

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

**Paradigma de alocação de fatores: uma abordagem metodológica para
compreensão e avaliação de delineamentos experimentais**

Pedro Henrique Massaro da Silveira

Trabalho de conclusão de curso apresentado como parte
dos requisitos para obtenção do título de Engenheiro
Agrônomo.

**Piracicaba
2025**

Pedro Henrique Massaro da Silveira

Paradigma de alocação de fatores: uma abordagem metodológica para compreensão e avaliação de delineamentos experimentais

Orientadora:

Profa. Dra. RENATA ALCARDE SERMARINI

Trabalho de conclusão de curso apresentado como parte dos requisitos para obtenção do título de Engenheiro Agrônomo.

**Piracicaba
2025**

DEDICATÓRIA

Aos meus pais, Vagner e Rosângela,
E a toda minha família.
Com amor e gratidão, por sempre apoiarem meus sonhos.

AGRADECIMENTOS

Gostaria de agradecer a Deus, por sempre estar ao meu lado e me conceder força e sabedoria ao longo desta jornada.

À Escola Superior de Agricultura “Luiz de Queiroz” da Universidade de São Paulo (ESALQ/USP), por toda a formação acadêmica e pelas oportunidades de aprendizado e crescimento que me proporcionou.

A Prof^a Dr^a Renata Alcarde Sermarini, por todos os ensinamentos, pela orientação e por compartilhar seu conhecimento com dedicação e paciência.

Aos amigos que tornaram essa trajetória mais leve e repleta de aprendizados. Agradeço especialmente a Brenda Monis, Camila Godoy, Cristiane Taniguti, Gabriel Mamédio, Gabriel Sales, Guilherme Ambrosano, Heitor Mendonça, João Vitor Calvo, Marina Bernardes, Raissa Krupek, Talissa Floriani, Vitória Bizão e a todos os demais que fizeram parte dessa caminhada.

Ao Departamento de Ciências Exatas da ESALQ/USP, pelo apoio e pela estrutura oferecida durante o desenvolvimento deste trabalho.

À Bayer e a todos os colegas que me acolheram e contribuíram para o meu aprendizado durante o estágio. Em especial, agradeço a Murilo Magno, Mariana Possobom, Gustavo Corazza e Gladson Lopes, com quem tive a oportunidade de aprender e crescer profissionalmente neste último ano.

À minha família - Natália, Matheus, Rosimeiri, Ramilson, Renan, Isabela, Helena, Leandro e Vânia - por todo o amor, carinho e incentivo constante.

E, com todo o meu coração, aos meus pais, Vagner e Rosângela, pelo amor incondicional, pelo apoio em cada passo e por acreditarem sempre nos meus sonhos.

EPÍGRAFE

“O começo de todas as ciências é o espanto
de as coisas serem o que são.”

- *Aristóteles*

“O que sabemos é uma gota,
o que ignoramos é um oceano.”

- *Isaac Newton*

“A ciência não conhece os países,
porque o conhecimento pertence à humanidade
e é a tocha que ilumina o mundo”

- *Louis Pasteur*



SUMÁRIO

RESUMO.....	1
ABSTRACT.....	2
1 INTRODUÇÃO.....	3
2 REVISÃO BIBLIOGRÁFICA.....	5
2.1 Delineamento experimental - Fundamentos e conceitos.....	5
2.2 Experimentos Multifásicos e sua Estrutura.....	8
2.3 Paradigma de alocação de fatores - Conceitos e Aplicações.....	10
2.4 O Pacote dae e sua aplicação no paradigma de alocação de fatores.....	14
3 OBJETIVOS.....	17
4 MATERIAL E MÉTODOS.....	18
4.1 Descrição do experimento de referência.....	18
4.2 Reestruturação e pressuposições do experimento.....	20
4.3 Proposição e avaliação comparativa dos delineamentos.....	21
5 RESULTADOS E DISCUSSÃO.....	23
5.1 Cenário A.....	23
5.2 Cenário B.....	29
5.3 Cenário C.....	33
5.4 Cenário D.....	36
5.5 Discussão Comparativa.....	38
6 CONSIDERAÇÕES FINAIS.....	40
REFERÊNCIAS.....	41
APÊNDICES.....	43

RESUMO

Paradigma de alocação de fatores: uma abordagem metodológica para compreensão e avaliação de delineamentos experimentais

Via de regra, os tratamentos de um experimento são alocados diretamente às parcelas, o que garante menor confundimento e maior eficiência na estimação dos efeitos de interesse. Entretanto, em delineamentos multifásicos ou não ortogonais, a complexidade das alocações aumenta e, por consequência, torna-se menos evidente se a estrutura adotada preserva tais condições ideais. Nesse contexto, este trabalho teve como objetivo demonstrar a aplicabilidade do paradigma de alocação de fatores como ferramenta de apoio ao planejamento e às tomadas de decisões na experimentação. Para tanto, foi conduzido um estudo em que o paradigma foi utilizado no planejamento de um experimento multifásico, adaptado das duas primeiras fases do estudo de Nazareno (2012), com o objetivo de evidenciar sua capacidade de identificar confundimentos e favorecer a compreensão da estrutura experimental. Diante disso, quatro cenários de delineamento - variando entre esquema de parcelas subdivididas e fatorial - foram propostos e avaliados quanto ao confundimento, eficiência dos contrastes, ordem de balanço e esperanças dos quadrados médios. Dentre os cenários avaliados, aqueles que incluíram o fator Repetição na primeira fase, alocado à Posição na segunda, apresentaram delineamentos com menores níveis de confundimento. Mostra-se, assim, a aplicabilidade do paradigma de alocação de fatores como uma abordagem minuciosa para descrição e avaliação dos delineamentos experimentais, contribuindo para decisões mais criteriosas e embasadas durante a experimentação.

Palavras-chave: planejamento experimental; tabela de anatomia; confundimento; eficiência.

ABSTRACT

Factor-allocation paradigm: a methodological approach for understanding and evaluating experimental designs

As a rule, treatments in an experiment are allocated directly to plots, ensuring minimal confounding and greater efficiency in the estimation of the effects of interest. However, in multiphase or nonorthogonal designs, the complexity of the allocations increases, making it less evident whether the adopted structure preserves such ideal conditions. In this context, this study aimed to demonstrate the applicability of the factor-allocation paradigm as a supporting tool for experimental planning and decision-making. To this end, a case study was conducted to apply the paradigm to the planning of a multiphase experiment adapted from the first two phases of Nazareno (2012), with the purpose of highlighting its ability to identify confounding and to enhance understanding of the experimental structure. Based on this, four design scenarios - ranging from split-plot to factorial arrangements - were simulated and evaluated in terms of confounding, contrast efficiency, balance order, and expected mean squares. Among the evaluated scenarios, those that included the factor Replication in the first phase, allocated to Position in the second, resulted in orthogonal designs with lower levels of confounding. Therefore, the study demonstrated the applicability of the factor-allocation paradigm as a detailed and informative approach for describing and evaluating experimental designs, supporting more reasoned and evidence-based decisions throughout the experimentation process.

Keywords: design of experiments (DOE); anatomy table; confounding; efficiency.

1 INTRODUÇÃO

O planejamento experimental consiste na alocação criteriosa de um conjunto de tratamentos a um conjunto de unidades experimentais, de modo a reduzir a influência de grandes fontes de variação sobre a estimação dos efeitos de interesse (Brien e Bailey, 2006). Durante essa etapa, duas formas de confundimento tornam-se preocupações centrais: a mistura entre diferentes contrastes de tratamentos (*aliasing*) e a mistura entre contrastes de tratamentos e contrastes de blocos (*confounding*) (Finney, 1943).

Embora originalmente o confundimento fosse compreendido apenas sob essa ótica restrita, uma abordagem mais ampla, proposta por Brien (2017), o define em: (i) a mistura entre contrastes de diferentes fatores dentro da mesma camada (*aliasing*) e (ii) a mistura entre contrastes de diferentes fatores dentro de camadas distintas, como a camada de tratamentos e a de unidades (*confounding*). Como consequência, todo experimento apresenta algum nível de confundimento (Brien, 2023). Assim, a qualidade de um delineamento experimental não é determinada pela ausência de confundimento, mas pela maneira como ele se apresenta. Um bom delineamento é aquele que gerencia as alocações de tal forma que os efeitos de tratamento se confundam apenas com fontes de variação que se espera serem pequenas e aleatórias, minimizando o impacto sobre a precisão das estimativas e sobre a validade das conclusões (Brien, 2022).

Em delineamentos clássicos, essa conexão entre fases tende a ocorrer de forma automática. Entretanto, tanto em experimentos multifásicos como em delineamentos não ortogonais, a complexidade estrutural pode introduzir novos confundimentos adicionais que impactam diretamente na validade dos resultados e, por vezes, podem passar despercebidos. É notório, portanto, que à medida que os experimentos se tornam mais complexos, o risco de confundimento aumenta, podendo comprometer a eficiência estatística, reduzindo a acurácia das estimativas e, em situações críticas, afetando a validade das inferências (Brien et al., 2023; Sermarini et al., 2020).

