distinção é importante porque determina a forma como a análise de variância deve ser feita e, por conseguinte, quais são os tipos de conclusões que podem ser tiradas a partir da análise. Resumidamente, podemos dizer que tratar provadores como representantes aleatórios nos permite generalizar as conclusões dos testes de hipóteses para a população geral de pessoas.

Os provadores, entretanto, frequentemente foram previamente analisados e selecionados pelo pesquisador e têm formações específicas, ou seja, características semelhantes. Assim, os provadores não podem ser tratados como representantes de uma população aleatória, sendo tratados como fixos no modelo. Logo, é importante salientar que a população em questão se refere à população de pessoas com a mesma capacidade para passar pelo mesmo teste e com a mesma formação que os provadores reais. Além disso, para cada caso devem ser definidos o tipo de teste, as característica da equipe, as condições da análise, o delineamento experimental e a análise estatística.

Com relação à condução do experimento, segundo Bolini (2000), as condições básicas para a apresentação das amostras para a análise sensorial são as padronizações do preparo, da apresentação, da quantidade, do recipiente, da temperatura, da codificação, da ordem de apresentação, do número de amostras a serem avaliadas por teste e do horário da análise. O laboratório, por sua vez, também precisa ser padronizado, ou seja, as cabines individuais devem ser confortáveis, a iluminação deve ser apropriada, o ambiente deve estar livre de odores e ruídos e deve estar isolado da área de preparo das amostras. A ficha de avaliação deve ser elaborada de forma adequada ao teste a ser realizado e a seleção e formação dos provadores podem ser feitas de duas maneiras, visando-se a análise descritiva quantitativa (ADQ) ou o teste afetivo. Os testes afetivos têm como objetivo medir, por meio de uma escala hedônica, atitudes subjetivas como aceitação ou preferência de produtos, de forma individual

ou em relação a outros. Essa escala, previamente estabelecida, varia gradativamente com base nos atributos gosta e desgosta (CHAVES e SPROESSER, 1996). Para a ADQ, os provadores devem ser treinados para a realização de testes discriminativos e analíticos e para o teste afetivo, os provadores devem representar a população dos consumidores do produto. Em ambos os testes, após a coleta dos dados, é feita a validação dos resultados, que se baseia na sensibilidade e capacidade de reprodução dos seus julgamentos.

Na seleção de uma equipe sensorial, segundo o autor, os provadores devem reconhecer os gostos básicos: doce, salgado, ácido, amargo, umami (sabor de substâncias como os sais de L-glutamato, importante elemento de sabor em alimentos naturais sendo o principal sabor de pratos japoneses e de outros produtos orientais). Além disso, devem estar com boa saúde, sem infecções bucais ou nasais e não devem estar usando aparelhos ortodônticos ou dentaduras. Devem possuir apetite normal, demonstrar capacidade em reproduzir os julgamentos, possuir boa memória sensorial e não ter aversão aos produtos teste. Precisam, ainda, ter disponibilidade de tempo para realizar os testes de forma tranquila. No que se refere à idade, as crianças ou idosos são selecionados somente para estudos específicos.

Quanto aos fatores que podem influenciar negativamente na avaliação sensorial, tem-se os erros psicológicos (fatores de personalidade ou atitude, relacionados com motivação) e os de ordem fisiológica (estresse, condições da amostra, adaptação, patologias, tratamentos medicamentosos e sensibilidade). Outros fatores, que podem influenciar positivamente, estão relacionados com a motivação em participar do projeto, que pode ser estimulada por meio da apresentação prévia do mesmo e apresentação dos resultados ao final dos projetos, elogiando, realizando críticas construtivas e até mesmo fornecendo recompensas aos participantes.

De modo a treinar e selecionar pessoas para descrever sensorialmente as características de um produto com precisão em termos matemáticos, foi especialmente criada a análise descritiva quantitativa (ADQ). Esta, segundo Moskowitz (1988), permite quantificar a variabilidade dessas características e comparar diferentes produtos ou tratamentos e é principalmente empregada quando se necessita avaliar os atributos sensoriais de um produto (MAGALHÃES, 1996), como a aparência, o sabor e a textura (DUTCOSKY, 1996). Como a ADQ normalmente utiliza uma equipe de 10 a 12 provadores que são essencialmente selecionados e treinados para isso, este método sensorial descritivo apresenta vantagens como: (i)

maior confiança no julgamento e resultados obtidos; (ii) desenvolvimento de uma linguagem descritiva objetiva mais próxima à linguagem do consumidor; (iii) desenvolvimento consensual da terminologia descritiva a ser utilizada, o que implica em maior concordância de julgamentos entre os provadores (BEHRENS e SILVA, 2000). Ressalta-se que a maior confiança advém do fato de os provadores serem treinados e de os tratamentos serem analisados por todos os provadores em pré-testes às cegas, de modo a calibrá-los.

Independente de os provadores terem sido selecionados pela metodologia ADQ ou não, um fator importante que deve ser levado em conta é a dependência entre as avaliações emitidas pelos provadores na avaliação sensorial sequencial dos diferentes produtos ou tratamentos. Este fato ocorre como consequência da ordem de servir sequencial monádica, isto é, em que os produtos (ou tratamentos) e respectivas fichas de avaliação são apresentados um de cada vez, sequencialmente.

Embora, nesse caso, as avaliações sejam feitas independentemente, as respostas, no entanto, podem ter alguma dependência cujos impactos sobre as conclusões dos testes de hipóteses de interesse não é totalmente clara (STONE e SIDEL, 1993).

Além disso, os participantes dos ensaios individuais necessariamente têm experiência prévia como utilizadores do produto e, deste modo, suas respostas irão refletir essa experiência ou conhecimento prévio, que pode ser também originada durante a seleção dos provadores para a ADQ. A utilização de sequências pré especificadas de apresentação dos produtos, ou tratamentos, podem, no entanto, minimizar o efeito tanto dessa experiência prévia como da dependência ou, pelo menos, distribuir mais uniformemente o seu efeito em todos os produtos provados.

Outro ponto importante que deve ser ressaltado em análise sensorial ocorre quando um degustador experimenta um determinado produto ou tratamento, e prova outro logo em seguida. Neste caso, frequentemente há um efeito residual do primeiro sobre o outro que deve ser levado em conta na análise estatística, de modo a estimá-lo. Resumidamente, tais efeitos podem ser de aprendizado ou de fadiga, tendo, respectivamente, efeito positivo ou negativo na resposta. Além disso, em se tratando de humanos, um efeito negativo do primeiro tratamento pode condicionar o provador a produzir um resultado negativo no segundo tratamento. Por outro lado, uma resposta positiva no primeiro tratamento pode fazer com que o

provador aumente as chances do tratamento subsequente apresentar um resultado positivo, mesmo no caso de placebo.

De modo a minimizar a influência dos efeitos residuais sobre os efeitos dos tratamentos, o planejamento cuidadoso dos experimentos assume, assim, papel fundamental. Esses experimentos são usados para selecionar equipes, avaliar a habilidade e consistência dessas equipes, determinar e controlar a qualidade dos alimentos e averiguar a preferência do consumidor (MORAES, 1993).

Há uma vasta literatura que trata especificamente do planejamento e análise de experimentos dentre os quais ressaltam-se os trabalhos de Cochran e Cox (1957), Steel e Torrie (1980), Campos (1984), Montgomery (1984), Banzatto e Kronka (1989), Pimentel-Gomes (1990), Barbin (2003), Pimentel-Gomes e Garcia (2002). São apresentados a seguir, os delineamentos mais comumente utilizados para a ADQ.

Como primeira opção, os blocos completos casualizados (DBC) apresentam todos os tratamentos por bloco (ou provadores) e são aplicados quando, teoricamente, não há problema de fadiga sensorial do julgador em provar todos os tratamentos. Esse delineamento é eficiente quando o analista está seguro de que os provadores são consistentes em avaliar a amostra, mas reconhece que eles podem usar diferentes partes da escala de acordo com as suas percepções. Do ponto de vista estatístico, considera-se, neste caso, que não há efeito de interação entre blocos (provadores) e tratamentos.

A tabela 1 mostra um exemplo de delineamento em blocos completos ao acaso para 10 provadores (blocos) e 5 tratamentos (0; 1; 2; 3 e 4), ou produtos, aleatoriamente apresentados aos mesmos. Note que nesse caso particular, o tratamento 0 nunca será oferecido na segunda ordem e será, no entanto, oferecido 5 vezes na quarta ordem. Isso ressalta o fato de que se assume que a ordem de apresentação dos tratamentos aos provadores não é importante.

Quando por questão de fadiga sensorial, os provadores não conseguem provar o grupo completo de tratamentos, são geralmente utilizados os delineamentos de blocos incompletos balanceados, que não incluem todos os tratamentos por bloco.

Nos delineamentos de blocos incompletos balanceados os provadores avaliam somente q dos t tratamentos, sendo $q < t$, e considerando-se todos os provadores, cada tratamento é avaliado em igual número de vezes e todos os pares de tratamentos são avaliados

Tabela 1 - Delineamento em blocos completos ao acaso com 10 blocos, ou provadores, e 5 tratamentos (0, 1, 2, 3 e 4), ou produtos, em diferentes ordens de degustação

Bloco ou	Ordem				
Provador	1	2	3	4	5
1	4	3	0	1	2
2	4	2	1	0	3
3	3	2	1	0	4
4	2	1	3	0	4
5	0	3	1	4	2
6	1	2	3	0	4
7	4	3	0	2	1
8	0	4	1	2	3
9	4	2	1	3	0
10	2	1	3	0	4

em iguais números de vezes. Desta forma assegura-se que a média de cada amostra é estimada com igual precisão.

A figura 1 apresenta o delineamento em blocos incompletos balanceados para 10 blocos (ou provadores) e 5 tratamentos com 3 tratamentos por bloco e seis repetições por tratamento. A aleatorização dos tratamentos dentro de cada bloco, ou analogamente, das ordens de apresentação dos tratamentos aos provadores deve ser então realizada, podendo gerar o delineamento apresentado na figura 1(b).

Mais uma vez, pode-se notar que os tratamentos não vão ocorrer necessariamente, com as mesmas frequências dentro de cada ordem. Assim, também neste caso, assume-se que a ordem de degustação das amostras não é importante e que não há efeito de interação entre provadores e tratamentos.

De modo a garantir que todos os tratamentos apareçam com iguais frequências para todas as ordens, pode-se utilizar os delineamentos chamados quadrados latinos. Um quadrado latino de ordem t é uma matriz $t \times t$ preenchida com t diferentes letras ou números, que ocorrem, no máximo, uma vez em cada linha ou coluna. É considerado reduzido ou

Bloco ou Provador	Tratamento				
	0	1	2	3	4
1	x	x	x		
2	x	x		x	
3	x	x			x
4	x		x	x	
5	x		x		x
6	x			x	x
7		x	x	x	
8		x	x		x
9		x		x	
10			x	x	x

(a)

Bloco ou Provador	Tratamento		
	0	1	2
1	2	1	0
2	1	3	0
3	0	1	4
4	3	0	2
5	2	4	0
6	3	0	4
7	1	2	3
8	4	1	2
9	3	1	4
10	3	4	2

(b)

Figura 1 - Delineamentos em blocos incompletos balanceados para 10 provadores (blocos) e 5 tratamentos (0, 1, 2, 3 e 4) com 3 tratamentos por bloco, sem a aleatorização das ordens dos tratamentos (a) e após a aleatorização (b), mostrando a sequência de tratamentos por provador

padrão se as letras se dispõem em ordem alfabética na primeira linha e na primeira coluna ou se os números estiverem na sua ordem natural na primeira linha e primeira coluna como ilustra a tabela 2, com o delineamento quadrado latino padrão para $t = 5$ tratamentos ou produtos. Neste caso, por definição, cada tratamento é apresentado uma vez em cada ordem. Logo, podem-se estimar, além dos efeitos de provadores e de tratamentos, os efeitos de ordem de degustação ou de apresentação dos tratamentos aos provadores.

Apesar da aparente pouca flexibilidade dos quadrados latinos pelo fato de o número de tratamentos ser, por definição, igual ao número de provadores, pode-se, entretanto, repeti-los. Isto pode ser feito, segundo Montgomery (1976), usando-se: (i) os mesmos provadores e ordens em cada repetição; (ii) os mesmos provadores, mas diferentes ordens em cada repetição (ou equivalentemente, utilizar as mesmas ordens, mas diferentes provadores), ou (iii) diferentes provadores e diferentes ordens. A tabela 3 apresenta, como ilustração, o delineamento formado por dois quadrados latinos 5×5 com aleatorização de suas linhas e

Tabela 2 - Delineamento quadrado latino sem aleatorização de linhas e colunas, para 5 provadores, $t = 5$ tratamentos e 5 ordens de degustação

Linha ou	Coluna ou Ordem				
Provador	1	2	3	4	5
1	0	1	2	3	4
2	1	2	3	4	0
3	2	3	4	0	1
4	3	4	0	1	2
5	4	0	1	2	3

colunas, resultando em um delineamento que poderia ser utilizado para análises sensoriais.

Tabela 3 - Delineamento formado por dois quadrados latinos considerando que tem-se 5 provadores, 5 tratamentos e 5 ordens de degustação, totalizando 10 provadores, após a aleatorização das linhas e colunas

Linha ou	Coluna ou Ordem				
Provador	1	2	3	4	5
1	3	2	1	4	0
2	1	4	0	2	3
3	4	3	2	0	1
4	0	3	4	1	2
5	2	1	0	3	4
6	2	0	1	3	4
7	4	2	3	0	1
8	3	1	2	4	0
9	1	0	4	2	3
10	0	4	3	1	2

Até agora, no entanto, todos os delineamentos apresentados consideram que não há efeito residual de um tratamento sobre o seguinte, na sequência de degustações. Uma tentativa de solucionar esse problema é utilizar os quadrados latinos balanceados para a vizinhança apresentados por Willians (1949). Outra solução é utilizar os chamados ensaios

rotativos ("change-over"ou "switch-over") apresentados por Petterson e Lucas (1962), que são comumente utilizados em experimentos com vacas leiteiras e em ensaios cíclicos em Medicina e Psicologia. No primeiro caso, segundo Pimentel-Gomes (1990), toma-se cada animal como sendo um bloco, com diversas parcelas, dadas pelos períodos sucessivos de produção de leite, cada um deles com uma semana de duração. Os tratamentos atribuídos a todos os animais são diferentes e, eventualmente, no fim do ensaio, o animal volta a receber o tratamento inicial como ocorre no experimento rotativo ("switch-back"). De acordo com o autor, entretanto, como defeito fundamental deste tipo de ensaio, há a possibilidade de existência de efeito residual de um tratamento sobre o tratamento subsequente. Este defeito pode, no entanto, ser sanado desprezando-se a produção do animal na primeira semana que se segue à mudança de tratamento ou incluindo-se o efeito residual no modelo de análise.

Embora o autor considere que haja o defeito citado, a possibilidade de se analisarem os resultados considerando-se os efeitos residuais, torna os ensaios rotativos potencialmente úteis em análise sensorial. A figura 2 apresenta dois delineamentos rotativos úteis para análise sensorial com 4 e 5 tratamentos, propostos por Petterson e Lucas (1962). Note que a última coluna do delineamento para 4 tratamentos, pode ser retirada garantindo, ainda, o balanceamento para a vizinhança, característica fundamental para a análise de situações em que há efeito residual de um tratamento sobre o seguinte.

Convém ressaltar, ainda, que, segundo Bailey (2005), se os efeitos de vizinhança forem ignorados e a análise for feita da maneira usual, isto é, sem considerar os efeitos residuais, os estimadores de efeitos diretos serão viesados. No entanto, um modelo para vizinhança balanceada, tem-se estimadores menos viesados dos efeitos diretos.