Para enfrentar esses desafios, a abordagem do paradigma de alocação de fatores, em conjunto com funções do pacote *dae* (Brien, 2024), têm se mostrado uma abordagem eficaz para a descrição e avaliação da estrutura de delineamentos experimentais. Essa metodologia permite identificar e quantificar as relações de confundimento, bem como avaliar a eficiência na estimação dos contrastes das fontes de variação, oferecendo suporte ao planejamento e à tomada de decisão durante a experimentação (Brien et al., 2023).

Diante do exposto, o presente trabalho tem como objetivo apresentar, a partir do estudo de caso, a aplicação do paradigma de alocação de fatores no planejamento de um experimento multifásico, evidenciando sua capacidade de identificar confundimentos e compreensão da estrutura experimental.

2 REVISÃO BIBLIOGRÁFICA

2.1 Delineamento experimental - Fundamentos e conceitos

O experimento de Park Grass, iniciado em 1856 em Rothamsted, Inglaterra, constitui-se como o mais antigo experimento ecológico contínuo do mundo e permanece como referência na área de experimentação. Desde então, o objetivo central do planejamento experimental continua sendo o mesmo: possibilitar a comparação entre diferentes tratamentos com a mínima influência da variação aleatória, de modo a garantir conclusões válidas e confiáveis (Montgomery, 2017).

Um experimento pode ser definido como um processo no qual observações são geradas, comumente sob condições controladas pelo pesquisador, de modo que os indivíduos avaliados (plantas, animais, entre outros) sejam submetidos a condições específicas, denominadas tratamentos (Andrade e Ogliari, 2007). Dessa forma, o sucesso de um experimento depende de um planejamento minucioso, que deve, ao mesmo tempo, gerenciar potenciais fontes de variação não controladas, a fim que as comparações entre os tratamentos sejam livres de outras possíveis explicações, e manter o delineamento o mais simples possível, sem comprometer os objetivos científicos.

Seguindo esses conceitos, Ronald A. Fisher estabeleceu três fundamentos que sustentam a validade e a eficiência de qualquer experimento: repetição, casualização e controle local (Fisher, 1937). Quando aplicados em conjunto, esses princípios têm como propósito reduzir a variação não controlada e, sobretudo, fornecer uma estimativa válida dessa variação.

O primeiro fundamento, a repetição, consiste na repetição de um tratamento em múltiplas unidades experimentais (parcelas). Sua função primária não é apenas aumentar o número de observações, mas sim fornecer a base para a estimação do erro experimental. O erro experimental é a medida da variabilidade existente entre unidades experimentais que recebem o mesmo tratamento. Sem repetição, é impossível quantificar essa variação natural e, conseqüentemente, determinar se as diferenças observadas entre tratamentos são reais ou meramente fruto do acaso (Box, 1980).

O segundo fundamento, a casualização, refere-se ao processo de alocar os tratamentos às unidades experimentais de tal modo que cada unidade tenha a mesma

probabilidade de receber qualquer um dos tratamentos. Este princípio garante a validade da estimativa do erro experimental e dos testes de significância (Fisher, 1937). A casualização serve para evitar vieses sistemáticos, de seleção ou acidentais, que poderiam ocorrer se o pesquisador alocasse os tratamentos de forma subjetiva. Ao distribuir de forma aleatória os efeitos de fatores não controlados, garante-se que, em média, as comparações entre tratamentos sejam livres de viés.

Por fim, o controle local ou blocagem baseia-se em agrupar as unidades experimentais em blocos homogêneos, de modo que a variabilidade dos blocos seja menor do que entre blocos. Em seguida, os tratamentos são alocados aleatoriamente dentro de cada bloco. Ao fazer isso, a variação associada às diferenças entre os blocos (por exemplo, gradientes de fertilidade no solo) pode ser isolada e removida do erro experimental, tornando o teste mais preciso para detectar diferenças entre os tratamentos (Federer, 1955).

A partir da aplicação desses princípios surgiram os principais delineamentos experimentais, que se consolidaram como referência no campo da experimentação, os quais, de acordo com Andrade e Ogliari (2007), incluem:

- **Delineamento Inteiramente Casualizado (DIC):** Utilizado quando as unidades experimentais são consideradas homogêneas. Os tratamentos são alocados de forma completamente aleatória às unidades, sem qualquer restrição (Princípio da repetição e casualização).
- **Delineamento em Blocos Casualizados (DBC):** Faz-se uso do princípio do controle local em uma direção. É adequado quando há um gradiente de variação conhecido, e os blocos são formados perpendicularmente a esse gradiente (Princípios da repetição, da casualização e do controle local).
- **Delineamento em Quadrado Latino (DQL):** Faz-se uso do controle local em duas direções simultaneamente (linhas e colunas), sendo eficaz para controlar fontes de variação bidimensionais (Princípios da repetição, da casualização e do controle local).
- **Delineamentos em Esquema Fatorial:** Refere-se a uma estrutura de tratamentos. São utilizados para estudar o efeito de dois ou mais fatores de interesse simultaneamente, permitindo a análise não só dos efeitos principais de cada fator, mas também de suas interações. Assim, diferentes estruturas experimentais podem ser combinadas, como a utilização de um DIC para as

unidades experimentais associado a um delineamento em esquema fatorial para a estrutura de tratamentos, entre outras possibilidades.

- **Delineamento em Parcelas Subdivididas:** Nesse delineamento, os fatores de interesse diferem quanto à facilidade de alteração, podendo ser classificados como fáceis ou difíceis de mudar, seja devido a custos, tempo de ajuste ou restrições operacionais (Dean e Voss, 1999). Essa estrutura de tratamentos permite fixar o fator de difícil alteração nas parcelas e combinar os demais fatores nas subparcelas.

Embora esses delineamentos sejam eficazes em muitos cenários, a complexidade experimental pode exigir estruturas não triviais, o que, por sua vez, torna o planejamento experimental substancialmente mais complexo. Nessa fase, uma das principais preocupações é referente ao confundimento de informações. Originalmente, Fisher (1937) e Finney (1943) definiram o conceito de confundimento: *aliasing e confounding*, como a relação entre os contrastes dos tratamentos e a relação entre os contrastes de tratamentos e de blocos, respectivamente.

Contudo, uma visão mais ampla e generalizada, adotada por Brien et al. (2023), que será adotada neste trabalho, define o confundimento (*aliasing e confounding*) como a mistura entre os contrastes da mesma camada e entre camadas diferentes, respectivamente. Uma consequência direta dessa visão é que todo experimento, seja ele aleatorizado ou sistemático, envolve algum nível de confundimento em virtude das alocações que emprega.

Assim, considerando que é impossível separar perfeitamente todos os efeitos de tratamento de todos os efeitos das unidades (Brien, 2022), a qualidade de um delineamento experimental não é medida pela ausência de confundimento, mas pela forma com que ele é sistematicamente controlado. Um bom delineamento é aquele que gerencia as alocações de tal forma que os efeitos de tratamento de interesse se confundam apenas com fontes de variação das unidades que se espera serem pequenas e aleatórias, minimizando o impacto nos resultados e conclusões da análise.

Nesse sentido, o planejamento experimental é uma fase onde se bem planejado, consegue-se garantir que o confundimento não comprometa a validade das inferências. No entanto, a complexidade dos delineamentos não se limita a esses aspectos, avanços na área trouxeram novas perspectivas para o campo da experimentação.

2.2 Experimentos Multifásicos e sua Estrutura

O aumento da complexidade nos delineamentos experimentais pode ocorrer, em parte, devido à presença de delineamentos não ortogonais, nos quais os efeitos dos fatores não podem ser estimados de forma completamente independente, pois há correlação entre os contrastes envolvidos. Isto ocorre devido a restrições operacionais, perdas de unidades, estruturas experimentais que conduzem a delineamentos desbalanceados ou a alocações irregulares, nos quais essa independência entre contrastes não é preservada. Nesses casos, parte da informação destinada a um efeito é compartilhada com outras fontes de variação (Mead, 1990). Além disso, a complexidade pode surgir, também, em experimentos que se desdobram em mais de uma fase, como aqueles em que materiais produzidos no campo são posteriormente processados em laboratório para análises bioquímicas ou sensoriais (Brien, 1983).

Tais experimentos, denominados multifásicos, ocorrem com frequência, embora sua natureza intrínseca muitas vezes não seja devidamente reconhecida (Brien et al., 2011). É comum que cada etapa seja tratada como um experimento independente, negligenciando-se as interdependências entre as fases (Brien, 2022). Essa prática, no entanto, ignora o principal benefício de uma abordagem multifásica: a capacidade de conectar corretamente todas as etapas em um único experimento coeso. A análise integrada permite rastrear com precisão como a variação das fases iniciais se propaga para as posteriores, possibilitando a atribuição adequada dos efeitos dos tratamentos iniciais sobre os resultados finais (Brien, 2017).

O conceito estatístico de experimentos sequenciais foi formalizado por G. A. McIntyre em 1955, que utilizou originalmente o termo '*two-phase experiments*' para descrever situações em que ocorre casualização em cada uma das fases. Segundo McIntyre (1955), a segunda fase tinha como finalidade avaliar o material produzido na primeira, sendo nela mensurada a variável resposta de interesse.

Seu trabalho foi fundamental ao estabelecer três princípios que introduziram esse tipo de delineamento:

- I. **Repetição obrigatória na primeira fase:** Sem repetição na fase inicial, seria impossível obter uma estimativa válida do erro experimental associado aos

tratamentos primários. A repetição na segunda fase, embora desejável, não poderia compensar a ausência de repetição na primeira.

- II. **Avaliação individualizada das unidades experimentais:** cada unidade produzida na primeira fase deve ser avaliada separadamente na segunda. O agrupamento (*pooling*) de amostras antes da segunda fase compromete a estimativa do erro da primeira fase.
- III. **Análise baseada na estrutura da primeira fase:** O objetivo final do delineamento de duas fases, segundo McIntyre, é permitir que os resultados obtidos na segunda fase (por exemplo, médias de análises laboratoriais) possam ser "trazidos de volta" para fatores da primeira fase e mensurar os impactos que eles ocasionaram na variável resposta.

Após os trabalhos de McIntyre, o campo evoluiu significativamente. Brien (1983) classificou os experimentos de duas fases como multicamadas (*multitiered*), e posteriormente, Brien e Bailey (2006) ampliaram a concepção, classificando-os como experimentos com múltiplas alocações (*multiple allocations*). Nessa perspectiva, cada fase corresponde à alocação de um conjunto de fatores alocados (*allocated factors*) - sejam tratamentos ou unidades - a um conjunto de fatores receptores (*recipient factors*) (Brien et al., 2011).

De acordo com Brien (2017), experimentos com múltiplas alocações apresentam três características fundamentais: (i) um ou mais conjuntos de objetos são apenas alocados, nunca receptores; (ii) existe um conjunto de objetos que participa de apenas uma alocação, atuando exclusivamente como receptor nessa etapa; e (iii) todos os demais conjuntos funcionam como receptores em uma alocação e como alocados em uma ou mais alocações subsequentes.

A aplicação desses conceitos tem se expandido a diversas áreas. Um exemplo relevante provém do melhoramento de plantas voltado a características de qualidade, como o rendimento de farinha em trigo e a qualidade de maltagem em cevada. A maioria dessas variáveis é obtida em experimentos multifásicos, nos quais variedades são cultivadas em ensaios de campo (Fase 1) e, posteriormente, amostras são processadas em laboratório (Fase 2). Smith, Lim e Cullis (2006) destacam que, apesar da relevância, a literatura sobre delineamento e análise de tais características qualitativas ainda é limitada.

Tais experimentos frequentemente resultam em dados desbalanceados e incluem múltiplas fontes de variação não-genética e de correlação dentro e entre as fases. O elevado custo das análises laboratoriais, por sua vez, restringe o número total de amostras e inviabiliza a repetição completa. Diante desse desafio, Smith, Lim e Cullis (2006) propuseram delineamentos com repetição parcial em todas as fases (*p-rep designs*), que permitem a utilização de modelos mistos na análise, resultando em ganhos substanciais em termos de ganho genético na seleção.

Esse exemplo ilustra a evolução da área: o reconhecimento da natureza multifásica levou à identificação de desafios práticos - correlações entre fases, dados desbalanceados e múltiplas fontes de variação. Tal como esse exemplo, experimentos multifásicos passaram a ser empregados em diferentes contextos, desde estudos com microarranjos (*microarray*) (Kerr, 2003) até ensaios clínicos com seres humanos (Walwyn e Roberts, 2010).

A complexidade inerente a esses delineamentos, envolvendo múltiplas alocações e fontes de variação, torna o controle do confundimento ainda mais desafiador no momento do planejamento experimental. Problemas como confundimento dentro e entre as camadas (*aliasing* e *confounding*) podem facilmente invalidar as conclusões de um experimento. Torna-se evidente, portanto, a necessidade de uma metodologia que ofereça uma forma sistemática de descrever e avaliar a estrutura completa dos experimentos.

2.3 Paradigma de alocação de fatores - Conceitos e Aplicações

Tradicionalmente, a descrição de delineamentos experimentais é realizada por meio do que Brien et al. (2022) denominam “descrição em único passo” (*single-set description*). Essa abordagem consiste em listar os fatores envolvidos, suas relações de aninhamento e cruzamento, e indicar quais são fixos ou aleatórios, sem detalhar como ocorre a alocação desses fatores durante o experimento. Jarrett, Farewell e Herzberg (2020), por exemplo, ao discutir experimentos multifásicos, propõem a construção de uma tabela semelhante à da Análise de Variância (ANOVA), a qual apresenta as fontes de variação, seus números de graus de liberdade e os quadrados médios esperados (*expected mean squares* – EMS), além de discutir estratégias como análise de subconjuntos, testes de permutação e formulações de modelos lineares abrangentes para planejamento e análise dos dados resultantes. Embora útil, essa prática mantém-se limitada devido à lógica de uma descrição única e não

estrutural, dificultando a visualização clara dos confundimentos gerados pelas alocações dos fatores.

O paradigma de alocação de fatores, desenvolvido por Brien e colaboradores (Brien e Demétrio, 2009; Brien et al., 2011; Brien, 2017; Brien, 2022; Brien et al., 2023), rompe com essa lógica ao enfatizar o processo de alocação dos fatores às unidades experimentais em cada fase, em vez de apenas listá-los no delineamento. Essa mudança desloca a ênfase para o processo de planejamento, permitindo identificar e compreender de forma explícita os confundimentos decorrentes das alocações. Diferentemente de Jarrett, Farewell e Herzberg (2020), que partem de um modelo único ajustado progressivamente, Brien propõe iniciar pelo reconhecimento das alocações dos fatores, representando-as em camadas e diagramas, para então formular o modelo estatístico.

De acordo com Brien et al. (2023),

“O paradigma baseia-se na identificação dos fatores que são alocados (tratamentos) e daqueles que são receptores (unidades), essa caracterização dos fatores enfatiza seus papéis na atribuição dos tratamentos dentro de um delineamento experimental.”.

Ressaltando a importância da caracterização dos fatores no processo de alocação, essa abordagem tem suas origens na distinção entre as estruturas “topográficas” e “de tratamento”, identificada por Fisher (1937) e sistematizada por Brien (1983).

Assim, o paradigma permite compreender o delineamento de forma dinâmica, conectando cada fator e sua alocação ao efeito correspondente na análise. Além disso, a caracterização explícita dos confundimentos oferece suporte tanto para a escolha do modelo adequado quanto para a avaliação do delineamento (Brien et al., 2023).

Diante disso, para sistematizar a descrição do delineamento, o paradigma baseia-se em três elementos centrais: camadas (*tiers*), diagramas de alocação e tabelas de anatomia. O conceito de camadas foi introduzido por Brien (1983) e consolidado em Brien e Bailey (2006). Cada camada corresponde a um conjunto de fatores que descrevem objetos (sejam tratamentos ou unidades) envolvidos em uma etapa de alocação. Essa classificação distingue fatores alocados (geralmente os tratamentos) daqueles receptores (as unidades experimentais), permitindo rastrear o fluxo de informação e variação ao longo das camadas. Em um experimento bifásico, por exemplo, geralmente haverá uma camada para os

tratamentos, outra para as unidades da primeira fase e uma terceira para as unidades da segunda fase.

O conceito de diagramas de alocação, proposto por Brien e Bailey (2009), sintetiza graficamente o delineamento, representando as relações de aninhamento e cruzamento, bem como o tipo de alocação (aleatória ou sistemática). Esses diagramas funcionam como a “planta baixa” do experimento, permitindo visualizar o percurso das alocações e as potenciais fontes de confundimento. São compostos por painéis (cada um representando uma camada) conectados por setas: contínuas para alocações aleatórias e tracejadas para alocações sistemáticas (Brien et al., 2023).

Por último, apresenta-se a tabela de anatomia (*anatomy table*), também chamada de tabela de decomposição (Bailey e Brien, 2009). Essas tabelas são construídas *a priori*, antes da coleta de dados, e expõem a estrutura completa do delineamento. Nessas tabelas, cada linha representa uma fonte de variação com seus respectivos número de graus de liberdade e suas eficiências. Ao contrário das tabelas de ANOVA tradicionais, que apresentam uma única coluna de fontes de variação, as tabelas de anatomia possuem colunas separadas para cada camada. O alinhamento horizontal das fontes de variação entre as colunas revela explicitamente quais fontes de tratamento estão confundidas com quais fontes de variação das unidades.

Dessa maneira, a aplicação do conceito pode ser resumida em cinco etapas principais (Figura 1), conforme descrito por Brien (2022) e Brien *et al.* (2023):




Figura 1. Etapas e produtos resultantes do paradigma de alocação de fatores. Fonte: Brien *et al.*, 2023.

- I. **Modelo antecipado (*Anticipated Model*):** Formulação inicial de um modelo que inclui todos os efeitos que o pesquisador antecipa que ocorrerão,

incluindo as relações de cruzamento e aninhamento entre os fatores das unidades.

- II. **Seleção do Delineamento e Diagrama de Alocação:** Com base no modelo antecipado, um delineamento é escolhido (*A-optimal design*) e sua estrutura completa é visualizada por meio do diagrama de alocação de fatores.
- III. **Modelo de alocação inicial (*Initial Allocation Model*):** Obtenção de um primeiro modelo diretamente do diagrama, a partir das combinações de fatores dentro de cada camada.
- IV. **Modelo de Alocação Homogêneo e *A Priori*:** O modelo inicial é, então, aperfeiçoado. O modelo homogêneo é criado ao se alterar, se necessário, a designação dos termos entre fixos e aleatórios, e adicionar interações entre camadas (como interações bloco-tratamento). Posteriormente, o modelo *a priori* pode ser formulado ao se especificarem estruturas mais complexas de variância e covariância, como autocorrelação ou variâncias heterogêneas.
- V. **Tabela de Anatomia:** Gerada a partir do modelo de alocação para expor a estrutura de confundimento, permitindo uma avaliação completa das propriedades do delineamento.