Bloco ou Provador	Ordem			
	1	2	3	4
1	0	1	2	3
2	1	0	3	2
3	2	3	0	1
4	3	2	1	0
5	0	2	3	1
6	1	3	2	0
7	2	0	1	3
8	3	1	0	2
9	0	3	1	2
10	1	2	0	3
11	2	1	3	0
12	3	0	2	1

(a)

Bloco ou Provador	Ordem				
	1	2	3	4	5
1	0	1	3	4	2
2	1	2	4	0	3
3	2	3	0	1	4
4	3	4	1	2	0
5	4	0	2	3	1
6	0	2	1	4	3
7	1	3	2	0	4
8	2	4	3	1	0
9	3	0	4	2	1
10	4	1	0	3	2

(b)

Figura 2 - Delineamentos rotativos para 4 tratamentos, formado por três quadrados latinos 4 $\times$ 4 (a) e para 5 tratamentos, formado por dois quadrados latinos 5 $\times$ 5 (b), ambos sem aleatorização dos provadores

3 MATERIAL E MÉTODOS

3.1 Material

O conjunto de dados utilizado neste trabalho provém de um experimento conduzido pela autora para estudar o perfil sensorial de 5 diferentes marcas de aguardente de cana-de-açúcar dispostas no mercado, codificadas como:

- tratamento 0 - aguardente composta com carvalho, o que dá coloração amarelada e sabor que lembra o do *whisky* por causa do malte impregnado na madeira. Ingredientes: destilado simples de caldo de cana-de-açúcar, extrato natural de carvalho, aroma idêntico ao natural de carvalho, açúcar e corante caramelo, com 38% vol. de álcool.

- tratamento 1 - aguardente destilada de cana-de-açúcar, envelhecida 2 anos em tonéis de bálsamo, o que resulta em coloração amarelada e numa cachaça de gosto amadeirado, adquirindo sabor e *bouquet* especiais, com 39% vol. de álcool.

- tratamento 2 - aguardente de cana-de-açúcar envelhecida em tonéis de madeira e duplamente filtrada. Ingredientes: aguardente de cana, açúcar e água, com 39% vol. de álcool.

- tratamento 3 - aguardente de cana-de-açúcar líder de mercado. Ingredientes: aguardente de cana-de-açúcar e açúcar, com 39% vol. de álcool.

- tratamento 4 - aguardente de cana-de-açúcar, com preço inferior no mercado. Ingredientes: destilado simples do caldo de cana-de-açúcar e açúcar, com 39% vol. de álcool.

O delineamento utilizado foi o dos quadrados latinos balanceados com a repetição do último tratamento, como proposto por Cochran e Cox (1957), apresentado na tabela 4. O estudo de aceitação das amostras de aguardentes foi em relação à aparência, aroma e sabor, e as amostras foram servidas aos provadores individualmente, na sequência apresentada na tabela 4, em copos transparentes sem odor. Os copos foram apresentados um a um no momento do teste, para análise da aparência, aroma e sabor.

As análises foram realizadas por 10 provadores, utilizando-se escala hedônica de nove pontos (1 = desgostei extremamente, ..., 5 = nem gostei e nem desgostei, ..., 9 =

Tabela 4 - Notas de aparência, aroma e sabor de cachaças de diferentes marcas (entre parênteses) emitidas por 10 provadores e no dia 4 de julho de 2009

Provadores	Ordem					
	1	2	3	4	5	6
1	9, 8, 5 (0)	8, 8, 6 (1)	9, 6, 6 (4)	8, 9, 4 (2)	8, 8, 8 (3)	8, 7, 7 (3)
2	7, 6, 5 (1)	8, 6, 5 (2)	8, 6, 5 (0)	7, 8, 7 (3)	8, 7, 8 (4)	7, 9, 8 (4)
3	8, 8, 7 (2)	7, 8, 6 (3)	8, 9, 6 (1)	9, 8, 7 (4)	9, 8, 7 (0)	9, 8, 8 (0)
4	8, 6, 7 (3)	8, 6, 8 (4)	7, 8, 7 (2)	9, 7, 7 (0)	7, 9, 7 (1)	9, 9, 8 (1)
5	8, 6, 8 (4)	7, 7, 6 (0)	8, 9, 9 (3)	9, 8, 9 (1)	8, 9, 8 (2)	7, 8, 9 (2)
6	8, 6, 6 (0)	7, 9, 9 (4)	8, 9, 7 (1)	9, 8, 7 (3)	8, 8, 8 (2)	8, 9, 7 (2)
7	8, 8, 6 (1)	9, 6, 5 (0)	7, 9, 8 (2)	9, 7, 6 (4)	8, 9, 7 (3)	9, 9, 7 (3)
8	7, 8, 6 (2)	8, 9, 7 (1)	8, 7, 8 (3)	9, 9, 7 (0)	8, 8, 9 (4)	7, 9, 9 (4)
9	8, 7, 7 (3)	7, 6, 7 (2)	8, 7, 8 (4)	8, 9, 5 (1)	9, 6, 5 (0)	7, 8, 7 (0)
10	8, 6, 8 (4)	7, 9, 7 (4)	9, 7, 6 (0)	8, 9, 7 (2)	9, 9, 7 (1)	9, 8, 6 (1)

gostei extremamente). A tabela 4, apresenta, ainda, as notas dadas pelos provadores em relação a cada uma das características observadas. Professores, estudantes e funcionários da Escola Superior de Agricultura Luiz de Queiroz - ESALQ, com idade compreendida entre 20 e 30 anos, com bom conhecimento em destilados, formaram a equipe de provadores. Foram selecionados por apreciarem e terem conhecimento do produto, representando assim o mercado alvo, ou seja, consumidores ou consumidores potenciais do produto testado. Entre cada degustação, cada provador colocava um pequeno pedaço de bolacha água e sal na boca, de modo a diminuir os efeitos de uma degustação sobre a outra.

A figura 3 apresenta a sequência e forma de avaliação dos atributos aparência, aroma e sabor, utilizados no experimento e a figura 4 apresenta um exemplo de ficha fornecida para um provador, no momento da degustação.

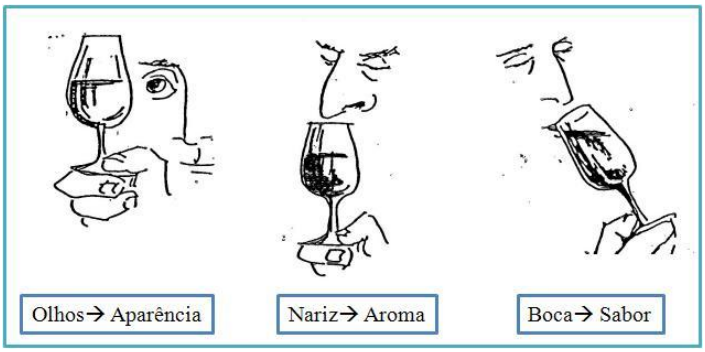

Figura 3 - Sequência da análise sensorial das cachaças

Provador	Cachaça	Aparência	Aroma	Sabor
1	1			
1	2			
1	3			
1	4			
1	5			
1	6			

Figura 4 - Exemplo da ficha fornecida aos degustadores

3.2 Métodos

3.2.1 Planejamento

São apresentados, a seguir, métodos de construção de delineamentos balanceados para a estimação de efeitos residuais de um único tratamento anterior. Nesse caso, segundo Williams (1949), quando o número t de tratamentos é par, é possível obter um delineamento balanceado com t repetições, ou provadores. No entanto, quando t é ímpar, são necessárias $2t$ repetições, ou provadores.

Para que se possa considerar somente o efeito residual do tratamento imediatamente anterior, deve ser levada em conta, na avaliação de efeitos residuais, que a condição de balanceamento seja satisfeita, ou seja, que cada tratamento seja precedido com igual frequência por todos os outros tratamentos. São considerados, neste trabalho, inicialmente os delineamentos em que cada tratamento é aplicado uma única vez para cada provador,

balanceados para o efeito do tratamento subsequente, bem como para o tratamento anterior. Neste caso, segundo Williams (1949), as condições para que um delineamento seja balanceado são: (1) Cada tratamento deve ser precedido por cada outro tratamento com a mesma frequência; (2) Cada tratamento deve ocorrer com igual frequência em cada posição, em ordem de aplicação para os provadores, de modo que o tratamento não seja afetado pelos possíveis efeitos de ordem de aplicação.

De modo a atender a essas condições, o número de provadores deve ser um múltiplo do número de tratamentos. Se há t tratamentos, existem $t(t-1)$ pares ordenados de tratamentos. Será mostrado que, quando o número t de tratamentos é par, o balanceamento pode ser atingido com um número mínimo t de provadores (ou linhas), e quando t é ímpar, com um número mínimo $2t$ de provadores (ou linhas). Segundo Williams (1949), delineamentos balanceados podem ser derivados de quadrados latinos cíclicos de tamanho t, em que os índices das linhas representam os provadores, os índices das colunas, as ordens de aplicações e os números ou símbolos, os tratamentos. No caso de t ser ímpar, são necessários, dois quadrados.

Caso I: Número par de tratamentos.

Seja cada tratamento representado por uma das classes de resíduos módulo t incluindo zero, ou seja, o conjunto de t tratamentos representados pelo grupo Z_t de inteiros módulo t. Neste caso, a primeira condição é satisfeita exigindo-se que as diferenças entre todos os números de dois tratamentos adjacentes seja o conjunto de todos os valores de 1 a $t-1$ com igual frequência. Se cada diferença ocorre na primeira linha do quadrado latino e as linhas sucessivas são obtidas por adição de uma unidade a cada elemento da linha anterior, o quadrado irá satisfazer às duas condições exigidas.

O problema de planejamento reside, então, na determinação das linhas iniciais de tais quadrados latinos, cuja solução geral para t tratamentos é dada pela sequência:

$$0 \quad 1 \quad t-1 \quad 2 \quad t-2 \quad 3 \quad t-3 \quad \ldots \quad t/2 \tag{1}$$

cujas diferenças sucessivas entre os elementos de 2 colunas consecutivas, em módulo t são

dados pela sequência:

$$1 \quad t-2 \quad 3 \quad t-4 \quad 5 \quad t-6 \quad 7 \quad t-8 \quad \ldots \tag{2}$$

Note que os valores ímpares em (1) estão em ordem crescente, alternando com os valores pares que estão em ordem decrescente, incluindo-se cada valor de diferença uma única vez, garantindo as duas condições. Logo, os quadrados latinos desenvolvidos a partir da linha inicial (1) são, portanto, balanceados para efeitos residuais de tratamentos e as demais linhas do quadrado latino são obtidas adicionando-se uma unidade a cada elemento da linha anterior em módulo t.

A figura 5 apresenta o quadrado latino balanceado para efeitos residuais de tratamentos com $t = 6$ tratamentos cuja primeira linha é dada por (1) e demais linhas obtidas pela adição sequencial de uma unidade em módulo 6.

Provadores	Ordem						
	1	2	3	4	5	6	
1	0	1	5	2	4	3	linha 1
2	1	**2**	0	3	5	4	(linha 1 + 1)(mod6) = (linha 1 + 1)(mod6)
3	2	3	1	**4**	0	5	(linha 2 + 1)(mod6) = (linha 1 + 2)(mod6)
4	3	4	2	5	**1**	0	(linha 3 + 1)(mod6) = (linha 1 + 3)(mod6)
5	4	5	**3**	0	2	1	(linha 4 + 1)(mod6) = (linha 1 + 4)(mod6)
6	**5**	0	4	1	3	2	(linha 5 + 1)(mod6) = (linha 1+ 5)(mod6)

Figura 5 - Quadrado latino balanceado para vizinhança para $t = 6$ tratamentos e esquema para obtenção das linhas do mesmo a partir da primeira em que os números em negrito correspondem aos tratamentos que precedem o tratamento 0 e os números sublinhados, precedidos pelo mesmo

Convém comentar que a partir da linha inicial, a obtenção das demais linhas pode ser feita alternativamente, acrescentando-se ou subtraindo-se um número inteiro a cada elemento da linha anterior em módulo t, de tal forma que os números iniciais das t linhas

formem o conjunto $0, 1, \ldots, t-1$. Esse procedimento, no entanto, é equivalente às linhas de índices $2, 3, \ldots, t$, como ilustra a figura 5.

Para verificar que o quadrado latino da figura 5 é balanceado para vizinhança, considere, inicialmente o tratamento 0. Nesse caso, cada outro tratamento precede e é precedido pelo tratamento 0 exatamente uma vez em cada linha, o que pode ser facilmente observado na figura 5, por meio dos tratamentos em negrito, que precedem o tratamento 0 e pelos sublinhados, precedidos pelo 0. Analogamente, pode-se facilmente verificar o balanceamento considerando-se os demais tratamentos.

Outro método de construção de um delineamento balanceado, também proposto por Williams (1949), é aplicável somente para os casos em que $t+1$ é um número primo, ou seja, para $t \epsilon \{2, 4, 6, 10, 12, 16, 18, 22, \ldots\}$. Neste caso, os tratamentos podem ser representados por um conjunto de classes de restos não nulos em módulo $t+1$, e a primeira linha do quadrado latino consiste dos restos dispostos em ordem crescente, ou seja, pela sequência de tratamentos $1, 2, 3, \ldots, t$. As linhas subsequentes podem ser então obtidas pela multiplicação dos elementos da primeira linha, por $2, 3, \ldots$ até t em módulo $t+1$. Se $t+1$ for primo, então cada tratamento será representado uma única vez em cada coluna. Além disso, as diferenças entre os elementos sucessivos de qualquer linha são todas iguais às diferenças dos dois elementos iniciais. Assim, entre qualquer tratamento t e o tratamento anterior, todas as diferenças, exceto t, ocorrem uma vez em cada linha que não começa com t. O tratamento t é, entretanto, precedido uma vez por cada um dos outros tratamentos, e o delineamento é, portanto, balanceado. A figura 6 apresenta os quadrados latinos balanceado para $t = 4$, e $t = 6$ e os respectivos métodos de construção.

Note que, se x é um resto cuja t-ésima potência é a menor potência congruente a 1 módulo $t+1$, então todas as potências $x^1, x^2, \ldots, x^t$ são diferentes e cada um dos restos 1 a t podem ser representados como uma potência de x . Assim, se os tratamentos são agora representados pelos índices de x , as diferenças entre os elementos correspondentes de colunas adjacentes serão constantes. No entanto, como o delineamento é balanceado, cada uma das diferenças de 1 a $t-1$ deve ser representada em cada linha, em que é possível notar que os restos estão sendo tomados em módulo $t+1$ e não módulo t. Mais diretamente, a última afirmação decorre do fato de que os valores de restos sucessivos não nulos são todos diferentes,

Provadores	Ordem				
	1	2	3	4	
1	1	2	3	4	linha 1
2	2	4	1	3	linha 2 = (2 x linha 1)(mod5)
3	3	1	4	2	linha 3 = (3 x linha 1)(mod5)
4	4	3	2	1	linha 4 = (4 x linha 1)(mod5)

Provadores	Ordem						
	1	2	3	4	5	6	
1	1	2	3	4	5	6	linha 1
2	2	4	6	1	3	5	linha 2 = (2 x linha 1)(mod7)
3	3	6	2	5	1	4	linha 3 = (3 x linha 1)(mod7)
4	4	1	5	2	6	3	linha 4 = (4 x linha 1)(mod7)
5	5	3	1	6	4	2	linha 5 = (5 x linha 1)(mod7)
6	6	5	4	3	2	1	linha 6 = (6 x linha 1)(mod7)

Figura 6 - Quadrados latinos balanceados para vizinhança para $t = 4$ e $t = 6$ tratamentos, e método de obtenção das demais linhas a partir da primeira

quando o módulo é primo. Para $t = 4$ tem-se que $x = 2$ é um resto cuja quarta potência é a menor potência congruente a 1, em módulo 5, isto é, $2^4 = 16 \equiv 1$ (mod5). Logo, tem-se que $2^0 = 1$; $2^1 = 2$; $2^3 = 8 \equiv 3(\text{mod}5)$; $2^2 = 4$, cujas potências estabelecem a equivalência entre o delineamento quadrado latino para $t = 4$, apresentada na figura 6 e o apresentado na tabela 5. Note que esse delineamento é equivalente ao obtido utilizando-se a solução geral (1) fazendo-se a linha 2 = (linha $1 + 1$) (mod4), linha 3 = (linha $1 + 3$) (mod4) e linha 4 = linha $1 + 2(\text{mod}4)$.

Para $t = 6$ tratamentos, tem-se que $x = 3$ é um resto cuja sexta potência é a menor potência congruente a 1 em módulo 7, isto é, $3^6 = 729 \equiv 1(\text{mod}7)$. Logo, tem-se que $3^0 = 1$; $3^1 = 3$; $3^2 = 9 \equiv 2(\text{mod}7)$; $3^3 = 27 \equiv 6(\text{mod}7)$; $3^4 = 81 \equiv 4(\text{mod}7)$; $3^5 = 243 \equiv 5(\text{mod}7)$ cujas potências estabelecem a equivalência entre o delineamento para $t = 6$ tratamentos apresentado na figura 6 e o apresentado na tabela 6. Note que, nesse caso, tal delineamento é diferente do obtido por meio da solução geral (1).