Dessa forma, conforme resumido por Brien et al. (2023), as principais vantagens dessa metodologia são:

- **Compreensão da distribuição da informação:** A tabela de anatomia fornece uma descrição explícita do confundimento, mostrando como a informação dos tratamentos está distribuída entre as fontes de variação das unidades. Isso permite avaliar o delineamento e identificar o erro apropriado para cada estatística F.
- **Verificação do croqui experimental:** Permite checar se o croqui do experimento foi gerado corretamente, detectando erros de programação ou digitação.
- **Consideração antecipada de interações complexas:** Facilita a consideração de interações bloco-tratamento já na fase de planejamento, em vez de tratá-las como um problema apenas na fase de análise.
- **Deteção de problemas estruturais:** Revela automaticamente problemas como a pseudorreplificação - quando uma fonte de variação das unidades é exaurida - e singularidades no modelo. Neste último caso, permite distinguir

modelos não singulares, cujas matrizes associadas são invertíveis e de posto completo, o que garante a estimação completa e única dos parâmetros e a convergência em software de análise como Sommer e ASReml, de modelos singulares, caracterizados por matrizes não invertíveis decorrentes de dependência linear entre as colunas. Essa dependência impede a estimação completa dos parâmetros, inviabilizando a convergência do modelo (Rencher e Schaalje, 2008).

- **Vantagem pedagógica:** Tornar visível como a informação dos tratamentos se dispersa entre as fontes de variação.

Em síntese, o paradigma de alocação de fatores fornece um arcabouço conceitual e prático que integra o planejamento experimental à modelagem estatística. Ao incluir explicitamente todos os fatores, ele permite que todos os termos relevantes sejam incorporados ao modelo; e, ao expor os confundimentos entre os mesmos, viabiliza o entendimento e avaliação do delineamento. Nesse contexto, o uso dessa metodologia, apoiado por ferramentas computacionais, como a função `'designTwoPhaseAnatomies()'` e `'designAnatomy()'` do pacote *dae* (Brien, 2024), tem contribuído para disseminação da metodologia na etapa de planejamento dos delineamentos experimentais.

2.4 O Pacote *dae* e sua aplicação no paradigma de alocação de fatores

A aplicação do paradigma de alocação de fatores, apresentado no capítulo anterior, tornou-se ainda mais viável na prática com o desenvolvimento de ferramentas computacionais capazes de automatizar cálculos estatísticos complexos. Nesse contexto, Chris Brien desenvolveu o pacote *dae* disponibilizado no CRAN do ambiente de programação R (R Core Team, 2025). O *dae* (*Design and ANOVA of Experiments*) reúne funções voltadas ao planejamento e à análise de delineamentos experimentais, com ênfase na avaliação da anatomia de delineamentos clássicos e multifásicos (Brien, 2024).

De acordo com Brien (2024), o conteúdo do pacote está organizado em diferentes grupos de funções para: (i) manipulação de dados, (ii) manipulação de fatores, (iii) funções de delineamento, (iv) funções de ANOVA, (v) funções matriciais, (vi) funções de projetores e eficiências canônicas e (vii) funções diversas. Além disso, o pacote disponibiliza materiais

explicativos, como a `DesignNotes`, que exemplifica o uso das funções `designRandomize` (para geração de layouts randomizados) e `designAnatomy` (para avaliação das propriedades dos delineamentos), acompanhadas de conjuntos de dados de apoio incluídos no próprio pacote.

Dessa forma, o pacote *dae* representa a ponte entre a teoria e a aplicação prática do paradigma de alocação de fatores, viabilizando a descrição e a avaliação dos delineamentos por meio de funções especializadas. Dentre as funções do pacote, destacam-se aquelas voltadas à obtenção da tabela de anatomia dos delineamentos, fundamentais para a visualização do confundimento e da eficiência de cada fonte de variação:

- I. **`designAnatomy()`** - Esta função, considerada o “motor” do paradigma de alocação de fatores, realiza a análise canônica dos projetores associados às alocações dos fatores e gera a tabela de decomposição correspondente. O procedimento permite identificar confundimentos dentro e entre diferentes conjuntos de fatores. Além disso, a função calcula medidas de eficiência, como a *eficiência A* e a *eficiência E*, que quantificam a qualidade do delineamento em termos de balanceamento e distribuição da informação (Brien, 2024).
- II. **`designTwophaseAnatomies()`** - Voltada a experimentos multifásicos, essa função expande a lógica da anterior ao calcular as anatomias de quatro tipos de delineamentos associados: (i) delineamento bifásico, (ii) delineamento fase única (first-phase), (iii) delineamento cruzado (cross-phase) e (iv) delineamento de unidades combinadas (Brien, 2024). Assim como a `designAnatomy()`, essa função gera tabelas de decomposição e medidas de eficiência, permitindo uma análise detalhada de experimentos que envolvem múltiplas fases de alocação.

Ambas as funções exigem apenas a estrutura de fatores e suas relações, sem necessidade de valores observados. Isso possibilita a avaliação da qualidade do delineamento ainda na etapa de planejamento, uma característica fortemente defendida por Brien et al. (2023) para o processo da experimentação.

Dessa maneira, a combinação do paradigma de alocação de fatores com as funcionalidades do pacote *dae* permite que profissionais, pesquisadores e estudantes,

independentemente do nível de formação estatística, possam compreender e avaliar seus experimentos antes da execução. Essa integração assegura não apenas maior transparência sobre os confundimentos e eficiências envolvidos, mas também fornece subsídios para a formulação de modelos estatísticos adequados às particularidades de cada delineamento (Brien, 2022; Brien et al., 2023).

Portanto, o *dae* não deve ser entendido apenas como um recurso computacional, mas também como uma ferramenta pedagógica que contribui para a compreensão da anatomia dos delineamentos, tornando explícitas as relações entre fatores. Assim, ao alinhar teoria e prática, o pacote favorece a adoção de tabelas de anatomia na experimentação agrícola e em outras áreas das ciências aplicadas, assegurando a consistência metodológica e a interpretabilidade dos resultados (Brien et al., 2023).

3 OBJETIVOS

Demonstrar a aplicabilidade do paradigma de alocação de fatores como uma abordagem metodológica para a descrição, compreensão e avaliação dos delineamentos experimentais, com ênfase tanto em cenários multifásicos, destacando sua contribuição no planejamento e na tomada de decisões ao longo da experimentação. Inclui também, contribuir para a disseminação dessa metodologia, em conjunto com as funcionalidades do pacote *dae* no software R, na literatura em língua portuguesa.

4 MATERIAL E MÉTODOS

A abordagem central deste trabalho consiste na aplicação do paradigma de alocação de fatores, desenvolvido por Brien e colaboradores (Brien, 2017; Brien, 2022; Brien et al., 2023), para a descrição e avaliação dos delineamentos experimentais referente a um estudo de caso.

O estudo tem como foco demonstrar a aplicação do paradigma de alocação de fatores no planejamento de um experimento multifásico, evidenciando sua capacidade na identificação dos confundimentos e compreensão da estrutura experimental. O exemplo foi desenvolvido a partir de uma adaptação das duas primeiras fases do experimento descrito por Nazareno (2012), destacando, também, o papel do paradigma na tomada de decisão quanto ao delineamento mais adequado aos objetivos da pesquisa. Todas as análises e simulações estruturais foram realizadas no software *R* (R Core Team, 2025), com o auxílio do pacote *dae* (Brien, 2024). Todos os *scripts* utilizados encontram-se disponíveis no Apêndice A, ao final deste trabalho.

4.1 Descrição do experimento de referência

O experimento de Nazareno (2012) compreende três fases, das quais apenas as duas primeiras, após algumas pressuposições descritas na seção seguinte, atendem aos critérios de experimentos multifásicos (Página 9) apresentados por Brien (2017).

- I. Um ou mais conjuntos de objetos são apenas alocados, nunca receptores;
- II. Existe um conjunto de objetos que participa de apenas uma alocação, atuando exclusivamente como receptor nessa etapa;
- III. Todos os demais conjuntos funcionam como receptores em uma alocação e como alocados em uma ou mais alocações subsequentes.

O objetivo do estudo original foi avaliar, na primeira fase, os efeitos da idade das matrizes poedeiras e do tempo de estocagem na qualidade dos ovos. Na segunda fase, buscou-se analisar o impacto do transporte do matrizeiro ao incubatório, bem como da posição dos ovos durante esse transporte, sobre a qualidade final dos mesmos. A terceira fase da tese utilizou de novas unidades experimentais sem conexão estrutural com as

anteriores, configurando-se, portanto, como um novo experimento e sendo desconsiderada neste estudo.

Na primeira fase, conduzida em um matrizeiro avícola localizado em Amparo (SP), foram avaliadas três idades de matrizes da linhagem Cobb Fast - nova (29–30 semanas), intermediária (42–43 semanas) e velha (52–53 semanas) - e três intervalos de estocagem dos ovos - T_1 (50–52 h), T_2 (26–30 h) e T_3 (3–6 h).