Tabela 5 - Quadrado latino balanceado para a vizinhança com $t = 4$

Provadores	Ordem			
	1	2	3	4
1	0	1	3	2
2	1	2	0	3
3	3	0	2	1
4	2	3	1	0

Tabela 6 - Quadrado latino balanceado para a vizinhança com $t = 6$

Provadores	Ordem					
	1	2	3	4	5	6
1	0	2	1	4	5	3
2	2	4	3	0	1	5
3	1	3	2	5	0	4
4	4	0	5	2	3	1
5	5	1	0	3	4	2
6	3	5	4	1	2	0

Uma outra solução pode ser obtida no caso de t ser uma potência de 2, ou seja, $t = 2^k$, caso em que os resultados das sucessivas diferenças de cada elemento de uma mesma linha são dadas por:

$$1, \quad 2, \quad \ldots, \quad t-1, \tag{3}$$

cuja prova é apresentada por Williams (1949).

Assim, para $t = 4 = 2^2$, partindo-se do tratamento 0, tem-se que $0 + 1 = 1$, $1+2 = 3$, $3+3 = 6 \equiv 2(\text{mod}4)$, ou seja, tem-se a primeira linha do quadrado latino dada por 0, 1, 3 e 2, igual às obtidas por meio das soluções anteriores. Para $t = 8 = 2^3$ e partindo-se do tratamento 0, tem-se que $0+1 = 1$, $1+2 = 3$, $3+3 = 6$, $6+4 = 10 \equiv 2(\text{mod}8)$, $2+5 = 7$, $7 + 6 \equiv 13(\text{mod}8)$, $5 + 7 = 12 \equiv 4$ (mod8). Assim, obtém-se a solução 0, 1, 3, 6, 2, 7, 5, 4, diferente da obtida por meio da solução geral (1).

Segundo o autor tanto para t par, quanto para t ímpar, quando uma linha inicial é encontrada, outras podem ser derivadas a partir desta, multiplicando cada elemento por um resíduo que é primo para t, e acrescentando-se um inteiro arbitrário. Essas linhas são equivalentes, uma vez que o efeito de multiplicação é o mesmo que permutação dos números que representam os tratamentos. Assim a tabela 7 apresenta apenas um padrão representativo de cada um desses conjuntos de linhas .

Tabela 7 - Linhas iniciais de quadrados latinos balanceados para vizinhança, considerando-se diferentes números pares de tratamentos t

t	Linhas iniciais							
4			0	1	3	2		
6		0	1	5	2	4	3	
		0	2	1	4	5	3	
8	0	1	7	2	6	3	5	4
	0	1	3	6	2	7	5	4

Caso II: Número ímpar de tratamentos.

Quando t é ímpar, a soma dos restos é um múltiplo de t. Assim, se todas as diferenças ocorrem uma vez em uma linha, o último elemento será o mesmo que o primeiro. Portanto, conclui-se que é impossível construir quadrados latinos balanceados baseando-se apenas em um único quadrado latino, havendo a necessidade de se utilizar um quadrado latino adicional. Torna-se possível, deste modo, alcançar o balanceamento com um par de quadrados latinos. Quando $t = 5$, um par de conjuntos de possíveis diferenças de forma a gerar um par de quadrados latinos que juntos fornecem o balanceamento é dado por $1, 2, 1, 3$ e $2, 4, 3, 4$ gerando, respectivamente, suas primeiras linhas dadas por $0, 1, 3, 4, 2$ e $0, 2, 1, 4, 3$ gerando os quadrados latinos apresentados na tabela 8, cujas demais linhas são obtidas adicionando-se uma unidade às mesmas, sequencialmente.

Pode-se encontrar um par de quadrados latinos balanceados para valores ímpares de t, utilizando a seguinte solução geral para encontrar as respectivas linhas iniciais:

Tabela 8 - Delineamento balanceado para vizinhança com $t = 5$ tratamentos formado por dois quadrados latinos cujas primeiras linhas são apresentadas em negrito

Provadores	Ordem				
	1	2	3	4	5
1	**0**	**1**	**3**	**4**	**2**
2	1	2	4	0	3
3	2	3	0	1	4
4	3	4	1	2	0
5	4	0	2	3	1
6	**0**	**2**	**1**	**4**	**3**
7	1	3	2	0	4
8	2	4	3	1	0
9	3	0	4	2	1
10	4	1	0	3	2

$$0 \quad 1 \quad t-1 \quad 2 \quad t-2 \quad \ldots \quad \frac{t-1}{2} \quad \frac{t+1}{2} \tag{4}$$

que fornece diferenças ímpares duplicadas e a sequência reversa

$$\frac{t+1}{2} \quad \frac{t-1}{2} \quad \ldots \quad t-2 \quad 2 \quad t-1 \quad 1 \quad 0 \tag{5}$$

que fornece as diferenças pares duplicadas. Como consequência, o par de quadrados latinos apresenta o balanceamento desejado. Para $t = 3$ tratamentos tem-se que as linhas iniciais usando (4) e (5) são dadas por 0, 1, 2 e 2, 1, 0 ou equivalentemente, 0, 1, 2 e 0, 2, 1, esta última obtida somando-se uma unidade à segunda em módulo 3. Para $t = 5$, obtém-se, por sua vez, as linhas 0, 1, 4, 2, 3 e 3, 2, 4, 1, 0 ou equivalentemente, 0, 1, 4, 2, 3 e 0, 4, 1, 3, 2, esta última obtida somando-se 2 à segunda, em módulo 5.

Outra solução geral apresentada pelo autor é possível quando t é primo da forma $4m + 3$, ou seja, $m = 0$, e $t = 3$, $m = 1$ e $t = 7$, $m = 2$ e $t = 11$, $m = 4$ e $t = 19$ etc.

Nesse caso as sequências de diferenças sucessivas entre os tratamentos para os dois quadrados latinos são, respectivamente, dadas por:

$$1 \quad 2 \quad 3 \quad \ldots \quad 2m+1 \quad 2m+1 \quad \ldots \quad 3 \quad 2 \quad 1 \tag{6}$$

e

$$4m+2 \quad 4m+1 \quad \ldots \quad 2m+2 \quad 2m+2 \quad \ldots \quad 4m+1 \quad 4m+2, \tag{7}$$

em módulo t.

Para $t = 7$ e $m = 1$ obtém-se, por meio de (6) e (7) as sequências de diferenças sucessivas:

$$1 \quad 2 \quad 3 \quad 3 \quad 2 \quad 1$$

e

$$6 \quad 5 \quad 4 \quad 4 \quad 5 \quad 6,$$

que levam, em módulo 7, às sequências de tratamentos:

$$0 \quad 1 \quad 3 \quad 6 \quad 2 \quad 4 \quad 5$$

e

$$0 \quad 6 \quad 4 \quad 1 \quad 5 \quad 3 \quad 2.$$

A tabela 9 reproduz a tabela produzida por Williams (1949) com alguns pares de linhas iniciais, para $t = 3, 5$ e 7.

Como para valores pares de t, pares de quadrados latinos balanceados alternativos podem ser obtidos a partir dos apresentados na tabela 9 multiplicando cada elemento por um resto primo a t, e/ou acrescentando um inteiro arbitrário.

Tabela 9 - Linhas iniciais para pares de quadrados latinos balanceados para vizinhança, considerando-se diferentes números ímpares de tratamentos t

t	Linhas iniciais														
3				0	1	2					0	2	1		
5			0	1	3	4	2			0	2	1	4	3	
5			0	1	4	2	3			0	4	1	3	2	
7	0	1	6	2	5	3	4		0	6	1	5	2	4	3

Embora tenha sido enfatizado o uso dos delineamentos balanceados para estimação de efeitos residuais de um único tratamento anterior, o autor apresenta, ainda, os delineamentos balanceados para efeito de qualquer número de tratamentos anteriores, ignorando a interação dos efeitos residuais. Nesse caso, quando t é um número primo ou uma potência de um primo, um delineamento balanceado é possível com $t(t-1)$ repetições, que podem ser definidas como um conjunto de $t-1$ quadrados latinos mutuamente ortogonais, com as mesmas colunas iniciais. Delineamentos que não são expressos como quadrados latinos mutuamente ortogonais também são possíveis. Apresenta, ainda, a obtenção de delineamentos balanceados para os efeitos de dois tratamentos anteriores e suas interações, a partir de um conjunto de $t-1$ quadrados latinos mutuamente ortogonais obedecendo a certas restrições.

3.2.2 Procedimento de aleatorização para quadrados latinos balanceados para vizinhança

A fim de evitar erros sistemáticos e validar os pressupostos necessários para se aplicar a análise de variância, deve-se, necessariamente proceder a aleatorização dos quadrados latinos obtidos na sessão anterior.

Embora a aleatorização do quadrado latino tradicional implique em organizar as linhas e/ou colunas de forma aleatória, no caso em questão, a aleatorização das colunas é inviável, pois destrói o balanceamento da vizinhança. Isto ocorre pois a linha inicial é especialmente escolhida de forma a equilibrar os efeitos residuais da degustação, e com o sorteio das colunas tal equilíbrio é quebrado. Logo, o procedimento de aleatorização para os quadrados latinos balanceados para vizinhança resume-se a:

1. escolher, ao acaso, a(s) linha(s) inicial(is) do(s) quadrados latinos apresentados nas tabelas 7 e 9;

2. aleatorizar as linhas, ou provadores;

3. aleatorizar a correspondência entre os elementos de Z_t (conjunto de t tratamentos) e os tratamentos.

Segundo Durier et. al. (1996), o passo 1 não é estritamente necessário, embora seja recomendado. Por outro lado, segundo os autores, os passos 2 e 3 são necessários.

3.3 Modelo

Seja y_{ij} a nota dada pelo i-ésimo provador para a j-ésima amostra degustada e $k(i,j)$ uma função que indica o índice do tratamento correspondente à j-ésima amostra degustada pelo i-ésimo provador. Então:

$$y_{ij} = \mu + \alpha_i + \beta_j + \tau_{k(i,j)} + \tau'_{k(i,j-1)} + e_{ij} \tag{8}$$

em que μ é uma constante, α_i é o efeito do i-ésimo provador; β_j é o efeito da j-ésima degustação; $\tau_{k(i,j)}$ é o efeito direto do $k(i,j)$-ésimo tratamento; $\tau'_{k(i,j-1)}$ é o efeito residual do tratamento $k(i,j-1)$-ésimo tratamento ($j \geq 1$) e e_{ij} é o erro aleatório, i=1, 2, 3, ..., n e $j = 1, 2, 3, ..., J$.

Sejam $\mathbf{y} = (y_{11}, y_{12}, \ldots, y_{1n}, y_{21}, \ldots, y_{2n}, \ldots, y_{Jn})^T$, $\boldsymbol{e} = (e_{11}, e_{12}, \ldots, e_{1n}, e_{21}, \ldots, e_{2n}, \ldots, e_{Jn})^T$ e P, O, T e A as matrizes indicadoras de efeitos de provador, de ordem de degustação, tratamento direto e residual, ou do tratamento anterior, respectivamente. Assim, se $P = [P_{su}]$, então, por exemplo,

$$P_{su} = \begin{cases} 1, & \text{se a } s\text{-ésima nota (ou elemento) de } \mathbf{y} \text{ foi dado pelo } u\text{-ésimo provador} \\ 0, & \text{caso contrário} \end{cases}$$

ou ainda, $P = I_{\{n\}} \bigotimes \mathbb{1}_{J\times 1}$ e $O = \mathbb{1}_{n\times 1} \bigotimes I_{\{J\}}$, em que I é a matriz identidade, $\mathbb{1}$ uma matriz ou vetor de elementos iguais a 1 e $\bigotimes$ é o operador do produto de Kronecker.

Considere, por exemplo, as observações apresentadas na tabela 10, de um quadrado latino com $t = 3$ tratamentos, $J = 3$ ordens de degustação e $n = 6$ provadores.

Tabela 10 - Delineamento em quadrado latino balanceado para vizinhança com $t = 3$, em que os números entre parênteses representam os respectivos tratamentos

Provadores	Ordem			Total
	1	2	3	
1	$y_{11}(1)$	$y_{21}(2)$	$y_{31}(3)$	$y_{1.}$
2	$y_{12}(2)$	$y_{22}(3)$	$y_{32}(1)$	$y_{2.}$
3	$y_{13}(3)$	$y_{23}(1)$	$y_{33}(2)$	$y_{3.}$
4	$y_{14}(1)$	$y_{24}(3)$	$y_{34}(2)$	$y_{4.}$
5	$y_{15}(2)$	$y_{25}(1)$	$y_{35}(3)$	$y_{5.}$
$n = 6$	$y_{16}(3)$	$y_{26}(2)$	$y_{36}(1)$	$y_{6.}$
Total	$y_{.1}$	$y_{.2}$	$y_{.3}$	$y_{..}$

Nesse caso, as matrizes P, O, T, A são dadas, respectivamente, por

$$P = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}, O = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, T = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix} \text{ e } A = \begin{bmatrix} 0 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \end{bmatrix}.$$

Note que, $P = I_{\{6\}} \bigotimes \mathbb{1}_{3\times 1}$ e $O = \mathbb{1}_{6\times 1} \bigotimes I_{\{3\}}$.

Considere agora $\boldsymbol{\alpha} = (\alpha_1, \alpha_2, \alpha_3, \ldots, \alpha_n)^T$, $\boldsymbol{\beta} = (\beta_1, \beta_2, \ldots, \beta_J)^T$, $\boldsymbol{\tau} = (\tau_1, \tau_2, \ldots, \tau_t)^T$, $\boldsymbol{\tau}' = (\tau'_1, \tau'_2, \ldots, \tau'_t)^T$ e

$$\boldsymbol{\theta} = \begin{bmatrix} \mu \\ \boldsymbol{\alpha} \\ \boldsymbol{\beta} \\ \boldsymbol{\tau} \\ \boldsymbol{\tau}' \end{bmatrix},$$

em que $\boldsymbol{\theta}$ é o vetor de parâmetros a serem estimados, com dimensão $1 + n + J + t + t = 1 + n + J + 2t$.

Pode-se, então, escrever o modelo (8) na sua forma matricial dada por:

$$\begin{aligned} \mathbf{y} = & \ \mathbb{1}_{nJ\times 1}\mu + P\boldsymbol{\alpha} + O\boldsymbol{\beta} + T\boldsymbol{\tau} + A\boldsymbol{\tau}' + \boldsymbol{e} \\ = & \ [\mathbb{1}_{nJ\times 1} \vdots P \vdots O \vdots T \vdots A]\boldsymbol{\theta} + \boldsymbol{e} \\ = & \ X\boldsymbol{\theta} + \boldsymbol{e}, \end{aligned} \tag{9}$$

em que $Var(\boldsymbol{e}) = E(\boldsymbol{e}\boldsymbol{e}^T) = I_{\{n\}}\sigma^2$.

Como pressuposição para a realização de testes de hipóteses sobre os parâmetros do modelo, considere-se, adicionalmente, $\boldsymbol{e} \sim MN(\mathbf{0}, I\sigma^2)$.

Para se estimar $\boldsymbol{\theta}$, pode-se, então utilizar o método dos quadrados mínimos, isto é, obter $\boldsymbol{\theta}$ tal que $L = \boldsymbol{e}^T\boldsymbol{e} = (\mathbf{y} - X\boldsymbol{\theta})^T(\mathbf{y} - X\boldsymbol{\theta})$ seja mínimo, o que é equivalente a encontrar a solução do sistema de equações normais

$$X^T X\boldsymbol{\theta} = X^T\mathbf{y} \tag{10}$$

em que

$$X^T X = \ [\mathbb{1}_{nJ\times 1} \vdots P \vdots O \vdots T \vdots A]^T[\mathbb{1}_{nJ\times 1} \vdots P \vdots O \vdots T \vdots A]$$

$$X^TX = \begin{bmatrix} \mathbb{1}_{nJ\times 1}^T\mathbb{1}_{nJ\times 1} & \mathbb{1}_{nJ\times 1}^TP & \mathbb{1}_{nJ\times 1}^TO & \mathbb{1}_{nJ\times 1}^TT & \mathbb{1}_{nJ\times 1}^TA \\ P^T\mathbb{1}_{nJ\times 1}^T & P^TP & P^TO & P^TT & P^TA \\ O^T\mathbb{1}_{nJ\times 1}^T & O^TP & O^TO & O^TT & O^TA \\ T^T\mathbb{1}_{nJ\times 1}^T & T^TP & T^TO & T^TT & T^TA \\ A^T\mathbb{1}_{nJ\times 1}^T & A^TP & A^TO & A^TT & A^TA \end{bmatrix}$$

e

$$X^T\mathbf{y} = \left[\mathbb{1}_{nJ\times 1}\vdots P\vdots O\vdots T\vdots A\right]^T\mathbf{y} = \begin{bmatrix} \mathbb{1}^T\mathbf{y} \\ P^T\mathbf{y} \\ O^T\mathbf{y} \\ T^T\mathbf{y} \\ A^T\mathbf{y} \end{bmatrix} = \begin{bmatrix} G \\ \mathbf{p} \\ \mathbf{o} \\ \mathbf{t} \\ \mathbf{t}' \end{bmatrix} = \begin{bmatrix} y_{..} \\ y_{1.} \\ y_{2.} \\ \vdots \\ y_{n.} \\ y_{.1} \\ y_{.2} \\ \vdots \\ y_{.J} \\ y_{(1..)} \\ y_{(2..)} \\ \vdots \\ y_{(t..)} \\ \cdots \\ y'_{(1..)} \\ y'_{(2..)} \\ \vdots \\ y'_{(k..)} \end{bmatrix}$$

em que $y_{..} = \sum_{i=1}^n \sum_{j=1}^J y_{ij}$, $y_{u.} = \sum_{i=1}^n y_{ui}$, $y_{.u} = \sum_{j=1}^J y_{ju}$, $y_{u..} = \sum_{\{(i,j)|k(i,j)=1\}}^t y_{ij}$, $y'_{u..} = \sum_{\{(i,j)|k(i,j-1)=1\}}^t y_{ij}$, ou seja, $G = y_{..}$ é o total de observações do experimento; $\mathbf{p} = P^T\mathbf{y}$ é o vetor dos totais observados para as linhas, ou seja, para os provadores; $\mathbf{o} = O^T\mathbf{y}$ é o vetor dos totais observados para as colunas, ou seja, para cada ordem de degustação; $\mathbf{t} = T^T\mathbf{y}$ é

o vetor dos totais observados para os tratamentos, ou seja, e $\mathbf{t}' = A^T\mathbf{y}$ é o vetor dos totais observados para os tratamentos precedentes.

No caso em questão, como a matriz X tem posto coluna incompleto, então X^TX é não-singular e o sistema de equações normais é indeterminado. Neste caso, soluções exatas deste sistema podem ser obtidas dentre outras, por:

$$\boldsymbol{\theta}^0 = (X^TX)^G X^T\mathbf{y} \tag{11}$$

em que $(X^TX)^G$ é uma inversa generalizada de X^TX.

Segundo Rao (1945), apud Iemma (1993), "uma função linear paramétrica $\lambda^T\boldsymbol{\theta}$ é estimável, no modelo linear de Gauss-Markov, se e somente se $\lambda \epsilon C(X^T)$", em que $C(X^T)$ é o espaço coluna de X^T. Em termos práticos, tem-se que se $E(y) = X\boldsymbol{\theta}$, então $X\boldsymbol{\theta}$ é estimável. Além disso, segundo o autor, combinações lineares de funções estimáveis são também estimáveis.

Vale lembrar também que, pelo teorema de Gauss-Markov, se $\lambda^T\boldsymbol{\theta}$ é estimável, então seu BLUE ("Best Linear Unbiased Estimator") é único e dado por $\lambda^T\boldsymbol{\theta} = \lambda^T\boldsymbol{\theta}^0$, em que $\boldsymbol{\theta}^0$ é qualquer solução do sistema de equações normais. As funções determinadas são ditas funções estimáveis, que são funções do tipo $\lambda^T\boldsymbol{\theta}$ para as quais as estimativas $\lambda^T\boldsymbol{\theta}^0$ são invariantes para qualquer $\boldsymbol{\theta}^0$ solução do sistema de equações normais.

Considerando-se a solução $\boldsymbol{\theta}^0$ dada por (11), têm-se que o vetor $\hat{\mathbf{y}}$ de valores preditos dado por:

$$\hat{\mathbf{y}} = X\boldsymbol{\theta}^0 = X(X^TX)^G X^T\mathbf{y} = Q\mathbf{y},$$

invariante para qualquer solução $\boldsymbol{\theta}^0$ do sistema de equações normais (10) (IEMMA e PALM, 1992). Tem-se, ainda, que o vetor $\hat{\boldsymbol{e}}$ de erros preditos é dado por:

$$\hat{\boldsymbol{e}} = \mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - X\boldsymbol{\theta}^0 = \mathbf{y} - X(X^TX)^G X^T\mathbf{y} = (I - Q)\mathbf{y}.$$

Segundo os autores, $Q = X(X^TX)^G X^T$ é o projetor ortogonal de $\mathbf{y}$ sobre o espaço gerado pelas colunas de X e $(I - Q)$ é o projetor ortogonal de $\mathbf{y}$ sobre o complemento

ortogonal do espaço coluna de X, $C^{\perp}(X)$. Uma vez que $Q^TQ = Q$ e $(I-Q)^T(I-Q) = (I-Q)$ tem-se a decomposição clássica da análise de variância:

$$||\mathbf{y}||^2 = ||\hat{\mathbf{y}}||^2 + ||\hat{\boldsymbol{e}}||^2,$$

em que:

$$\begin{aligned}
||\mathbf{y}||^2 &= \mathbf{y}^T\mathbf{y} = \sum_{ij} y_{ij}^2 = \text{SQTotal;} \\
||\hat{\mathbf{y}}||^2 &= \hat{\mathbf{y}}^T\hat{\mathbf{y}} = \sum_{ij} \hat{y}_{ij}^2 = \hat{\mathbf{y}}^T Q\mathbf{y} = \boldsymbol{\theta}^{0^T} X^T\mathbf{y} = \text{SQParâmetros} = SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}, \boldsymbol{\tau}') \\
||\hat{\boldsymbol{e}}||^2 &= \hat{\boldsymbol{e}}^T\hat{\boldsymbol{e}} = \sum_{ij} \hat{e}_{ij}^2 = \mathbf{y}^T\mathbf{y} - \boldsymbol{\theta}^{0^T} X^T\mathbf{y} = \mathbf{y}^T(I-Q)\mathbf{y} = \text{SQResíduo}
\end{aligned}$$

A fim de testar certas hipóteses de interesse, considere, agora os seguintes casos particulares do modelo (9):

$$\begin{aligned}
\mathbf{y} &= X_1\boldsymbol{\theta}_1 + \boldsymbol{e}_1 = \mathbb{1}\mu + \boldsymbol{e}_1 \\
\mathbf{y} &= X_2\boldsymbol{\theta}_2 + \boldsymbol{e}_2 = \begin{bmatrix} \mathbb{1} \vdots P \end{bmatrix} \begin{bmatrix} \mu \\ \boldsymbol{\alpha} \end{bmatrix} \mu + \boldsymbol{e}_2 \\
\mathbf{y} &= X_3\boldsymbol{\theta}_3 + \boldsymbol{e}_3 = \begin{bmatrix} \mathbb{1} \vdots P \vdots O \end{bmatrix} \begin{bmatrix} \mu \\ \boldsymbol{\alpha} \\ \boldsymbol{\beta} \end{bmatrix} + \boldsymbol{e}_3 \\
\mathbf{y} &= X_4\boldsymbol{\theta}_4 + \boldsymbol{e}_4 = \begin{bmatrix} \mathbb{1} \vdots P \vdots O \vdots T \end{bmatrix} \begin{bmatrix} \mu \\ \boldsymbol{\alpha} \\ \boldsymbol{\beta} \\ \boldsymbol{\tau} \end{bmatrix} + \boldsymbol{e}_4 \\
\mathbf{y} &= X_5\boldsymbol{\theta}_5 + \boldsymbol{e}_5 = \begin{bmatrix} \mathbb{1} \vdots P \vdots O \vdots A \end{bmatrix} \begin{bmatrix} \mu \\ \boldsymbol{\alpha} \\ \boldsymbol{\beta} \\ \boldsymbol{\tau}' \end{bmatrix} + \boldsymbol{e}_5
\end{aligned}$$

Nesses casos, têm-se, respectivamente, os seguintes sistemas de equações normais:

$$X_1^T X_1 \boldsymbol{\theta}_1 = X_1^T \mathbf{y},$$

$$X_2^T X_2 \boldsymbol{\theta}_2 = X_2^T \mathbf{y},$$

$$X_3^T X_3 \boldsymbol{\theta}_3 = X_3^T \mathbf{y},$$

$$X_4^T X_4 \boldsymbol{\theta}_4 = X_4^T \mathbf{y}$$

e

$$X_5^T X_5 \boldsymbol{\theta}_5 = X_5^T \mathbf{y}$$

cujas soluções são, respectivamente, dadas por

$$\theta_1 = (X_1^T X_1)^{-1} X_1^T \mathbf{y} = \frac{1}{nJ} y_{..} = \frac{G}{nJ}$$

$$\boldsymbol{\theta}_2^0 = (X_2^T X_2)^G X_2^T \mathbf{y}$$

$$\boldsymbol{\theta}_3^0 = (X_3^T X_3)^G X_3^T \mathbf{y}$$

$$\boldsymbol{\theta}_4^0 = (X_1^T X_4)^G X_4^T \mathbf{y}$$

$$\boldsymbol{\theta}_5^0 = (X_5^T X_5)^G X_5^T \mathbf{y}$$

Convém notar que as soluções $\boldsymbol{\theta}_2^0$, $\boldsymbol{\theta}_3^0$, $\boldsymbol{\theta}_4^0$, $\boldsymbol{\theta}_5^0$, não são únicas pois dependem da inversa generalizada utilizada. No entanto, os vetores de valores preditos, $\hat{\mathbf{y}}_2 = X_2 \boldsymbol{\theta}_2^0$, $\hat{\mathbf{y}}_3 = X_3 \boldsymbol{\theta}_3^0$, $\hat{\mathbf{y}}_4 = X_4 \boldsymbol{\theta}_4^0$ e $\hat{\mathbf{y}}_5 = X_5 \boldsymbol{\theta}_5^0$ são invariantes à inversa utilizada.

No entanto, se forem consideradas as restrições nas soluções dada por:

$$\mathbb{1}_{n\times 1}^T \boldsymbol{\alpha} = \mathbb{1}_{J\times 1}^T \boldsymbol{\beta} = \mathbb{1}_{t\times 1}^T \boldsymbol{\tau} = \mathbb{1}_{t\times 1}^T \boldsymbol{\tau}' = 0 \tag{12}$$

ou seja,

$$S\boldsymbol{\theta} = (0 \oplus \mathbb{1}_{n\times 1}^T \oplus \mathbb{1}_{J\times 1}^T \oplus \mathbb{1}_{t\times 1}^T \oplus \mathbb{1}_{t\times 1}^T)\boldsymbol{\theta} = \mathbf{0} \tag{13}$$

tem-se o modelo completo, com restrições, dado por:

$$\begin{bmatrix} \mathbf{y} \\ \mathbf{0} \end{bmatrix} = \begin{bmatrix} X \\ S \end{bmatrix} \boldsymbol{\theta} + \begin{bmatrix} \boldsymbol{e} \\ \mathbf{0} \end{bmatrix}$$

cujo sistema de equações normais é

$$(X^T X + S^T S)\boldsymbol{\theta} = X^T \mathbf{y}, \tag{14}$$

com solução única dada por:

$$\hat{\boldsymbol{\theta}} = (X^T X + S^T S)^{-1} X^T \mathbf{y}, \tag{15}$$

em que

$$S^T S = (0 \oplus \mathbb{1}_{n\times n} \oplus \mathbb{1}_{J\times J} \oplus \mathbb{1}_{t\times t} \oplus \mathbb{1}_{t\times t}) \tag{16}$$

Considere, agora, as somas de quadrados de parâmetros dos modelos considerados, dadas por:

$$\begin{aligned}
SQ(\theta_1) &= SQ(\mu) = \hat{\theta}_1 X_1^T \mathbf{y} = nJy_{..}^2 \\
SQ(\boldsymbol{\theta}_2) &= SQ(\mu, \boldsymbol{\alpha}) = \boldsymbol{\theta}_2^{0^T} X_2^T \mathbf{y} \\
SQ(\boldsymbol{\theta}_3) &= SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}) = \boldsymbol{\theta}_3^{0^T} X_3^T \mathbf{y} \\
SQ(\boldsymbol{\theta}_4) &= SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}) = \boldsymbol{\theta}_4^{0^T} X_4^T \mathbf{y} \\
SQ(\boldsymbol{\theta}_5) &= SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}') = \boldsymbol{\theta}_5^{0^T} X_5^T \mathbf{y}.
\end{aligned}$$

Seja $R(\boldsymbol{\theta}_b|\boldsymbol{\theta}_a)$ a redução na soma de quadrados de parâmetros devido à alteração de um modelo com vetor de parâmetros $\boldsymbol{\theta}_a$ para o modelo com vetor de parâmetros $\begin{bmatrix} \boldsymbol{\theta}_a \\ \boldsymbol{\theta}_b \end{bmatrix}$, dada por: $R(\boldsymbol{\theta}_b|\boldsymbol{\theta}_a) = SQ(\boldsymbol{\theta}_a, \boldsymbol{\theta}_b) - SQ(\boldsymbol{\theta}_a)$

Consequentemente, têm-se que:

$R(\boldsymbol{\alpha}|\mu) = SQ(\mu, \boldsymbol{\alpha}) - SQ(\mu) = SQ(\boldsymbol{\theta}_2) - SQ(\boldsymbol{\theta}_1)$, com $(n-1)$, graus de liberdade,

$R(\boldsymbol{\beta}|\mu, \boldsymbol{\alpha}) = SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}) - SQ(\mu, \boldsymbol{\alpha}) = SQ(\boldsymbol{\theta}_3) - SQ(\boldsymbol{\theta}_2)$, com $(J-1)$ graus de liberdade,

$R(\boldsymbol{\tau}|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}) = SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}) - SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}) = SQ(\boldsymbol{\theta}_4) - SQ(\boldsymbol{\theta}_3)$, com $(t-1)$ graus de liberdade,

$R(\boldsymbol{\tau}'|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}) = SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}') - SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}) = SQ(\boldsymbol{\theta}_5) - SQ(\boldsymbol{\theta}_3)$, com $(t-1)$ graus de liberdade,

$R(\boldsymbol{\tau}|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}') = SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}, \boldsymbol{\tau}') - SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}') = SQ(\boldsymbol{\theta}) - SQ(\boldsymbol{\theta}_5)$, com $(t-1)$ graus de liberdade,

$R(\boldsymbol{\tau}'|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}) = SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}, \boldsymbol{\tau}') - SQ(\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}) = SQ(\boldsymbol{\theta}) - SQ(\boldsymbol{\theta}_4)$, com $(t-1)$ graus de liberdade.

Logo, assumindo-se que $\boldsymbol{e} \sim MN(\mathbf{0}, I_{\{n\}}\sigma^2)$, pode-se testar a hipótese de existência de efeitos residuais de tratamentos ajustado para os demais efeitos, ou seja,

$$\begin{cases} H_0 : \boldsymbol{\tau}' = \mathbf{0}|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau} \\ H_a : \boldsymbol{\tau}' \neq \mathbf{0}|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau} \end{cases}$$

por meio da estatística:

$$F = \frac{R(\boldsymbol{\tau}'|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau})/(t-1)}{\text{SQResíduo/GLResíduo}}$$

em que GLResíduo $= (nJ-1) - [(n-1) + (J-1) + 2(t-1)]$, que sob hipótese H_0 tem distribuição F com parâmetros $\nu_1 = (t-1)$ e $\nu_2 =$ GLResíduo.

Analogamente, pode-se testar a hipótese de efeitos diretos de tratamentos ajustados para os demais efeitos, ou seja,

$$\begin{cases} H_0 : \boldsymbol{\tau} = \mathbf{0}|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}' \\ H_a : \boldsymbol{\tau} \neq \mathbf{0}|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}' \end{cases}$$

por meio da estatística

$$F = \frac{R(\boldsymbol{\tau}|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}')/(t-1)}{\text{SQResíduos/GLResíduo}}$$

que sob hipótese H_0 tem distribuição F com parâmetros $\nu_1 = (t-1)$ e $\nu_2 =$ GLResíduo.

Finalmente, pode-se construir as tabelas 11 e 12 de análise de variância correspondentes às hipóteses de interesse.