Quando as matrizes atingiam as idades determinadas, foram coletados 1.440 ovos, divididos em 6 caixas, totalizando 4.320 ovos. Foram pesados 140 ovos por combinação de tratamentos (Idade x Tempo de estocagem). A coleta foi realizada separadamente para cada idade de matriz do mesmo lote, de modo que os tempos de estocagem se encerrassem simultaneamente para o transporte. Assim, três dias antes do transporte foram armazenados 480 ovos; dois dias antes, mais 480; e, no dia do transporte, os 480 restantes. As caixas foram posicionadas no centro da sala, considerada homogênea quanto às condições microclimáticas, conforme resultados prévios de análises geoestatísticas.

A variável resposta foi o percentual de perda de água que foi obtido pela diferença entre os pesos dos ovos medidos na entrada e saída da sala de ovos. Dessa maneira, considerando a homogeneidade do microclima da sala, a autora adotou o delineamento inteiramente casualizado, com estrutura de tratamento em esquema fatorial 3×3 , correspondendo às combinações entre idades de matrizes e tempos de estocagem, com 140 observações cada, correspondendo a cada ovo pesado.

A segunda fase avaliou o transporte dos ovos do matrizeiro ao incubatório. Foram transportados 4.320 ovos (18 caixas correspondentes às amostras utilizadas na primeira fase), distribuídos em três viagens de 1.440 ovos cada, realizadas ao longo do período experimental. As caixas foram dispostas em dois níveis (superior e inferior) dentro do caminhão, com o intuito de avaliar se esse fator influenciava a variável resposta. Na disposição horizontal, as caixas foram posicionadas no centro geométrico da carroceria, de modo a garantir maior uniformidade nas condições microclimáticas nesse sentido.

Durante o transporte, os mesmos 140 ovos individualizados por combinação de tratamento foram novamente avaliados quanto à perda de água, seguindo metodologia idêntica à empregada na primeira fase. Nesta etapa, outros fatores também foram monitorados, como o número de choques e o nível de vibração durante o transporte. Assim,

para cada combinação dos fatores mensurados, foi realizada uma análise específica na tese, todas baseadas em delineamento inteiramente casualizado com esquema fatorial para os fatores de interesse, considerando cada ovo pesado como unidade de observação. Portanto, nota-se que em ambas as fases foram realizadas análises individualizadas e sem incorporar ao modelo a ligação entre elas.

4.2 Reestruturação e pressuposições do experimento

Adota-se a premissa de que o experimento ainda não foi conduzido, permitindo explorar e propor delineamentos alternativos de forma análoga à abordagem de Brien (2022). Dessa forma, o mesmo foi reestruturado sob alguns aspectos a fim de que o estudo presente tenha maior número de cenários possíveis de delineamento e assim consiga demonstrar a aplicabilidade da metodologia. Para tanto, manteve-se a estrutura geral do problema, com um total de 4.320 ovos produzidos, dos quais 1.296 seriam amostrados para pesagem (144 por combinação de tratamentos da primeira fase).

No entanto, as modificações adotados para este estudo de caso foram:

- I. Primeira fase: mantiveram-se os fatores Idade da matriz (3 níveis) e Tempo de estocagem (3 níveis). Contudo, as coletas de ovos para o fator *Idade* ocorreram juntos, tendo aves da mesma linhagem nos três níveis do fator, como também a unidade experimental foi redefinida. Em vez de 6 caixas por idade, assumiu-se que os ovos coletados seriam distribuídos em 18 caixas (parcelas), permitindo maior alternativas de cenário para com os delineamentos.
- II. Segunda fase: mantiveram-se os fatores Viagem (3 níveis) e Posicionamento (2 níveis). Porém variáveis como número de choques e nível de vibração, originalmente mensurados por sensores, foram desconsiderados como fatores de delineamento, pois sua distribuição não seria conhecida previamente. No contexto de um planejamento, tais variáveis seriam tratadas como covariáveis, a serem incluídas no modelo estatístico durante a fase de análise de dados.

Dessa forma, a camada (*tier*) de tratamentos representa o conjunto de objetos que são apenas alocados, nunca receptores. A camada de unidades da fase 1 refere-se ao conjunto de objetos que atuam como receptores em uma alocação e como alocados na alocação subsequente. Por fim, a camada de unidades da fase 2 corresponde ao conjunto de objetos que participam de apenas uma alocação, atuando exclusivamente como receptores nessa etapa. Atende, portanto, aos requisitos de um experimento multifásico, conforme proposto por Brien (2017).

4.3 Proposição e avaliação comparativa dos delineamentos

A partir do cenário reestruturado, foram propostos e comparados quatro delineamentos experimentais diferentes. Os cenários propostos exploram diferentes formas de estruturar e alocar os fatores em ambas as fases, incluindo delineamentos em parcelas subdivididas e em esquema fatorial, com e sem a inclusão do fator de controle *Repetição*.

- **Cenário A:** A primeira fase foi considerada como um delineamento em blocos casualizados em parcelas subdivididas, devido à segregação temporal entre os períodos de coleta dos ovos para o fator *Tempo*. Foi incluído o fator de controle *Repetição* nesta fase, de modo que este se confundisse com o fator *Posição* na segunda fase.
- **Cenário B:** Assim como no cenário anterior, a primeira fase foi estruturada como parcelas subdivididas, considerando a segregação temporal das coletas do fator *Tempo*. No entanto, considerou-se apenas o fator de controle *Bloco*, sem a inclusão do fator *Repetição*.
- **Cenário C:** Neste cenário, a primeira fase foi planejada sob um delineamento em blocos casualizados em esquema fatorial, conforme proposto originalmente por Nazareno (2012). Também, foi incluído o fator de controle *Repetição* nesta fase, de modo que este se confundisse com o fator *Posição* na segunda fase.
- **Cenário D:** Assim como no cenário anterior, adotou-se um delineamento em esquema fatorial na primeira fase, conforme Nazareno (2012). Entretanto, considerou-se apenas o fator de controle *Bloco*, sem a adição do fator *Repetição*.

A construção e avaliação de cada cenário seguiu os passos do paradigma de alocação de fatores, conforme descrito por Brien (2022) e Brien et al. (2023) (Figura 1). Para cada alternativa, o processo iniciou-se com a formulação de um modelo antecipado e a visualização da estrutura por meio de um diagrama de alocação de fatores. Subsequentemente, foram obtidos os modelos de alocação (inicial e homogêneo), que, posteriormente, serviram de base para a geração da tabela de anatomia por meio da função *designTwoPhaseAnatomies()* do pacote *dae* (Brien, 2024).

Por último, a avaliação comparativa dos quatro cenários foi realizada por meio da análise de suas respectivas tabelas de anatomia, destacando os seguintes critérios:

- **Estrutura de Confundimento:** Análise de como os efeitos de tratamento se confundem com as fontes de variação das unidades, tanto dentro de uma mesma camada (*aliasing*) quanto entre camadas diferentes (*confounding*).
- **Eficiência (*A-efficiency*):** Verificou-se a existência de perda de informação na estimação dos efeitos, distinguindo entre delineamentos ortogonais e não ortogonais. Nos casos em que houve perda, verificou-se o nível de perda de eficiência para cada fator.
- **Ordem de Balanço (*Order of Balance*):** Avaliou-se o número de níveis distintos de eficiência observados na determinação dos contrastes associados a um mesmo efeito.
- **Esperança dos Quadrados Médios (EMS):** Análise dos componentes de variância com o objetivo de identificar os erros apropriados para os testes de hipóteses em cada delineamento. As EMS foram calculadas a partir do diagrama de Hasse, os quais encontram-se disponíveis no Apêndice B.

Dessa forma, buscou-se identificar a estrutura experimental que apresentasse o menor nível de confundimento para os fatores de interesse, com a máxima eficiência e a menor ordem de balanço possível.

5 RESULTADOS E DISCUSSÃO

Nesta seção, são apresentados os resultados obtidos a partir da aplicação do paradigma de alocação de fatores para a avaliação e comparação dos quatro cenários de delineamentos experimentais propostos para o experimento multifásico descrito por Nazareno (2012). As análises seguem as etapas metodológicas propostas por Brien e colaboradores (Brien, 2022; Brien et al., 2023).

5.1 Cenário A

Neste cenário, entende-se que o fator *Tempo* gerou uma segregação temporal entre os períodos de coleta dos ovos. Como todos os ovos são provenientes de um mesmo lote de matrizes, torna-se inviável alternar essa coleta de forma a promover uma casualização. Diante disso, a primeira fase do experimento foi estruturada como um delineamento em parcelas subdivididas. Ademais, devido à presença do fator Posição na segunda fase e buscando-se minimizar o confundimento e maximizar a eficiência da análise desse fator, foi incluído o fator de controle Repetição na primeira fase. Este servirá como um fator a ser alocado ao fator Posição na segunda fase.