Tabela 11 - Quadro de análise de variância considerando efeito residual de tratamentos ajustado para demais efeitos

Fonte de Variação	GL	SQ
Provadores($\boldsymbol{\alpha}\|\mu$)	$n-1$	$R(\boldsymbol{\alpha}\|\mu)$
Ordem ($\boldsymbol{\beta}\|\mu, \boldsymbol{\alpha}$)	$J-1$	$R(\boldsymbol{\beta}\|\mu, \boldsymbol{\alpha})$
Tratamento		
Direto($\boldsymbol{\tau}\|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}$)	$n-1$	$R(\boldsymbol{\tau}\|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta})$
Residual aj.($\boldsymbol{\tau}'\|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}$)	$t-1$	$R(\boldsymbol{\tau}'\|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau})$
Resíduo	GLResíduo	SQResíduo
Total aj. ($\boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}, \boldsymbol{\tau}'\|\mu$)	$nJ-1$	$\mathbf{y}^T\mathbf{y}-1$

Tabela 12 - Quadro de análise de variância considerando efeito de tratamentos ajustado para demais efeitos

Fonte de Variação	GL	SQ
Provadores($\boldsymbol{\alpha}\|\mu$)	$n-1$	$R(\boldsymbol{\alpha}\|\mu)$
Ordem ($\boldsymbol{\beta}\|\mu, \boldsymbol{\alpha}$)	$J-1$	$R(\boldsymbol{\beta}\|\mu, \boldsymbol{\alpha})$
Tratamento		
Residual aj.($\boldsymbol{\tau}'\|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}$)	$t-1$	$R(\boldsymbol{\tau}'\|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta})$
Direto($\boldsymbol{\tau}\|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}'$)	$t-1$	$R(\boldsymbol{\tau}\|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}')$
Resíduo	GLResíduo	SQResíduo
Total aj. ($\boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}, \boldsymbol{\tau}'\|\mu$)	$nJ-1$	$\mathbf{y}^T\mathbf{y}-1$

São feitas, a seguir, algumas considerações importantes. Se, por acaso, as sessões de degustação fossem feitas em dias diferentes, em cada dia teria que ter sido utilizado um quadrado latino e nesse caso poderiam ser levados em conta,também, os efeitos de sessões, ou seja, de cada quadrado latino. Os casos em que são utilizados mais que um quadrado latino são aqueles em que o número de tratamentos é ímpar ou caso haja mais provadores do que tratamentos, sendo assim necessário repetir os quadrados latinos, como já discutido anteriormente. Caso seja apenas utilizado um quadrado latino, este efeito é inexistente.

Um alternativa para que não seja necessário fazer o ajuste para efeitos residuais do tratamento anterior e depois para o efeito direto de tratamento, ou vice-versa, é dado por Cochran e Cox (1957). Neste caso, basta repetir a última ordem de degustação, ou seja, na última ordem de degustação, os provadores avaliam novamente os mesmos tratamentos da penúltima ordem. Assim, além de todo tratamento preceder com igual frequência todos os outros tratamentos, ele também precede a si mesmo e fazendo-se a análise ajustando primeiro para efeito direto do tratamento, ou primeiro para efeito residual do tratamento anterior, os resultados das análises seriam os mesmos. O raciocínio para a construção da matrix X do modelo é análogo ao mostrado anteriormente, apenas com uma coluna a mais na matriz θ. Este método foi utilizado para análise do experimento de cachaças apresentado mais adiante neste trabalho.

4 RESULTADOS E DISCUSSÃO

4.1 Estudo de simulação

De modo a analisar a influência de se considerar ou não a presença de efeitos residuais de tratamentos no modelo quando, na realidade, há ou não efeitos residuais, foi conduzido o estudo de simulação descrito a seguir.

Considere, inicialmente que há $t = 6$ tratamentos, numerados de 1 a 6 e $n = 6$ provadores que provaram todos os 6 tratamentos nas sequências ou ordens apresentadas na tabela 13.

Tabela 13 - Delineamento quadrado latino balanceado para a vizinhança, para $t = 6$ tratamentos e $n = t = 6$ provadores

Provadores	Ordem					
	1	2	3	4	5	6
1	3	6	2	5	4	1
2	5	3	4	6	1	2
3	1	4	5	2	6	3
4	2	1	6	4	3	5
5	6	5	1	3	2	4
6	4	2	3	1	5	6

Para as simulações, considerou-se o modelo de equação (8), em que $P = I_{\{6\}} \bigotimes \mathbb{1}_{1\times 6}$ e $O = \mathbb{1}_{1\times 6} \bigotimes I_{\{6\}}$,

$$\mathbf{T} = \begin{bmatrix}
0 & 0 & 1 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 1 \\
0 & 1 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 1 & 0 \\
0 & 0 & 0 & 1 & 0 & 0 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 1 & 0 \\
0 & 0 & 1 & 0 & 0 & 0 \\
0 & 0 & 0 & 1 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 1 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 1 & 0 & 0 & 0 & 0 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 1 & 0 & 0 \\
0 & 0 & 0 & 0 & 1 & 0 \\
0 & 1 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 1 \\
0 & 0 & 1 & 0 & 0 & 0 \\
0 & 1 & 0 & 0 & 0 & 0 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 1 \\
0 & 0 & 0 & 1 & 0 & 0 \\
0 & 0 & 1 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 1 & 0 \\
0 & 0 & 0 & 0 & 0 & 1 \\
0 & 0 & 0 & 0 & 1 & 0 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 1 & 0 & 0 & 0 \\
0 & 1 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 1 & 0 & 0 \\
0 & 0 & 0 & 1 & 0 & 0 \\
0 & 1 & 0 & 0 & 0 & 0 \\
0 & 0 & 1 & 0 & 0 & 0 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 1 & 0 \\
0 & 0 & 0 & 0 & 0 & 1
\end{bmatrix} \text{ e } \mathbf{A} = \begin{bmatrix}
0 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 1 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 1 \\
0 & 1 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 1 & 0 \\
0 & 0 & 0 & 1 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 1 & 0 \\
0 & 0 & 1 & 0 & 0 & 0 \\
0 & 0 & 0 & 1 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 1 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 0 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 1 & 0 & 0 \\
0 & 0 & 0 & 0 & 1 & 0 \\
0 & 1 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 1 \\
0 & 0 & 0 & 0 & 0 & 0 \\
0 & 1 & 0 & 0 & 0 & 0 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 1 \\
0 & 0 & 0 & 1 & 0 & 0 \\
0 & 0 & 1 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 1 \\
0 & 0 & 0 & 0 & 1 & 0 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 1 & 0 & 0 & 0 \\
0 & 1 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 1 & 0 & 0 \\
0 & 1 & 0 & 0 & 0 & 0 \\
0 & 0 & 1 & 0 & 0 & 0 \\
1 & 0 & 0 & 0 & 0 & 0 \\
0 & 0 & 0 & 0 & 1 & 0
\end{bmatrix}.$$

Foram considerados, ainda, os seguintes parâmetros: $\mu = 6$, $\boldsymbol{\alpha} = [-1, 2, 1, 1, -2, -1]^T$, $\boldsymbol{\beta} = [-2, -1, 0, 0, 1, 2]^T$, ou seja, com efeitos de provadores e de ordens de degustação. Para os parâmetros relativos aos efeitos diretos de tratamentos ou residuais,

dados pelos vetores de parâmetros $\boldsymbol{\tau}$ e $\boldsymbol{\tau}'$, respectivamente, consideraram-se quatro casos distintos:

Caso I: $\boldsymbol{\tau} = \mathbf{0}_{1\times t}$ e $\boldsymbol{\tau}' = \mathbf{0}_{1\times t}$, em que não há efeitos diretos, nem residuais de tratamentos;

Caso II: $\boldsymbol{\tau} = [2, -2, 1, 0, -1, 0]^T$ e $\boldsymbol{\tau}' = \mathbf{0}_{1\times t}$, em que há efeitos diretos de tratamentos e não há efeitos residuais de tratamentos;

Caso III: $\boldsymbol{\tau} = \mathbf{0}_{1\times t}$ e $\boldsymbol{\tau}' = [1, -1, 0, 0, 2, -2]^T$, em que não há efeitos diretos de tratamentos porém, há efeitos residuais de tratamentos e

Caso IV: $\boldsymbol{\tau} = [2, -2, 1, 0, -1, 0]^T$ e $\boldsymbol{\tau}' = [1, -1, 0, 0, 2, -2]^T$, em que há efeitos diretos e residuais de tratamentos.

No que diz respeito ao vetor de erros aleatórios $\mathbf{e}$, adotou-se para a simulação o parâmetro $\sigma = \frac{1}{2}$, ou seja, $\mathbf{e} \sim MN(\mathbf{0}; \frac{1}{4} I_{\{36\}})$.

Para cada um dos quatro casos considerados, foram gerados e analisados 10000 conjuntos de dados, cujas porcentagens de vezes em que cada um dos fatores foi significativo, considerando-se o nível de significância 5%, são apresentadas na tabela 14.

Adicionalmente, de modo a garantir a ortogonalidade entre os efeitos diretos e residuais de tratamentos, repetiu-se a degustação do último produto (ou tratamento) seguindo a sugestão de Cochran e Cox (1957). Nesse caso, denominado, aqui, modelo ortogonal, o vetor de parâmetros $\boldsymbol{\beta}$, relativo aos efeitos de ordens de degustação, passa a ter um parâmetro a mais, considerado igual a 0, ou seja,

$$\boldsymbol{\beta} = [-2, -1, 0, 0, 1, 2, 0]^T$$

e as matrizes do modelo (9) passam, neste caso, a ser iguais a: $P = I_{\{6\}} \bigotimes \mathbb{1}_{1\times 7}$ e $O = \mathbb{1}_{1\times 6} \bigotimes I_{\{7\}}$. As matrizes T e A passam, agora, a ter dimensões 42×6 e podem ser obtidas de forma análoga à anterior. Como consequência, tem-se que

$$R(\boldsymbol{\tau}|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}') = R(\boldsymbol{\tau}'|\mu, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\tau}),$$

e os resultados obtidos por meio da simulação são apresentados na tabela 14.

Finalmente, de modo a evidenciar eventuais problemas que a análise usual pode apresentar por não incluir no modelo os parâmetros relativos aos efeitos residuais, todos os

conjuntos simulados para os quatro casos foram reanalisados e os resultados são apresentados na tabela 14.

Tabela 14 - Porcentagem dos efeitos significativos ao nível de significância 5% em 10000 conjuntos de dados simulados, considerando-se ou não efeitos diretos e/ou residuais de tratamentos, e os modelos: D = usual, sem efeito residual de tratamento, DR = com ajuste sequencial de efeito direto e residual de tratamento, RD = com ajuste sequencial de efeitos residual e direto de tratamento e MO = ortogonal

	Efeito de	Modelo			
Caso	Tratamento	D	DR	RD	MO
I	Direto	$5,3\%$	$5,3\%$	$5,5\%$	$5,0\%$
	Residual	–	$5,3\%$	$5,4\%$	$5,1\%$
II	Direto	100%	100%	100%	100%
	Residual	–	$4,8\%$	$23,1\%$	$5,1\%$
III	Direto	0%	$35,5\%$	$5,2\%$	$4,9\%$
	Residual	–	100%	100%	100%
IV	Direto	$49,4\%$	100%	100%	100%
	Residual	–	100%	100%	100%

No caso I, em que não há efeitos diretos nem residuais de tratamentos, todos os modelos considerados apresentaram, para efeitos diretos ou residuais de tratamentos, taxas de erro aproximadamente igual a 5%, como seria esperado.

Note que se a probabilidade de rejeição de uma certa hipótese H_0 de nulidade para um conjunto simulado de dados for $p = 0,05$, então a proporção $\hat{p}$ de conjuntos em que há rejeição de H_0 dentre 10000 conjuntos simulados, com probabilidade aproximadamente $0,95$, pertencerá ao intervalo $0,05 \pm 1,96\sqrt{\dfrac{0,05 \times 0,95}{10000}} = 0,05 \pm 0,0043 = [0,0457; 0,0543]$ e com probabilidade aproximadamente $0,99$, pertencerá ao intervalo $[0,0444; 0,0556]$.

No caso II, em que há somente efeitos de tratamentos, quando se utiliza o

modelo com ajuste sequencial de efeitos residuais, e diretos de tratamentos, houve, para o teste da hipótese de existência de efeitos residuais, $23,1\%$ de conclusões erradas, muito superior à esperada, 5%. Este fato revela o cuidado que se deve ter quando se utiliza a metodologia de análise proposto por Williams (1949).

No caso III, em que há somente efeitos residuais de tratamentos, a análise usual revela-se inadequada por apresentar, para a hipótese de existência de efeitos diretos, porcentagem nula de conclusões erradas inferior à esperada 5%. Ainda com relação ao teste dessa hipótese, o ajuste sequencial de efeitos diretos e residuais de tratamentos mostrou-se totalmente inadequado por apresentar $35,5\%$ de conclusões erradas, muito superior à esperada, 5%.

No caso IV, em que há efeitos diretos e residuais de tratamentos, mais uma vez o modelo usual se mostrou ineficiente para detectar a presença de efeitos de tratamentos, com apenas $49,4\%$ de conclusões corretas.

Finalmente, considerando-se os quatro casos analisados e que, a priori, não se sabe se há ou não efeitos residuais de um tratamento sobre o seguinte, recomenda-se, no planejamento, que haja a repetição da degustação do último tratamento e que se considere, para a análise, o modelo ortogonal.

4.2 Experimento para a análise sensorial das aguardentes de cana-de-açúcar (cachaças).

A tabela 15 apresenta as análises de variâncias referentes às variáveis observadas: aparência, aroma e sabor.

Nessa tabela observa-se que, para todas as variáveis consideradas, houve efeitos diretos e residuais significativos de tratamentos considerando-se o nível de significância de 5%. Observa-se, ainda, que a não consideração dos efeitos residuais de tratamentos nas análises usuais levou a alterações consideráveis nas conclusões relativas aos testes de hipóteses sobre os efeitos de provadores e de ordens de degustação. Para a variável aparência, tais efeitos passaram a ser não significativos. Por outro lado, para a variável aroma, o efeito de provadores passou a ser significativo.

Para todas as variáveis consideradas pode-se notar um aumento nos quadrados

Tabela 15 - Análises de variâncias das variáveis nota de aparência, aroma e sabor das cachaças considerando-se os modelos com ou sem efeitos residuais de tratamentos

Fonte de	Com efeitos residuais					Sem efeitos residuais				
variação	GL	SQ	QM	F	valor p	GL	SQ	QM	F	valor p
Provadores	9	4,60	0,51	2,23	0,0426	9	4,60	0,51	1,20	0,3192
Ordem	5	4,53	0,91	3,95	0,0057	5	4,53	0,91	2,13	0,0805
Tratamentos										
Direto	4	5,39	1,35	5,86	0,0000	4	5,39	1,35	3,17	0,0233
Residual	4	8,92	2,23	9,71	0,0009	-	-	-	-	-
Resíduos	37	8,49	0,23			41	17,41	0,42		
Total	59	31,93				59	31,93			
Provadores	9	10,68	1,19	2,00	0,0668	9	10,68	1,19	1,40	0,0221
Ordem	5	15,88	3,18	5,36	0,0008	5	15,88	3,18	3,74	0,0070
Tratamentos										
Direto	4	12,78	3,19	5,40	0,0016	4	12,78	3,20	3,76	0,0107
Residual	4	12,92	3,23	5,45	0,0015	-	-	-	-	-
Resíduos	37	21,92	0,59			41	34,84	0,850		
Total	59	74,18				59	74,18			
Provadores	9	24,02	2,67	4,83	0,0003	9	24,02	2,67	3,70	0,0018
Ordem	5	10,75	2,15	3,89	0,0063	5	10,75	2,15	2,98	0,0219
Tratamentos										
Direto	4	20,49	5,12	4,12	0,0073	4	20,49	5,12	7,10	0,0002
Residual	4	9,12	2,28	9,26	0,0000	-	-	-	-	-
Resíduos	37	20,40	0,55			41	29,52	0,72		
Total	59	84,78				59	84,78			

médios residuais e nas diferenças mínimas significativas, para uso no teste de Tukey, apresentadas na tabela 16. Como consequência, certas diferenças de tratamentos, antes consideradas significativas, passaram, na análise usual, a ser consideradas não significativas.

Tabela 16 - Notas médias de aparência, aroma e sabor, e resultados do teste de Tukey considerando-se o nível de significância 5% (médias seguidas por pelo menos uma letra em comum não diferem entre si), utilizando-se o modelo com (MER) e sem (MU) efeito residual do tratamento anterior sobre o seguinte

	Aparência			Aroma			Sabor		
Cachaça	Médias	MER	MU	Médias	MER	MU	Médias	MER	MU
0	8,50	a	a	7,17	b	b	6,17	c	c
1	8,18	a b	a b	8,42	a	a	6,58	bc	bc
2	7,58	b	b	8,08	ab	ab	6,92	bc	bc
3	7,92	b	ab	7,92	ab	ab	7,25	ab	ab
4	8,00	a b	a b	7,33	b	ab	7,83	a	a
d.m.s*	–	0,76	0,56	–	1,07	0,90	–	0,99	0,87

(*)Diferença mínima significativa

A diferença significativa entre as notas médias de aparência das cachaças 0 e 3 passou a não ser detectada na análise usual. O mesmo aconteceu para as notas médias de aroma das cachaças 1 e 4.

Do exposto até aqui, fica evidente a necessidade da inclusão no modelo, dos efeitos residuais de tratamentos assim como do planejamento cuidadoso dos experimentos para análise sensorial.

Como trabalhos a serem desenvolvidos, serão consideradas as variáveis notas como tendo distribuições diferentes da normal e suas análises serão feitas por meio de modelos lineares generalizados. Uma outra extensão será a obtenção e utilização de blocos incompletos balanceados para a vizinhança, para o caso em que o número de tratamentos ou produtos a serem avaliados sequencialmente exceda o máximo estipulado pelos pesquisadores.

5 CONCLUSÕES

Com base nos resultados obtidos, conclui-se que, para o planejamento de ensaios para a análise descritiva quantitativa (ADQ), os quadrados latinos balanceados para vizinhança, com a última coluna repetida, são uma alternativa importante por permitirem que os efeitos diretos de tratamentos sejam obtidos independentemente dos efeitos residuais de tratamento, eventualmente existentes.

REFERÊNCIAS

BAILEY, R.A. Design of fields experiments in the presence of interference between treatments. **School of Mathematical Sciences**, Queen Mary: University of London, 2005. 30p.

BANZATTO, D. A. , KRONKA, S. N. **Experimentação agrícola.** Jaboticabal : Funep, 1989. 247 p.

BARBIN, D. **Planejamento e análise estatística de experimentos agronômicos.** Arapongas: Midas, 2003. 208 p.

BEHRENS,J. H., SILVA, M. A. A. P. Perfil sensorial de vinhos brancos varietais brasileiros através de análise descritiva quantitativa. **Ciência e Tecnologia de Alimentos**. Campinas, v. 20 n. 1, 2000.

BOLINI, H. M. A.; SILVA, M. A. A. P.; DAMÁSIO, M. H. Análise descritiva quantitativa de edulcorantes em diferentes concentrações. **Ciência e Tecnologia de Alimentos**, Campinas, v. 20, n. 3, p. 318-328, 2000

CAMPOS, H. de. **Estatística aplicada à experimentação com cana-de-açúcar.** Piracicaba: FEALQ., 1984. 292 p.

CHAVES, J.C.S., SPROESSER, R.L. **Práticas de laboratório de análise sensorial de alimentos e bebidas.** Viçosa: Universidade Federal de Viçosa, 1996. 81p.

COCHRAN, G.C., COX, G.M. **Experimental designs.** John Wiley: New York, 1957. 614p.

DURIER, C., MONOD, H., BRUETSCHY, A. Designs and analysis of factorial sensory experiments with carry-over effects. **Food Quality and Preference**, Versailles, v.8, n. 2, p.141-149, 1997.

DUTCOSKY, S.D. **Análise sensorial de alimentos**. Curitiba: Champagnat, 1996. 123p.

GROPPO, V. D. **Laranja "Pêra"(Citrus sinensis L. Osbeck) minimamente processada:** efeito de cloreto de cálcio e película de alginato de sódio na fisiologia e conservação. 2007. 98 p. Dissertação (Mestrado em Ciências. Área de Concentração: Ciência e Tecnologia de Alimentos) - Escola Superior de Agricultura "Luiz de Queiroz". Universidade de São Paulo, Piracicaba, 2007.

IEMMA, A. F.; PALM, R. Les matrices inverses generalisées et utilisation dans le modele linéaire. **Notes de Statistique et D'informatique, Faculté des Sciences Agronomiques.** Gembloux, v.92, n.1, p.1-26, 1992.

IEMMA, A. F. Que hipóteses testamos através dos SAS em presença de caselas vazias? **Scientia Agricola,** Piracicaba, v.52, n.2, p.209 - 219, 1995-c.

LEA, P., NAES, T., RODBOTTEN, M. **Analysis of variance for sensory Data.** New York: John Wiley, 1998. 100p.

LUCAS, H.L., **Switch-back trials for more than two treatments**. J. Dairy Science, v.39, n.2, p.146-54, 1956.

MAGALHÃES, F.A.R. **Métodos descritivos e avaliação sensorial de doce de leite pastoso.** 1996. 83p. Dissertação (Mestrado em Ciência e Tecnologia de Alimentos) - Universidade Federal de Viçosa, Viçosa, 1996.

MONTGOMERY, D. C.**Design and analysis of experiments.** 2.ed., New York: John Wiley, 1984. 538 p.

MORAES, M.C.A. **Métodos para avaliação sensorial dos alimentos.** 8. ed. Campinas: Unicamp, 1993. 93p.

MOSKOWITZ, H.R. **Applied sensory analysis of foods.** Boca Ratton: CRC Press, 1988. 259p.

OMAN, S. D., SEIDEN, E. Switch-back Designs. **Biometrika** , Great Britain, v.75, n. 1, p.88-89, 1988.

PIMENTEL-GOMES, F.**Curso de estatística experimental.** 11 ed. São Paulo: Nobel, 1990. 465p.

PIMENTEL-GOMES, F., GARCIA, C.H. **Estatística aplicada a experimentos agronômicos e florestais.** Piracicaba: FEALQ, 2002. 307 p.

PETTERSON, H. D., LUCAS, H.L. Change-over designs. **North Carolina Agricultural Experimental Station Technical Bulletin**. n. 147, 1962.

SALGADO, J. M.; CARRER, J. C.; DANIELI, F. Avaliação sensorial de maionese tradicional e maionese enriquecida com ervas aromáticas. **Ciência e Tecnologia de Alimentos**, Campinas, v.26, n.4, p.731-734, 2006.

STEEL,R. G. D., TORRIE, J. H. **Principles and procedures of statistics : a biometrical approach.** 2. ed. New York : McGraw-Hill, 1980. 633 p.

STONE, H., SIDEL, J.L. **Sensory evaluation practices.** 2.ed. London: Academic Press, 1993. 337p.

WILLIAMS, E.J. Experimental designs for the estimation of residual effects of treatments. **Australian Journal of Scientific Research**, Series A: Physical Sciences, v.2, p.149-168, 1949.

APÊNDICES

APÊNDICE A - Programa para análise dos dados do experimento

```
rm(list=ls())
library(lme4)
library(lattice)
require(graphics)
library(nlme)
library(splines)

t=5                 # número de tratamentos
p<-10               # número de provadores

a=seq(1:p)
provador=rep(rep(a,each=t+1),1 )

b=seq(1:(t+1))
ordem=rep(b,p)

trat= c(0,1,4,2,3,3,1,2,0,3,4,4,2,3,1,4,0,0,3,4,2,0,1,1,4,0,3,1,2,2,0,4,1,3,2,2,1,0,
2,4,3,3,2,1,3,0,4,4,3,2,4,1,0,0,4,3,0,2,1,1)# tratamentos fixados

efr= c(10,0,1,4,2,3,10,1,2,0,3,4,10,2,3,1,4,0,10,3,4,2,0,1,10,4,0,3,1,2,10,0,4,1,
3,2,10,1,0,2,4,3,10,2,1,3,0,4,10,3,2,4,1,0,10,4,3,0,2,1)

aparencia<- c(9,8,9,8,8,8,
7,8,8,7,8,7,
8,7,8,9,9,9,
8,8,7,9,7,9,
8,7,8,9,8,7,
8,7,8,9,8,8,
```

```
8,9,7,9,8,9,
7,8,8,9,8,7,
8,7,8,8,9,7,
8,7,9,8,9,9)

aroma<-c(8,8,6,9,8,7,
6,6,6,8,7,9,
8,8,9,8,8,8,
6,6,8,7,9,9,
6,7,9,8,9,8,
6,9,9,8,8,9,
8,6,9,7,9,9,
8,9,7,9,8,9,
7,6,7,9,6,8,
6,9,7,9,9,8)

sabor<-c(5,6,6,4,8,7,
5,5,5,7,8,8,
7,6,6,7,7,8,
7,8,7,7,7,8,
8,6,9,9,8,9,
6,9,7,7,8,7,
6,5,8,6,7,7,
6,7,8,7,9,9,
7,7,8,5,5,7,
8,7,6,7,7,6)

########################################### Dados

QL<- data.frame(provador,ordem, trat, efr, aparencia, aroma, sabor)
```

```
summary(QL)
provador  <- as.factor(provador)
ordem <- as.factor(ordem)
trat   <- as.factor(trat)
efr    <- as.factor(efr)
attach(QL)

# Aparência - Modelo Proposto

ML11<-lm(aparencia~provador+ordem+trat+efr)
an11<-anova(ML11)
TukeyHSD(aov(ML11),"trat",ordered=TRUE)

# Aparência - Modelo Usual

ML12<-lm(aparencia~provador+ordem+trat)
an12<-anova(ML12)
TukeyHSD(aov(ML12),"trat",ordered=TRUE)

par(mfrow=c(1,2)) # dois gráficos na janela
plot(TukeyHSD(aov(ML11),"trat",ordered=TRUE))
plot(TukeyHSD(aov(ML12),"trat",ordered=TRUE))

# Aroma - Modelo Proposto

ML21<-lm(aroma~provador+ordem+trat+efr)
an21<-anova(ML21)
TukeyHSD(aov(ML21),"trat",ordered=TRUE)

#Aroma - Modelo Usual
```

```
ML22<-lm(aroma~provador+ordem+trat)
an22<-anova(ML22)
TukeyHSD(aov(ML22),"trat",ordered=TRUE)

par(mfrow=c(1,2)) # dois gráficos na janela
plot(TukeyHSD(aov(ML21),"trat",ordered=TRUE))
plot(TukeyHSD(aov(ML22),"trat",ordered=TRUE))

# Sabor - Modelo Proposto

ML31<-lm(sabor~provador+ordem+trat+efr)
an31<-anova(ML31)
TukeyHSD(aov(ML31),"trat",ordered=TRUE)

#Sabor - Modelo Usual

ML32<-lm(sabor~provador+ordem+trat)
an32<-anova(ML32)
TukeyHSD(aov(ML32),"trat",ordered=TRUE)

par(mfrow=c(1,2)) # dois gráficos na janela
plot(TukeyHSD(aov(ML31),"trat",ordered=TRUE))
plot(TukeyHSD(aov(ML32),"trat",ordered=TRUE))
```

APÊNDICE B - Programa para a simulação sem efeito residual e sem efeito de tratamento

```
rm(list=ls())
set.seed(1)
library(lme4)
library(lattice)
library(nlme)
library(splines)

t=6                 # número de tratamentos
p<-t                # número de provadores

a=seq(1:t)
a_1=seq(1:(t+1))
provador=rep(rep(a,each=t),1 )
provador_1=rep(rep(a,each=t+1),1 )

ordem=rep(a,t)
ordem_1=rep(a_1,t)

trat= c(3,6,2,5,4,1,5,3,4,6,1,2,1,4,5,2,6,3,2,1,6,4,3,5,6,5,1,3,2,4,4,2,3,1,
5,6) # tratamentos fixados

trat_1= c(3,6,2,5,4,1,1,5,3,4,6,1,2,2,1,4,5,2,6,3,3,2,1,6,4,3,5,5,6,5,1,3,2,
4,4,4,2,3,1,5,6,6) # tratamentos fixados

efr= c(0,3,6,2,5,4,0,5,3,4,6,1,0,1,4,5,2,6,0,2,1,6,4,3,0,6,5,1,3,2,0,4,2,3,1,5)
efr_1= c(0,3,6,2,5,4,1,0,5,3,4,6,1,2,0,1,4,5,2,6,3,0,2,1,6,4,3,5,0,6,5,1,3,2,4,
0,4,2,3,1,5,6)
```

```
y<- c(56.7,53.8,54.4,54.4,58.9,54.5,58.5,60.2,61.3,54.4,59.1,59.8,55.7,60.7,
56.7,59.9,56.6,59.6,57.3,57.7,55.2,58.1,60.2,60.2,53.7,57.1,59.2,58.9,58.9,
59.6,58.1,55.7,58.9,56.6,59.6,57.5)

y_1<- c(56.7,53.8,54.4,54.4,58.9,54.5,55.5,58.5,60.2,61.3,54.4,59.1,59.8,55.5,
55.7,60.7,56.7,59.9,56.6,59.6,55.5,57.3,57.7,55.2,58.1,60.2,60.2,55.5,53.7,
57.1,59.2,58.9,58.9,59.6,55.5,58.1,55.7,58.9,56.6,59.6,57.5,55.5)

##################################Dados

QL<- data.frame(provador,ordem, trat, efr, y)
QL_1<- data.frame(provador_1,ordem_1, trat_1, efr_1, y_1)
summary(QL)
summary(QL_1)
provador  <- as.factor(provador)
ordem <- as.factor(ordem)
trat   <- as.factor(trat)
efr    <- as.factor(efr)
provador_1  <- as.factor(provador_1)
ordem_1 <- as.factor(ordem_1)
trat_1   <- as.factor(trat_1)
efr_1    <- as.factor(efr_1)
attach(QL)
attach(QL_1)

ML1<-lm(y~provador+ordem+trat+efr) # ajuste direto + residual
anova(ML1)
ML2<-lm(y~provador+ordem+efr+trat) # ajuste residual + direto
anova(ML2)
ML3 <-lm(y~provador+ordem+trat) # modelo usual
```

```
anova(ML3)

ML_1<-lm(y_1~provador_1+ordem_1+trat_1+efr_1)# ajuste direto + residual
anova(ML_1)
ML_2<-lm(y_1~provador_1+ordem_1+efr_1+trat_1) # ajuste residual + direto
anova(ML_2)
ML_3 <-lm(y_1~provador_1+ordem_1+trat_1) # modelo usual
anova(ML_3)

X <- model.matrix(ML1)
teta <- matrix(c(6,2,1,1,-2,-1,-1,0,0,1,2,0,0,0,0,0,0,0,0,0,0,0),nrow=22,ncol=1)
X%*%teta

X_1 <- model.matrix(ML_1)
teta_1 <- c(6,2,1,1,-2,-1,-1,0,0,1,2,1,0,0,0,0,0,0,0,0,0,0,0)
X_1%*%teta_1

# modelo 1  trat+res
ind11<-NULL
ind12<-NULL
ind13<-NULL
ind14<-NULL

#modelo 2  res+trat
ind21<-NULL
ind22<-NULL
ind23<-NULL
ind24<-NULL

#modelo 3 Usual
```

```
ind31<-NULL
ind32<-NULL
ind33<-NULL

#modelo 4 ortogonal
ind41<-NULL
ind42<-NULL
ind43<-NULL
ind44<-NULL

#modelo 5 ortogonal   apenas para conferência
ind51<-NULL
ind52<-NULL
ind53<-NULL
ind54<-NULL

ind11.draw<-NULL
ind12.draw<-NULL
ind13.draw<-NULL
ind14.draw<-NULL

ind21.draw<-NULL
ind22.draw<-NULL
ind23.draw<-NULL
ind24.draw<-NULL

ind31.draw<-NULL
ind32.draw<-NULL
ind33.draw<-NULL
```

```
ind41.draw<-NULL
ind42.draw<-NULL
ind43.draw<-NULL
ind44.draw<-NULL

ind51.draw<-NULL
ind52.draw<-NULL
ind53.draw<-NULL
ind54.draw<-NULL

for(i in 1:10000){

r<- rnorm(36,sd=0.5)
b<- rnorm(6,sd=0.5)

r_1<- c(r[1:6], b[1], r[7:12], b[2],r[13:18], b[3],r[19:24], b[4],r[25:30], b[5],
r[31:36], b[6])

y1 <- (X%*%teta +r)
y_1 <- (X_1%*%teta_1 +r_1)
ML1<-lm(y1~provador+ordem+trat+efr)
ML2<-lm(y1~provador+ordem+efr+trat)
ML3<-lm(y1~provador+ordem+trat)
ML4<- lm(y_1~provador_1+ordem_1+trat_1+efr_1)
ML5<- lm(y_1~provador_1+ordem_1+efr_1+trat_1)

#armazenando na memória os valores dos p-valores de efeito de tratamento e residual

efprov1<-anova(ML1)$Pr[1]
eford1<-anova(ML1)$Pr[2]
```

```
eftrat1<- anova(ML1)$Pr[3]
efres1<- anova(ML1)$Pr[4]

efprov2<-anova(ML2)$Pr[1]
eford2<-anova(ML2)$Pr[2]
eftrat2<- anova(ML2)$Pr[4]
efres2<- anova(ML2)$Pr[3]

efprov3<-anova(ML3)$Pr[1]
eford3<-anova(ML3)$Pr[2]
eftrat3<- anova(ML3)$Pr[3]

efprov4<-anova(ML4)$Pr[1]
eford4<-anova(ML4)$Pr[2]
eftrat4<- anova(ML4)$Pr[3]
efres4<- anova(ML4)$Pr[4]

efprov5<-anova(ML5)$Pr[1]
eford5<-anova(ML5)$Pr[2]
eftrat5<- anova(ML5)$Pr[4]
efres5<- anova(ML5)$Pr[3]

ind11[i]<-  ifelse(efprov1<0.05, 1, 0)
ind11.draw=ind11[i]
ind12[i]<-  ifelse(eford1<0.05, 1, 0)
ind12.draw=ind12[i]
ind13[i]<-  ifelse(eftrat1<0.05, 1, 0)
ind13.draw=ind13[i]
ind14[i]<-  ifelse(efres1<0.05, 1, 0)
ind14.draw=ind14[i]
```

```
ind21[i]<-  ifelse(efprov2<0.05, 1, 0)
ind21.draw=ind21[i]
ind22[i]<-  ifelse(eford2<0.05, 1, 0)
ind22.draw=ind22[i]
ind23[i]<-  ifelse(eftrat2<0.05, 1, 0)
ind23.draw=ind23[i]
ind24[i]<-  ifelse(efres2<0.05, 1, 0)
ind24.draw=ind24[i]

ind31[i]<-  ifelse(efprov3<0.05, 1, 0)
ind31.draw=ind31[i]
ind32[i]<-  ifelse(eford3<0.05, 1, 0)
ind32.draw=ind32[i]
ind33[i]<-  ifelse(eftrat3<0.05, 1, 0)
ind33.draw=ind33[i]

ind41[i]<-  ifelse(efprov4<0.05, 1, 0)
ind41.draw=ind41[i]
ind42[i]<-  ifelse(eford4<0.05, 1, 0)
ind42.draw=ind42[i]
ind43[i]<-  ifelse(eftrat4<0.05, 1, 0)
ind43.draw=ind43[i]
ind44[i]<-  ifelse(efres4<0.05, 1, 0)
ind44.draw=ind44[i]

ind51[i]<-  ifelse(efprov5<0.05, 1, 0)
ind51.draw=ind51[i]
ind52[i]<-  ifelse(eford5<0.05, 1, 0)
ind52.draw=ind52[i]
ind53[i]<-  ifelse(eftrat5<0.05, 1, 0)
```

```
ind53.draw=ind53[i]
ind54[i]<-  ifelse(efres5<0.05, 1, 0)
ind54.draw=ind54[i]
}

a<-(sum(ind11)/10000)*100
b<-(sum(ind12)/10000)*100
c<-(sum(ind13)/10000)*100
d<-(sum(ind14)/10000)*100

e<-(sum(ind21)/10000)*100
f<-(sum(ind22)/10000)*100
g<-(sum(ind23)/10000)*100
h<-(sum(ind24)/10000)*100

i<-(sum(ind31)/10000)*100
j<-(sum(ind32)/10000)*100
k<-(sum(ind33)/10000)*100

m<-(sum(ind41)/10000)*100
n<-(sum(ind42)/10000)*100
o<-(sum(ind43)/10000)*100
u<-(sum(ind44)/10000)*100

v<-(sum(ind51)/10000)*100
x<-(sum(ind52)/10000)*100
w<-(sum(ind53)/10000)*100
z<-(sum(ind54)/10000)*100
```