A partir disso, a abordagem metodológica do paradigma de alocação de fatores inicia-se com a formulação do modelo antecipado, que identifica todos os efeitos a serem considerados, bem como nas relações de cruzamento e aninhamento entre eles no delineamento experimental. Na primeira fase, os fatores alocados são Idade das Matrizes (I) e Tempo de Estocagem (T), enquanto os fatores recipientes são Blocos (B), Repetição (R), Parcelas (P), Subparcelas (S) e Unidades (U). Nessa fase, os fatores I e T encontram-se cruzados, ao passo que os demais fatores recipientes estão hierarquicamente aninhados, do primeiro ao último estrato. Assim, para a primeira fase, obteve-se o seguinte modelo antecipado:

$$Média + T + I + T:I \mid Média + B + B:R + B:R:P + \underline{B:R:P:S} + B:R:P:S:U.$$

É importante destacar que, neste e nos demais modelos a serem apresentados: (i) os termos à esquerda da barra vertical “|”, correspondem aos efeitos fixos, enquanto os termos à direita representam os efeitos aleatórios, (ii) os efeitos de cada termo aleatório são

assumidos como independentes e identicamente distribuídos, e (iii) o termo sublinhado refere-se ao termo de identidade, o qual representa as unidades experimentais do modelo.

Na segunda fase, os fatores alocados são Viagem (V) e Posição (Po), enquanto os fatores recipientes são Parcelas (Q) e Unidades (W) - sendo adotadas essas notações para que não haja ambiguidade com os fatores da primeira fase. Nessa fase, os fatores V e Po encontram-se cruzados, enquanto os fatores recipientes apresentam uma relação de aninhamento do primeiro ao último estrato. Sendo assim, o modelo antecipado para esta fase é descrito como:

$$Média + V + Po + V:Po \mid Média + \underline{V:Po:Q} + V:Po:Q:W.$$

Dessa forma, o modelo antecipado completo para o experimento multifásico resulta da combinação dos modelos antecipados das duas fases, sendo representado por:

$$Média + T * I + V * Po \mid Média + B + B:R + B:R:P + B:R:P:S + B:R:P:S:U + \\ + \underline{V:Po:Q} + V:Po:Q:W.$$

A próxima etapa da metodologia consiste na seleção do delineamento e a construção do diagrama de alocação de fatores. Considerando a estrutura experimental descrita, o delineamento selecionado corresponde a um delineamento em blocos casualizados com parcelas subdivididas para a primeira fase e a um delineamento em blocos para a segunda fase. Entretanto, caso a estrutura ainda estivesse em desenvolvimento, é possível recorrer a três abordagens, conforme discutido por Brien et al. (2023): (i) delineamentos clássicos (por exemplo, DIC, DBC, Quadrado Latino), (ii) catálogos de delineamentos (como em Cochran & Cox, 1957), ou (iii) buscas computacionais.

O diagrama de alocação de fatores (Figura 2) ilustra a estrutura do delineamento adotado. Por se tratar de um experimento de duas fases, o diagrama é composto por três camadas (tiers): uma para os tratamentos da primeira fase, outra para as unidades da primeira fase e a última para as unidades da segunda fase. A seta com linha tracejada indica uma alocação sistemática, enquanto a seta com linha contínua indica uma alocação aleatória entre fatores. Dessa maneira, na primeira fase, o fator Tempo (T) foi alocado às Parcelas (P) e o fator Idade (I) às Subparcelas. Na segunda fase, Blocos (B) foram alocados à Viagem (V), Repetição (R) à Posição (P), e as unidades combinadas de Parcelas e Subparcelas (P:S) foram alocadas às Parcelas da segunda fase (Q).




Figura 2. Diagrama de alocação de fatores, cenário A.

À vista disso, o modelo de alocação inicial é obtido a partir do diagrama de alocação. Nesse modelo, os termos são formados pelas combinações entre fatores dentro de cada camada, respeitando as relações de cruzamento e aninhamento. Termos compostos apenas por fatores alocados são designados como fixos, enquanto os demais são designados como aleatórios. Assim, o modelo de alocação inicial para este cenário é:

$$\begin{aligned} Média + T * I \mid Média + B + B:R + B:R:P + B:R:P:S + B:R:P:S:U + V + Po + \\ + V:Po + \underline{V:Po:Q} + V:Po:Q:W. \end{aligned}$$

O paradigma de alocação de fatores é um processo dinâmico que reconhece a necessidade de aprimorar o modelo de alocação inicial, quando necessário. Esses ajustes ocorrem em duas etapas principais. Primeiramente, o modelo inicial é transformado no modelo de alocação homogêneo quando se há alteração na designação de algum dos termos (de fixo para aleatório, ou vice-versa) e/ou a inclusão das interações entre os fatores de diferentes camadas, como as interações bloco-tratamento. Subsequentemente, o modelo homogêneo pode ser lapidado para formar o modelo de alocação *a priori*. Esse segundo ajuste ocorre quando se prevê a necessidade de especificar estruturas de variância-covariância mais complexas para os termos aleatórios - superando a pressuposição inicial de independência e homogeneidade. Isso pode incluir, por exemplo, estruturas heterogêneas ou não-estruturadas de variância-covariância (Brien, 2022; Brien et al., 2023).

Neste estudo, o modelo de alocação homogêneo difere do modelo inicial pela incorporação dos seguintes ajustes: (i) inclusão das interações bloco-tratamento ($B:T$, $B:I$, $B:T:I$) e (ii) designação de Posição (Po) como efeito fixo. Portanto, resulta o seguinte modelo de alocação homogêneo:

$$\begin{aligned} Média + T * I + Po \mid Média + B + B:R + B:R:P + B:T + B:R:P:S + B:I + B:T:I + (1) \\ + B:R:P:S:U + V + V:Po + \underline{V:Po:Q} + V:Po:Q:W. \end{aligned}$$

Uma vez que não foram propostas modificações na estrutura de variância-covariância, devido ao estudo não ter acesso a experimentos prévios ou aos dados experimentais. O modelo de alocação *a priori* é idêntico ao modelo de alocação homogêneo (1).

A próxima e última etapa final do paradigma de alocação de fatores consiste na obtenção da tabela de anatomia, ferramenta que permite avaliar e compreender a estrutura do delineamento experimental, tornando explícitos os confundimentos intrínsecos entre as fontes de variação. Nessa abordagem, o confundimento pode ser identificado visualmente, pois as fontes de variação de diferentes camadas são dispostas em colunas distintas, e as relações de confundimento são reveladas pelo alinhamento horizontal das fontes.

Assim, o modelo de alocação homogêneo (5) serviu como base para a obtenção da tabela de anatomia. Esta tabela foi obtida por meio da função `DesignTwoPhaseAnatomies()` do pacote *dae* (Brien, 2024). Posteriormente, a tabela foi complementada com a esperança do quadrado médio (EMS), convertendo em um esqueleto da ANOVA (*skeleton-ANOVA*), que possibilita uma visualização detalhada da decomposição das fontes de variabilidade e a identificação das razões dos testes de hipótese apropriados para cada efeito de interesse. O resultado dessa etapa é apresentado na Tabela 1.

Tabela 1. Esqueleto da ANOVA para o modelo de alocação homogêneo do Cenário A.

Unidades da Segunda Fase		Unidades da Primeira Fase		Tratamentos da Primeira Fase		A-eff.	E-eff.	Ordem	Esperança do Quadrado Médio (EMS)														θ	
Fonte	GL	Fonte	GL	Fonte	GL				$\sigma_{\hat{V}PoQW}^2$	$\sigma_{\hat{V}PoQ}^2$	$\sigma_{\hat{V}Po}^2$	$\sigma_{\hat{V}}^2$	σ_{μ}^2	$\sigma_{\hat{B}RPSU}^2$	$\sigma_{\hat{B}RPS}^2$	$\sigma_{\hat{B}RP}^2$	$\sigma_{\hat{B}R}^2$	$\sigma_{\hat{B}}^2$	σ_{μ}^2	$\sigma_{\hat{B}TI}^2$	$\sigma_{\hat{B}T}^2$	$\sigma_{\hat{B}I}^2$		$\sigma_{\hat{B}}^2$
Média	1	Média	1			1.00	1.00	1	1	24	216	432	1296	1	24	72	216	432	1292	1	3	3	9	θ_{μ}
V	2	B	2	B	2	1.00	1.00	1	1	24	216	432		1	24	72	216	432		1	3	3	9	
Po	1	R [B]	1			1.00	1.00	1	1	24	216			1	24	72	216							θ_{Po}
V#Po	2	R [B]	2			1.00	1.00	1	1	24	216			1	24	72	216							
Q[V:Po]	48	P [B:R]	12	T	2	1.00	1.00	1	1	24				1	24	72			1	3				θ_T
				B#T	4	1.00	1.00	1	1	24				1	24	72			1	3				
				Residuo	6	1.00	1.00	1	1	24				1	24	72								
		S [B:R:P]	36	I	2	1.00	1.00	1	1	24				1	24				1		3			θ_I
				B#I	4	1.00	1.00	1	1	24				1	24				1		3			
				T#I	4	1.00	1.00	1	1	24				1	24				1					θ_{TI}
				B#T#I	8	1.00	1.00	1	1	24				1	24				1					
				Residuo	18	1.00	1.00	1	1	24				1	24									
W[V:Po:Q]	1242	U[B:R:P:S]	1242			1.00	1.00	1	1					1										
Total	1296																							

Nota: GL: Números de graus de liberdade. EMS: Esperança do Quadrado Médio. A-eff.: A-efficiency, a média harmônica dos fatores de eficiência canônicos para uma fonte de variação. E-eff.: E-efficiency, o menor valor entre as eficiências canônicas para uma fonte de variação. Ordem: Ordem de balanço, o número de valores únicos para as eficiências canônicas de uma fonte de variação.