APÊNDICE C - Programa para a simulação sem efeito residual e com efeito de tratamento

```
rm(list=ls())
set.seed(2)
library(lme4)
library(lattice)
library(nlme)
library(splines)

t=6                 # número de tratamentos
p<-t                # número de provadores

a=seq(1:t)
a_1=seq(1:(t+1))
provador=rep(rep(a,each=t),1 )
provador_1=rep(rep(a,each=t+1),1 )

ordem=rep(a,t)
ordem_1=rep(a_1,t)

trat= c(3,6,2,5,4,1,5,3,4,6,1,2,1,4,5,2,6,3,2,1,6,4,3,5,6,5,1,3,2,4,4,2,3,1,
5,6) # tratamentos fixados

trat_1= c(3,6,2,5,4,1,1,5,3,4,6,1,2,2,1,4,5,2,6,3,3,2,1,6,4,3,5,5,6,5,1,3,2,4,
4,4,2,3,1,5,6,6) # tratamentos fixados

efr= c(0,3,6,2,5,4,0,5,3,4,6,1,0,1,4,5,2,6,0,2,1,6,4,3,0,6,5,1,3,2,0,4,2,3,1,5)
efr_1= c(0,3,6,2,5,4,1,0,5,3,4,6,1,2,0,1,4,5,2,6,3,0,2,1,6,4,3,5,0,6,5,1,3,2,4,0,
4,2,3,1,5,6)
```

```
y<- c(56.7,53.8,54.4,54.4,58.9,54.5,58.5,60.2,61.3,54.4,59.1,59.8,55.7,60.7,
56.7,59.9,56.6,59.6,57.3,57.7,55.2,58.1,60.2,60.2,53.7,57.1,59.2,58.9,58.9,
59.6,58.1,55.7,58.9,56.6,59.6,57.5)

y_1<- c(56.7,53.8,54.4,54.4,58.9,54.5,55.5,58.5,60.2,61.3,54.4,59.1,59.8,55.5,
55.7,60.7,56.7,59.9,56.6,59.6,55.5,57.3,57.7,55.2,58.1,60.2,60.2,55.5,53.7,
57.1,59.2,58.9,58.9,59.6,55.5,58.1,55.7,58.9,56.6,59.6,57.5,55.5)

##############################################################Dados

QL<- data.frame(provador,ordem, trat, efr, y)
QL_1<- data.frame(provador_1,ordem_1, trat_1, efr_1, y_1)
summary(QL)
summary(QL_1)
provador  <- as.factor(provador)
ordem <- as.factor(ordem)
trat   <- as.factor(trat)
efr    <- as.factor(efr)
provador_1  <- as.factor(provador_1)
ordem_1 <- as.factor(ordem_1)
trat_1   <- as.factor(trat_1)
efr_1    <- as.factor(efr_1)
attach(QL)
attach(QL_1)

ML1<-lm(y~provador+ordem+trat+efr) # ajuste direto + residual
anova(ML1)
ML2<-lm(y~provador+ordem+efr+trat) # ajuste residual + direto
anova(ML2)
ML3 <-lm(y~provador+ordem+trat) # Modelo usual
```

```
anova(ML3)

ML_1<-lm(y_1~provador_1+ordem_1+trat_1+efr_1) # ajuste direto + residual
anova(ML_1)
ML_2<-lm(y_1~provador_1+ordem_1+efr_1+trat_1) # ajuste residual + direto
anova(ML_2)
ML_3 <-lm(y_1~provador_1+ordem_1+trat_1) # Modelo usual
anova(ML_3)

X <- model.matrix(ML1)
teta <- matrix(c(6,2,1,1,-2,-1,-1,0,0,1,2,-2,1,0,-1,0,0,0,0,0,0,0),nrow=22,ncol=1)
X%*%teta

X_1 <- model.matrix(ML_1)
teta_1 <- c(6,2,1,1,-2,-1,-1,0,0,1,2,1,-2,1,0,-1,0,0,0,0,0,0,0)
X_1%*%teta_1

# modelo 1  trat+res
ind11<-NULL
ind12<-NULL
ind13<-NULL
ind14<-NULL

#modelo 2  res+trat
ind21<-NULL
ind22<-NULL
ind23<-NULL
ind24<-NULL

#modelo 3 Usual
```

```
ind31<-NULL
ind32<-NULL
ind33<-NULL

#modelo 4 ortogonal
ind41<-NULL
ind42<-NULL
ind43<-NULL
ind44<-NULL

#modelo 5 ortogonal   apenas para conferência
ind51<-NULL
ind52<-NULL
ind53<-NULL
ind54<-NULL

ind11.draw<-NULL
ind12.draw<-NULL
ind13.draw<-NULL
ind14.draw<-NULL

ind21.draw<-NULL
ind22.draw<-NULL
ind23.draw<-NULL
ind24.draw<-NULL

ind31.draw<-NULL
ind32.draw<-NULL
ind33.draw<-NULL
```

```
ind41.draw<-NULL
ind42.draw<-NULL
ind43.draw<-NULL
ind44.draw<-NULL

ind51.draw<-NULL
ind52.draw<-NULL
ind53.draw<-NULL
ind54.draw<-NULL

for(i in 1:10000){

r<- rnorm(36,sd=0.5)
b<- rnorm(6,sd=0.5)

r_1<- c(r[1:6], b[1], r[7:12], b[2],r[13:18], b[3],r[19:24], b[4],r[25:30], b[5],
r[31:36], b[6])

y1 <- (X%*%teta +r)
y_1 <- (X_1%*%teta_1 +r_1)
ML1<-lm(y1~provador+ordem+trat+efr)
ML2<-lm(y1~provador+ordem+efr+trat)
ML3<-lm(y1~provador+ordem+trat)
ML4<- lm(y_1~provador_1+ordem_1+trat_1+efr_1)
ML5<- lm(y_1~provador_1+ordem_1+efr_1+trat_1)

#armazenando na memória os valores dos p-valores de efeito de tratamento e residual

efprov1<-anova(ML1)$Pr[1]
eford1<-anova(ML1)$Pr[2]
```

```
eftrat1<- anova(ML1)$Pr[3]
efres1<- anova(ML1)$Pr[4]

efprov2<-anova(ML2)$Pr[1]
eford2<-anova(ML2)$Pr[2]
eftrat2<- anova(ML2)$Pr[4]
efres2<- anova(ML2)$Pr[3]

efprov3<-anova(ML3)$Pr[1]
eford3<-anova(ML3)$Pr[2]
eftrat3<- anova(ML3)$Pr[3]

efprov4<-anova(ML4)$Pr[1]
eford4<-anova(ML4)$Pr[2]
eftrat4<- anova(ML4)$Pr[3]
efres4<- anova(ML4)$Pr[4]

efprov5<-anova(ML5)$Pr[1]
eford5<-anova(ML5)$Pr[2]
eftrat5<- anova(ML5)$Pr[4]
efres5<- anova(ML5)$Pr[3]

ind11[i]<-  ifelse(efprov1<0.05, 1, 0)
ind11.draw=ind11[i]
ind12[i]<-  ifelse(eford1<0.05, 1, 0)
ind12.draw=ind12[i]
ind13[i]<-  ifelse(eftrat1<0.05, 1, 0)
ind13.draw=ind13[i]
ind14[i]<-  ifelse(efres1<0.05, 1, 0)
ind14.draw=ind14[i]
```

```
ind21[i]<-  ifelse(efprov2<0.05, 1, 0)
ind21.draw=ind21[i]
ind22[i]<-  ifelse(eford2<0.05, 1, 0)
ind22.draw=ind22[i]
ind23[i]<-  ifelse(eftrat2<0.05, 1, 0)
ind23.draw=ind23[i]
ind24[i]<-  ifelse(efres2<0.05, 1, 0)
ind24.draw=ind24[i]

ind31[i]<-  ifelse(efprov3<0.05, 1, 0)
ind31.draw=ind31[i]
ind32[i]<-  ifelse(eford3<0.05, 1, 0)
ind32.draw=ind32[i]
ind33[i]<-  ifelse(eftrat3<0.05, 1, 0)
ind33.draw=ind33[i]

ind41[i]<-  ifelse(efprov4<0.05, 1, 0)
ind41.draw=ind41[i]
ind42[i]<-  ifelse(eford4<0.05, 1, 0)
ind42.draw=ind42[i]
ind43[i]<-  ifelse(eftrat4<0.05, 1, 0)
ind43.draw=ind43[i]
ind44[i]<-  ifelse(efres4<0.05, 1, 0)
ind44.draw=ind44[i]

ind51[i]<-  ifelse(efprov5<0.05, 1, 0)
ind51.draw=ind51[i]
ind52[i]<-  ifelse(eford5<0.05, 1, 0)
ind52.draw=ind52[i]
ind53[i]<-  ifelse(eftrat5<0.05, 1, 0)
```

```
ind53.draw=ind53[i]
ind54[i]<-  ifelse(efres5<0.05, 1, 0)
ind54.draw=ind54[i]
}

a<-(sum(ind11)/10000)*100
b<-(sum(ind12)/10000)*100
c<-(sum(ind13)/10000)*100
d<-(sum(ind14)/10000)*100

e<-(sum(ind21)/10000)*100
f<-(sum(ind22)/10000)*100
g<-(sum(ind23)/10000)*100
h<-(sum(ind24)/10000)*100

i<-(sum(ind31)/10000)*100
j<-(sum(ind32)/10000)*100
k<-(sum(ind33)/10000)*100

m<-(sum(ind41)/10000)*100
n<-(sum(ind42)/10000)*100
o<-(sum(ind43)/10000)*100
u<-(sum(ind44)/10000)*100

v<-(sum(ind51)/10000)*100
x<-(sum(ind52)/10000)*100
w<-(sum(ind53)/10000)*100
z<-(sum(ind54)/10000)*100
```

APÊNDICE D - Programa para a simulação com efeito residual e sem efeito de tratamento

```
rm(list=ls())
set.seed(3)
library(lme4)
library(lattice)
library(nlme)
library(splines)

t=6                 # declarando número
p<-t                # número de provadores

a=seq(1:t)
a_1=seq(1:(t+1))
provador=rep(rep(a,each=t),1 )
provador_1=rep(rep(a,each=t+1),1 )

ordem=rep(a,t)
ordem_1=rep(a_1,t)

trat= c(3,6,2,5,4,1,5,3,4,6,1,2,1,4,5,2,6,3,2,1,6,4,3,5,6,5,1,3,2,4,4,2,3,1,
5,6) # tratamentos fixados

trat_1= c(3,6,2,5,4,1,1,5,3,4,6,1,2,2,1,4,5,2,6,3,3,2,1,6,4,3,5,5,6,5,1,3,2,
4,4,4,2,3,1,5,6,6) # tratamentos fixados

efr= c(0,3,6,2,5,4,0,5,3,4,6,1,0,1,4,5,2,6,0,2,1,6,4,3,0,6,5,1,3,2,0,4,2,3,1,5)
efr_1= c(0,3,6,2,5,4,1,0,5,3,4,6,1,2,0,1,4,5,2,6,3,0,2,1,6,4,3,5,0,6,5,1,3,2,4,
0,4,2,3,1,5,6)
```

```
y<- c(56.7,53.8,54.4,54.4,58.9,54.5,58.5,60.2,61.3,54.4,59.1,59.8,55.7,60.7,
56.7,59.9,56.6,59.6,57.3,57.7,55.2,58.1,60.2,60.2,53.7,57.1,59.2,58.9,58.9,
59.6,58.1,55.7,58.9,56.6,59.6,57.5)

y_1<- c(56.7,53.8,54.4,54.4,58.9,54.5,55.5,58.5,60.2,61.3,54.4,59.1,59.8,55.5,
55.7,60.7,56.7,59.9,56.6,59.6,55.5,57.3,57.7,55.2,58.1,60.2,60.2,55.5,53.7,
57.1,59.2,58.9,58.9,59.6,55.5,58.1,55.7,58.9,56.6,59.6,57.5,55.5)

##############################################Dados

QL<- data.frame(provador,ordem, trat, efr, y)
QL_1<- data.frame(provador_1,ordem_1, trat_1, efr_1, y_1)
summary(QL)
summary(QL_1)
provador  <- as.factor(provador)
ordem <- as.factor(ordem)
trat   <- as.factor(trat)
efr    <- as.factor(efr)
provador_1  <- as.factor(provador_1)
ordem_1 <- as.factor(ordem_1)
trat_1   <- as.factor(trat_1)
efr_1    <- as.factor(efr_1)
attach(QL)
attach(QL_1)

ML1<-lm(y~provador+ordem+trat+efr)  # ajuste direto + residual
anova(ML1)
ML2<-lm(y~provador+ordem+efr+trat) # ajuste residual + direto
anova(ML2)
ML3 <-lm(y~provador+ordem+trat) # Modelo usual
```

```
anova(ML3)

ML_1<-lm(y_1~provador_1+ordem_1+trat_1+efr_1) # ajuste direto + residual
anova(ML_1)
ML_2<-lm(y_1~provador_1+ordem_1+efr_1+trat_1) # ajuste residual + direto
anova(ML_2)
ML_3 <-lm(y_1~provador_1+ordem_1+trat_1) # Modelo usual
anova(ML_3)

X <- model.matrix(ML1)
teta <- c(6,2,1,1,-2,-1,-1,0,0,1,2,0,0,0,0,0,1,-1,0,0,2,-2)
X%*%teta

X_1 <- model.matrix(ML_1)
teta_1 <- c(6,2,1,1,-2,-1,-1,0,0,1,2,1,0,0,0,0,0,1,-1,0,0,2,-2)
X_1%*%teta_1

# modelo 1  trat+res
ind11<-NULL
ind12<-NULL
ind13<-NULL
ind14<-NULL

#modelo 2  res+trat
ind21<-NULL
ind22<-NULL
ind23<-NULL
ind24<-NULL

#modelo 3 Usual
```

```
ind31<-NULL
ind32<-NULL
ind33<-NULL

#modelo 4 ortogonal
ind41<-NULL
ind42<-NULL
ind43<-NULL
ind44<-NULL

#modelo 5 ortogonal   apenas para conferência
ind51<-NULL
ind52<-NULL
ind53<-NULL
ind54<-NULL

ind11.draw<-NULL
ind12.draw<-NULL
ind13.draw<-NULL
ind14.draw<-NULL

ind21.draw<-NULL
ind22.draw<-NULL
ind23.draw<-NULL
ind24.draw<-NULL

ind31.draw<-NULL
ind32.draw<-NULL
ind33.draw<-NULL
```

```
ind41.draw<-NULL
ind42.draw<-NULL
ind43.draw<-NULL
ind44.draw<-NULL

ind51.draw<-NULL
ind52.draw<-NULL
ind53.draw<-NULL
ind54.draw<-NULL

for(i in 1:10000){

r<- rnorm(36,sd=0.5)
b<- rnorm(6,sd=0.5)

r_1<- c(r[1:6], b[1], r[7:12], b[2],r[13:18], b[3],r[19:24], b[4],r[25:30], b[5],
r[31:36], b[6])

y1 <- (X%*%teta +r)
y_1 <- (X_1%*%teta_1 +r_1)
ML1<-lm(y1~provador+ordem+trat+efr)
ML2<-lm(y1~provador+ordem+efr+trat)
ML3<-lm(y1~provador+ordem+trat)
ML4<- lm(y_1~provador_1+ordem_1+trat_1+efr_1)
ML5<- lm(y_1~provador_1+ordem_1+efr_1+trat_1)

#armazenando na memória os valores dos p-valores de efeito de tratamento e residual

efprov1<-anova(ML1)$Pr[1]
eford1<-anova(ML1)$Pr[2]
```

```
eftrat1<- anova(ML1)$Pr[3]
efres1<- anova(ML1)$Pr[4]

efprov2<-anova(ML2)$Pr[1]
eford2<-anova(ML2)$Pr[2]
eftrat2<- anova(ML2)$Pr[4]
efres2<- anova(ML2)$Pr[3]

efprov3<-anova(ML3)$Pr[1]
eford3<-anova(ML3)$Pr[2]
eftrat3<- anova(ML3)$Pr[3]

efprov4<-anova(ML4)$Pr[1]
eford4<-anova(ML4)$Pr[2]
eftrat4<- anova(ML4)$Pr[3]
efres4<- anova(ML4)$Pr[4]

efprov5<-anova(ML5)$Pr[1]
eford5<-anova(ML5)$Pr[2]
eftrat5<- anova(ML5)$Pr[4]
efres5<- anova(ML5)$Pr[3]

ind11[i]<-  ifelse(efprov1<0.05, 1, 0)
ind11.draw=ind11[i]
ind12[i]<-  ifelse(eford1<0.05, 1, 0)
ind12.draw=ind12[i]
ind13[i]<-  ifelse(eftrat1<0.05, 1, 0)
ind13.draw=ind13[i]
ind14[i]<-  ifelse(efres1<0.05, 1, 0)
ind14.draw=ind14[i]
```

```
ind21[i]<-  ifelse(efprov2<0.05, 1, 0)
ind21.draw=ind21[i]
ind22[i]<-  ifelse(eford2<0.05, 1, 0)
ind22.draw=ind22[i]
ind23[i]<-  ifelse(eftrat2<0.05, 1, 0)
ind23.draw=ind23[i]
ind24[i]<-  ifelse(efres2<0.05, 1, 0)
ind24.draw=ind24[i]

ind31[i]<-  ifelse(efprov3<0.05, 1, 0)
ind31.draw=ind31[i]
ind32[i]<-  ifelse(eford3<0.05, 1, 0)
ind32.draw=ind32[i]
ind33[i]<-  ifelse(eftrat3<0.05, 1, 0)
ind33.draw=ind33[i]

ind41[i]<-  ifelse(efprov4<0.05, 1, 0)
ind41.draw=ind41[i]
ind42[i]<-  ifelse(eford4<0.05, 1, 0)
ind42.draw=ind42[i]
ind43[i]<-  ifelse(eftrat4<0.05, 1, 0)
ind43.draw=ind43[i]
ind44[i]<-  ifelse(efres4<0.05, 1, 0)
ind44.draw=ind44[i]

ind51[i]<-  ifelse(efprov5<0.05, 1, 0)
ind51.draw=ind51[i]
ind52[i]<-  ifelse(eford5<0.05, 1, 0)
ind52.draw=ind52[i]
ind53[i]<-  ifelse(eftrat5<0.05, 1, 0)
```

```
ind53.draw=ind53[i]
ind54[i]<-  ifelse(efres5<0.05, 1, 0)
ind54.draw=ind54[i]
}

a<-(sum(ind11)/10000)*100
b<-(sum(ind12)/10000)*100
c<-(sum(ind13)/10000)*100
d<-(sum(ind14)/10000)*100

e<-(sum(ind21)/10000)*100
f<-(sum(ind22)/10000)*100
g<-(sum(ind23)/10000)*100
h<-(sum(ind24)/10000)*100

i<-(sum(ind31)/10000)*100
j<-(sum(ind32)/10000)*100
k<-(sum(ind33)/10000)*100

m<-(sum(ind41)/10000)*100
n<-(sum(ind42)/10000)*100
o<-(sum(ind43)/10000)*100
u<-(sum(ind44)/10000)*100

v<-(sum(ind51)/10000)*100
x<-(sum(ind52)/10000)*100
w<-(sum(ind53)/10000)*100
z<-(sum(ind54)/10000)*100
```

APÊNDICE E - Programa para a simulação com efeito residual e sem efeito de tratamento

```
rm(list=ls())
set.seed(4)
library(lme4)
library(lattice)
library(nlme)
library(splines)

t=6                 # número de tratamentos
p<-t                # número de provadores

a=seq(1:t)
a_1=seq(1:(t+1))
provador=rep(rep(a,each=t),1 )
provador_1=rep(rep(a,each=t+1),1 )

ordem=rep(a,t)
ordem_1=rep(a_1,t)

trat= c(3,6,2,5,4,1,5,3,4,6,1,2,1,4,5,2,6,3,2,1,6,4,3,5,6,5,1,3,2,4,4,2,3,1,
5,6) # tratamentos fixados

trat_1= c(3,6,2,5,4,1,1,5,3,4,6,1,2,2,1,4,5,2,6,3,3,2,1,6,4,3,5,5,6,5,1,3,2,
4,4,4,2,3,1,5,6,6) # tratamentos fixados

efr= c(0,3,6,2,5,4,0,5,3,4,6,1,0,1,4,5,2,6,0,2,1,6,4,3,0,6,5,1,3,2,0,4,2,3,1,5)
efr_1= c(0,3,6,2,5,4,1,0,5,3,4,6,1,2,0,1,4,5,2,6,3,0,2,1,6,4,3,5,0,6,5,1,3,2,4,
0,4,2,3,1,5,6)
```

```
y<- c(56.7,53.8,54.4,54.4,58.9,54.5,58.5,60.2,61.3,54.4,59.1,59.8,55.7,60.7,
56.7,59.9,56.6,59.6,57.3,57.7,55.2,58.1,60.2,60.2,53.7,57.1,59.2,58.9,58.9,
59.6,58.1,55.7,58.9,56.6,59.6,57.5)

y_1<- c(56.7,53.8,54.4,54.4,58.9,54.5,55.5,58.5,60.2,61.3,54.4,59.1,59.8,55.5,
55.7,60.7,56.7,59.9,56.6,59.6,55.5,57.3,57.7,55.2,58.1,60.2,60.2,55.5,53.7,
57.1,59.2,58.9,58.9,59.6,55.5,58.1,55.7,58.9,56.6,59.6,57.5,55.5)

##############################################Dados
QL<- data.frame(provador,ordem, trat, efr, y)
QL_1<- data.frame(provador_1,ordem_1, trat_1, efr_1, y_1)
summary(QL)
summary(QL_1)
provador  <- as.factor(provador)
ordem <- as.factor(ordem)
trat   <- as.factor(trat)
efr    <- as.factor(efr)
provador_1  <- as.factor(provador_1)
ordem_1 <- as.factor(ordem_1)
trat_1   <- as.factor(trat_1)
efr_1    <- as.factor(efr_1)
attach(QL)
attach(QL_1)

ML1<-lm(y~provador+ordem+trat+efr) # ajuste direto + residual
anova(ML1)
ML2<-lm(y~provador+ordem+efr+trat) # ajuste residual + direto
anova(ML2)
ML3 <-lm(y~provador+ordem+trat) # Modelo usual
anova(ML3)
```

```
ML_1<-lm(y_1~provador_1+ordem_1+trat_1+efr_1) # ajuste direto + residual
anova(ML_1)
ML_2<-lm(y_1~provador_1+ordem_1+efr_1+trat_1) # ajuste residual + direto
anova(ML_2)
ML_3 <-lm(y_1~provador_1+ordem_1+trat_1) # Modelo usual
anova(ML_3)

X <- model.matrix(ML1)
teta <- matrix(c(6,2,1,1,-2,-1,-1,0,0,1,2,-2,1,0,-1,0,1,-1,0,0,2,-2), nrow=22,ncol=1)
X%*%teta

X_1 <- model.matrix(ML_1)
teta_1 <- c(6,2,1,1,-2,-1,-1,0,0,1,2,1,-2,1,0,-1,0,1,-1,0,0,2,-2)
X_1%*%teta_1

# modelo 1  trat+res
ind11<-NULL
ind12<-NULL
ind13<-NULL
ind14<-NULL

#modelo 2  res+trat
ind21<-NULL
ind22<-NULL
ind23<-NULL
ind24<-NULL

#modelo 3 Usual
ind31<-NULL
ind32<-NULL
```

```
ind33<-NULL

#modelo 4 ortogonal
ind41<-NULL
ind42<-NULL
ind43<-NULL
ind44<-NULL

#modelo 5 ortogonal   apenas para conferência
ind51<-NULL
ind52<-NULL
ind53<-NULL
ind54<-NULL

ind11.draw<-NULL
ind12.draw<-NULL
ind13.draw<-NULL
ind14.draw<-NULL

ind21.draw<-NULL
ind22.draw<-NULL
ind23.draw<-NULL
ind24.draw<-NULL

ind31.draw<-NULL
ind32.draw<-NULL
ind33.draw<-NULL

ind41.draw<-NULL
ind42.draw<-NULL
```

```
ind43.draw<-NULL
ind44.draw<-NULL

ind51.draw<-NULL
ind52.draw<-NULL
ind53.draw<-NULL
ind54.draw<-NULL

for(i in 1:10000){

r<- rnorm(36,sd=0.5)
b<- rnorm(6,sd=0.5)

r_1<- c(r[1:6], b[1], r[7:12], b[2],r[13:18], b[3],r[19:24], b[4],r[25:30], b[5],
r[31:36], b[6])

y1 <- (X%*%teta +r)
y_1 <- (X_1%*%teta_1 +r_1)
ML1<-lm(y1~provador+ordem+trat+efr)
ML2<-lm(y1~provador+ordem+efr+trat)
ML3<-lm(y1~provador+ordem+trat)
ML4<- lm(y_1~provador_1+ordem_1+trat_1+efr_1)
ML5<- lm(y_1~provador_1+ordem_1+efr_1+trat_1)

#armazenando na memória os valores dos p-valores de efeito de tratamento e residual

efprov1<-anova(ML1)$Pr[1]
eford1<-anova(ML1)$Pr[2]
eftrat1<- anova(ML1)$Pr[3]
efres1<- anova(ML1)$Pr[4]
```

```
efprov2<-anova(ML2)$Pr[1]
eford2<-anova(ML2)$Pr[2]
eftrat2<- anova(ML2)$Pr[4]
efres2<- anova(ML2)$Pr[3]

efprov3<-anova(ML3)$Pr[1]
eford3<-anova(ML3)$Pr[2]
eftrat3<- anova(ML3)$Pr[3]

efprov4<-anova(ML4)$Pr[1]
eford4<-anova(ML4)$Pr[2]
eftrat4<- anova(ML4)$Pr[3]
efres4<- anova(ML4)$Pr[4]

efprov5<-anova(ML5)$Pr[1]
eford5<-anova(ML5)$Pr[2]
eftrat5<- anova(ML5)$Pr[4]
efres5<- anova(ML5)$Pr[3]

ind11[i]<-  ifelse(efprov1<0.05, 1, 0)
ind11.draw=ind11[i]
ind12[i]<-  ifelse(eford1<0.05, 1, 0)
ind12.draw=ind12[i]
ind13[i]<-  ifelse(eftrat1<0.05, 1, 0)
ind13.draw=ind13[i]
ind14[i]<-  ifelse(efres1<0.05, 1, 0)
ind14.draw=ind14[i]

ind21[i]<-  ifelse(efprov2<0.05, 1, 0)
ind21.draw=ind21[i]
```

```
ind22[i]<-  ifelse(eford2<0.05, 1, 0)
ind22.draw=ind22[i]
ind23[i]<-  ifelse(eftrat2<0.05, 1, 0)
ind23.draw=ind23[i]
ind24[i]<-  ifelse(efres2<0.05, 1, 0)
ind24.draw=ind24[i]

ind31[i]<-  ifelse(efprov3<0.05, 1, 0)
ind31.draw=ind31[i]
ind32[i]<-  ifelse(eford3<0.05, 1, 0)
ind32.draw=ind32[i]
ind33[i]<-  ifelse(eftrat3<0.05, 1, 0)
ind33.draw=ind33[i]

ind41[i]<-  ifelse(efprov4<0.05, 1, 0)
ind41.draw=ind41[i]
ind42[i]<-  ifelse(eford4<0.05, 1, 0)
ind42.draw=ind42[i]
ind43[i]<-  ifelse(eftrat4<0.05, 1, 0)
ind43.draw=ind43[i]
ind44[i]<-  ifelse(efres4<0.05, 1, 0)
ind44.draw=ind44[i]

ind51[i]<-  ifelse(efprov5<0.05, 1, 0)
ind51.draw=ind51[i]
ind52[i]<-  ifelse(eford5<0.05, 1, 0)
ind52.draw=ind52[i]
ind53[i]<-  ifelse(eftrat5<0.05, 1, 0)
ind53.draw=ind53[i]
ind54[i]<-  ifelse(efres5<0.05, 1, 0)
```

```
ind54.draw=ind54[i]
}

a<-(sum(ind11)/10000)*100
b<-(sum(ind12)/10000)*100
c<-(sum(ind13)/10000)*100
d<-(sum(ind14)/10000)*100

e<-(sum(ind21)/10000)*100
f<-(sum(ind22)/10000)*100
g<-(sum(ind23)/10000)*100
h<-(sum(ind24)/10000)*100

i<-(sum(ind31)/10000)*100
j<-(sum(ind32)/10000)*100
k<-(sum(ind33)/10000)*100

m<-(sum(ind41)/10000)*100
n<-(sum(ind42)/10000)*100
o<-(sum(ind43)/10000)*100
u<-(sum(ind44)/10000)*100

v<-(sum(ind51)/10000)*100
x<-(sum(ind52)/10000)*100
w<-(sum(ind53)/10000)*100
z<-(sum(ind54)/10000)*100
```