A análise do esqueleto da ANOVA (Tabela 1) expõe que: (i) B está confundido com V, (ii) Po e V#Po estão confundidos com R[B], (iii) T e B#T estão confundidos com P[B:R] e (iv) I, B#I, T#I e B#T#I estão confundidos com S[B:R:P], em que P[B:R] e S[B:R:P] estão confundidos com Q[V:Po]. Foram, também, identificadas duas fontes residuais: (a) uma associada a P, representando o subespaço ortogonal aos efeitos de T e B#T, e (b) outra associada a S, ortogonal ao efeito I e suas interações.

Ademais, o valor de eficiência A igual a 1,00 para todos os termos confirma que o delineamento é ortogonal. A presença dos EMS permite identificar os denominadores apropriados, destacados em laranja na tabela, para os testes F: o quadrado médio da interação tripla (B#T#I) serve como o denominador para a estatística F associada à interação T#I, assim como o quadrado médio da interação B#I para a estatística F relacionada ao efeito de I, o quadrado médio da interação B#T para a estatística F relacionada ao efeito de T, e o quadrado médio de V#Po para a estatística F relacionada ao efeito de Po. Em suma, os testadores para os efeitos de interesse são as interações tratamento-bloco do modelo. No entanto, a tabela também revela que as fontes de unidade B e R são exaustivamente confundidas por V e pelo conjunto Po e V#Po, respectivamente, evidenciado pela ausência de uma fonte residual para elas. Esta condição caracteriza casos de pseudorrepetição.

Conforme Brien & Demétrio (2009), quando ocorre confundimento exaustivo, é possível adotar um modelo de conveniência, que inclui apenas os termos estimáveis, tornando o modelo não singular. Para isso, o fator B foi removido em favor de V, R em favor de Po e V:Po, e B:R:P:S:U em favor de V:Po:Q:W. Assim, o modelo de conveniência proposto foi:

$$\begin{aligned} Média + T * I + Po \mid Média + B:R:P + B:T + B:R:P:S + B:I + B:T:I + V + V:Po + \\ + \underline{V:Po:Q} + V:Po:Q:W. \end{aligned}$$

No entanto, é fundamental destacar que em decorrência ao uso do modelo de conveniência. Ao remover os termos exaustivamente confundidos, a variabilidade que eles representavam é integralmente absorvida pelos fatores que foram mantidos no modelo. Consequentemente, a estimativa do componente de variância para Viagem (V) não representa mais apenas σ_v^2 , mas sim a soma dos componentes confundidos: $\sigma_v^2 + \sigma_b^2$. O mesmo princípio se aplica aos demais termos, como Po e V:Po, cujas fontes de variabilidade agora incorporam a de Repetição (R). Portanto, a interpretação das estimativas de variância deste modelo deve sempre considerar essas combinações das fontes de variabilidade.

5.2 Cenário B

Neste cenário, mantiveram-se as mesmas premissas adotadas no cenário anterior quanto ao delineamento da primeira fase - um delineamento em parcelas subdivididas. No entanto, não se inclui o fator de controle Repetição na primeira fase, a fim de quantificar o impacto desta simplificação sobre as propriedades do delineamento.

Dessa maneira, a estrutura da primeira fase é simplificada. Os fatores alocados permanecem Idade das Matrizes (I) e Tempo de Estocagem (T), cruzados entre si, mas a estrutura hierárquica das unidades recipientes agora compreende Blocos (B), Parcelas (P), Subparcelas (S) e Unidades (U). Assim, o modelo antecipado para a primeira fase é representado por:

$$Média + T + I + T:I \mid Média + B + B:P + \underline{B:P:S} + B:P:S:U.$$

A segunda fase do experimento permanece inalterada em relação ao Cenário A. Os fatores alocados se mantêm Viagem (V) e Posição (Po) e os fatores recipientes continuam Parcelas (Q) e Unidades (W). Sendo assim, o modelo antecipado para esta fase é:

$$Média + V + Po + V:Po \mid Média + \underline{V:Po:Q} + V:Po:Q:W.$$

Portanto, a combinação das duas fases resulta no seguinte modelo antecipado completo:

$$Média + T * I + V * Po \mid Média + B + B:P + B:P:S + B:P:S:U + \underline{V:Po:Q} + V:Po:Q:W.$$

Seguindo para a seleção do delineamento e a construção do diagrama de alocação de fatores, observa-se que, considerando a estrutura experimental descrita, o delineamento selecionado mantém-se como um delineamento em blocos casualizados com parcelas subdivididas na primeira fase e um delineamento em blocos na segunda fase. Entretanto, devido à não inclusão do fator de repetição, obteve-se o diagrama de alocação de fatores na Figura 3.




Figura 3. Diagrama de alocação de fatores, cenário B.

O diagrama de alocação (Figura 3) mostra que na primeira fase, o fator Tempo (T) foi alocado às Parcelas (P) e o fator Idade (I) às Subparcelas. Na segunda fase, Blocos (B) foram alocados à Viagem (V), e as unidades combinadas de Parcelas e Subparcelas (P:S) foram alocadas às unidades combinadas de Posição (Po) e Parcelas (Q) na segunda fase.

Diante disso, o modelo de alocação inicial é obtido a partir do diagrama de alocação de fatores. Sendo assim representado por:

$$Média + T * I \mid Média + B + B:P + B:P:S + B:P:S:U + V + Po + V:Po + \underline{V:Po:Q} + V:Po:Q:W.$$

Seguindo com o ajuste do modelo, o modelo de alocação homogêneo se difere do modelo inicial pela incorporação dos seguintes ajustes: (i) inclusão das interações bloco-tratamento ($B:T$, $B:I$, $B:T:I$) e (ii) designação de Posição (Po) como efeito fixo. Portanto, resulta no seguinte modelo de alocação homogêneo:

$$Média + T * I + Po \mid Média + B + B:P + B:T + B:P:S + B:I + B:T:I + B:P:S:U + \quad (2) \\ + V + V:Po + \underline{V:Po:Q} + V:Po:Q:W.$$

Uma vez que não foram propostas modificações na estrutura de variância-covariância, devido ao estudo não ter acesso a experimentos prévios ou aos dados experimentais, o modelo de alocação *a priori* é idêntico ao modelo de alocação homogêneo (2).

Com a definição do modelo de alocação homogêneo (2), este serviu como base para a obtenção da tabela de anatomia. Esta tabela foi obtida por meio da função ‘DesignTwoPhaseAnatomies()’ do pacote *dae* (Brien, 2024) e, posteriormente, complementada com a esperança dos quadrados médios (EMS), resultando em um esqueleto da ANOVA. O resultado dessa etapa é apresentado na Tabela 2.

Tabela 2. Esqueleto da ANOVA para o modelo de alocação homogêneo do Cenário B.

Unidades da Segunda Fase		Unidades da Primeira Fase		Tratamentos da Primeira Fase		A-eff.	E-eff.	Ordem	Esperança do Quadrado Médio (EMS)																		θ
Fonte	GL	Fonte	GL	Fonte	GL				σ^2_{VPoQW}	σ^2_{VPoQ}	σ^2_{VPo}	σ^2_V	σ^2_μ	σ^2_{BPSU}	σ^2_{BPS}	σ^2_{BP}	σ^2_B	σ^2_μ	σ^2_{BTI}	σ^2_{BT}	σ^2_{BI}	σ^2_B					
Média	1	Média	1			1.00	1.00	1	1	24	216	432	1296	1	24	144	432	1292	1	3	3	9	θ_μ				
V	2	B	2	B	2	1.00	1.00	1	1	24	216	432		1	24	144	432		1	3	3	9					
Po	1	P [B]	1	T	1	0.74	0.74	1	1	24	216			1	24	144			1	3			$\theta_{Po \rightarrow P[B]^* \rightarrow T}$				
V#Po	2	P [B]	2	T	2	0.17	0.10	2	1	24	216			1	24	144			1	3			$\theta_{V\#Po^* \rightarrow P[B]^* \rightarrow T}$				
Q [V:Po]	48	P [B]	6	T	2	0.61	0.47	2	1	24				1	24	144			1	3			$\theta_{Q[V:Po]^* \rightarrow P[B]^* \rightarrow T}$				
				B#T	4	0.50	0.33	4	1	24				1	24	144			1	3							
		S [B:P]	42	I	2	0.96	0.93	2	1	24				1	24				1		3		$\theta_{Q[V:Po]^* \rightarrow S[B:P]^* \rightarrow I}$				
				B#I	4	0.95	0.84	2	1	24				1	24				1		3						
				T#I	4	0.94	0.81	2	1	24				1	24				1				$\theta_{Q[V:Po]^* \rightarrow S[B:P]^* \rightarrow T\#I}$				
				B#T#I	8	0.90	0.53	2	1	24				1	24				1								
				Residuo	24	1.00	1.00	1	1	24				1	24				1								
W [V:Po:Q]	1242	U [B:P:S]	1242			1.00	1.00	1	1					1													
Total	1296																										

Nota: GL: Números de graus de liberdade. EMS: esperança do quadrado médio. A-eff.: A-efficiency. E-eff.: E-efficiency. Ordem: ordem de balanço. O símbolo θ representa uma forma quadrática na esperança da resposta, onde o subscrito detalha o confundimento entre as fontes de variação. A notação subscrita, por exemplo $Po \rightarrow P[B]^* \rightarrow T$, deve ser lida da direita para a esquerda: a fonte fixa T está confundida com a fonte aleatória P[B], que, por sua vez, está confundida com a fonte fixa Po. Um asterisco (*) indica que a fonte é aleatória.

Tabela 3. Tabela de confundimento entre fatores da mesma camada, *aliasing*, para o modelo de alocação homogêneo do Cenário B.

Fonte	GL	Confundido	Estrato	A-eff.	E-eff.	Ordem
S [B:P]	3	P [B]	Q [V:Po]	1.000	1.000	1
B#T	2	T	Q [V:Po] & P [B]	0.182	0.182	1
B#I	1	I	Q [V:Po] & S [B:P]	0.014	0.014	1
T#I	1	I	Q [V:Po] & S [B:P]	0.014	0.014	1
T#I	1	B#I	Q [V:Po] & S [B:P]	0.030	0.030	1
B#T#I	1	I	Q [V:Po] & S [B:P]	0.034	0.034	1
B#T#I	1	B#I	Q [V:Po] & S [B:P]	0.073	0.073	1
B#T#I	1	T#I	Q [V:Po] & S [B:P]	0.073	0.073	1

Nota: GL: graus de liberdade. A-eff.: A-efficiency. E-eff.: E-efficiency. Ordem: ordem de balanço.

A análise da tabela de anatomia (Tabela 2) expõe que: (i) B está confundido com V; (ii) Po está confundido com P[B], que está confundido com T; (iii) V#Po está confundido com P[B], o qual também está confundido com T; (iv) T e B#T estão confundidos com P[B] e (v) I, B#I, T#I e B#T#I estão confundidos com S[B:P], em que P[B] e S[B:P] confundidos com Q[V:Po]; e (vi) W[V:Po:Q] está confundido com U[B:P:S]. Além disso, foi identificada uma única fonte residual associada a S, ortogonal aos efeitos de I e suas interações.

Nesse cenário, a Tabela 3 complementa essa análise ao detalhar os confundimentos entre fontes pertencentes à mesma camada (*aliasing*). Nessa tabela, a coluna *Fonte* indica o termo analisado, a coluna *Confundido* especifica a fonte sobreposta, e *Estrato* informa o nível em que o confundimento ocorre. As demais colunas (A-eff., E-eff. e Ordem) seguem a mesma estrutura da Tabela 2.

A interpretação da Tabela 3 pode ser exemplificada pela segunda linha: a fonte B#T apresenta dois graus de liberdade parcialmente confundidos com o fator T. Esse confundimento ocorre no estrato das unidades Q[V:Po] e P[B], e o valor de eficiência A (0,182) quantifica essa sobreposição, indicando que 18,2% da informação associada a T está confundida com B#T nesses estratos. O mesmo princípio de interpretação aplica-se às demais fontes apresentadas.

A ocorrência desses confundimentos, juntamente com os valores de A-eficiência inferiores a 1,00 observados na Tabela 2, confirmam que o delineamento é não ortogonal. Dessa forma, na decomposição das fontes de variação, os componente de variação da última camada, indicado em tracejado na Tabela 2 (σ_{BTI}^2 , σ_{BT}^2 , σ_{BI}^2 , σ_B^2), devem ser ponderados pelos respectivos valores de eficiência A de seus estratos.

A presença dos EMS permite também identificar os denominadores apropriados para os testes de hipótese, os quais permanecem os mesmos que no cenário A, ao assumir que as eficiências apresentam valores próximos, destacados em laranja na Tabela 2. Em suma, os testadores adequados para os efeitos de interesse correspondem às interações tratamento-bloco do modelo. Entretanto, é necessário analisar se os confundimentos previamente identificados impactam esses testes de hipótese.

De fato, observou-se que tanto os confundimentos entre fatores de diferentes camadas (como o de Po com T, por serem de efeitos fixos) quanto os confundimentos dentro de uma

mesma camada (Tabela 3) afetam diretamente os testes de hipótese. Para a camada de tratamentos, verificou-se que os denominadores dos testes estão quase totalmente confundidos com os numeradores de seus respectivos efeitos. Desse modo, ambos os casos introduzem erros e reduzem a confiabilidade dos resultados.

Diante desse nível de confundimento e do impacto direto nos testes dos efeitos de interesse, não foi proposto um modelo de conveniência, pois este resultaria em estimativas inválidas aos objetivos do estudo.

5.3 Cenário C

Neste cenário, considerou-se a mesma abordagem proposta por Nazareno (2012) para o delineamento da primeira fase, ou seja, um delineamento em blocos casualizados em esquema fatorial. Desconsiderou-se, portanto, a segregação temporal entre os períodos de coleta dos ovos. Ademais, neste cenário, foi incluído o fator de controle Repetição na primeira fase, o qual servirá como um fator a ser alocado à *Posição* na segunda fase.

A partir disso, os fatores alocados da primeira fase são Idade das Matrizes (I) e Tempo de Estocagem (T), enquanto os fatores recipientes são Blocos (B), Repetição (R), Parcelas (P) e Unidades (U). Nessa fase, os fatores I e T encontram-se cruzados, ao passo que os demais fatores recipientes encontram-se hierarquicamente aninhados, do primeiro ao último estrato. Assim, para a primeira fase, obteve-se o seguinte modelo antecipado:

$$Média + I + T + I:T \mid Média + B + B:R + \underline{B:R:P} + B:R:P:U.$$

A segunda fase do experimento permanece inalterada em relação aos cenários A e B. Os fatores alocados se mantêm Viagem (V) e Posição (Po) e os fatores recipientes continuam Parcelas (Q) e Unidades (W). Sendo assim, o modelo antecipado para esta fase é:

$$Média + V + Po + V:Po \mid Média + \underline{V:Po:Q} + V:Po:Q:W.$$

Dessa forma, a combinação das duas fases resulta no seguinte modelo antecipado completo:

$$Média + I * T + V * Po \mid Média + B + B:R + B:R:P + B:R:P:U + \underline{V:Po:Q} + V:Po:Q:W.$$

Seguindo para a seleção do delineamento e a construção do diagrama de alocação de fatores, observa-se que o delineamento selecionado corresponde a um delineamento em blocos casualizados em esquema fatorial na primeira fase e um delineamento em blocos casualizados na segunda fase. Dessa forma, obteve-se o diagrama de alocação de fatores apresentado na Figura 4.




Figura 4. Diagrama de alocação de fatores, cenário C.

O diagrama de alocação (Figura 4) mostra que na primeira fase, a combinação do fator Idade (I) e Tempo (T) foi alocado às Parcelas (P). Na segunda fase, Blocos (B) foram alocados à Viagem (V), Repetição (R) foi alocado à Posição (Po) e as Parcelas da primeira fase (P) foram alocadas a Parcelas da segunda fase (Q).

Diante disso, o modelo de alocação inicial foi obtido a partir do diagrama de alocação de fatores, sendo representado por:

$$Média + I * T \mid Média + B + B:R + B:R:P + B:R:P:U + V + Po + V:Po + \underline{V:Po:Q} + \\ + V:Po:Q:W.$$

Seguindo com o ajuste do modelo, o modelo de alocação homogêneo difere do modelo inicial pela designação de Posição (Po) como efeito fixo. Nesse caso, as interações bloco-tratamento não foram incluídas, uma vez que, pela abordagem adotada, assumiu-se a relação aditiva entre os fatores. Assim, o modelo homogêneo é expresso por:

$$Média + I * T + Po \mid Média + B + B:R + B:R:P + B:R:P:U + V + V:Po + \underline{V:Po:Q} + (3) \\ + V:Po:Q:W.$$

Como não foram propostas modificações na estrutura de variância-covariância, o modelo de alocação *a priori* é idêntico ao modelo de alocação homogêneo (3).

Com a definição do modelo de alocação homogêneo (3), este serviu como base para a obtenção da tabela de anatomia, a qual, posteriormente, foi complementada com a EMS, resultando em um esqueleto da ANOVA. O resultado dessa etapa é apresentado na Tabela 4.

Tabela 4. Esqueleto da ANOVA para o modelo de alocação homogêneo do Cenário C.

Unidades da Segunda Fase		Unidades da Primeira Fase		Tratamentos da Primeira Fase		A-eff.	E-eff.	Ordem	Esperança do Quadrado Médio (EMS)										
Fonte	GL	Fonte	GL	Fonte	GL				$\sigma_{V\#PoQW}^2$	$\sigma_{V\#PoQ}^2$	$\sigma_{V\#Po}^2$	σ_V^2	σ_μ^2	$\sigma_{B\#R\#P\#U}^2$	$\sigma_{B\#R\#P}^2$	$\sigma_{B\#R}^2$	σ_B^2	σ_μ^2	θ
Média	1	Média	1			1.00	1.00	1	1	24	216	432	1296	1	24	216	432	1292	θ_μ
V	2	B	2			1.00	1.00	1	1	24	216	432		1	24	216	432		
Po	1	R [B]	1			1.00	1.00	1	1	24	216			1	24	216			θ_{Po}
V#Po	2	R [B]	2			1.00	1.00	1	1	24	216			1	24	216			
Q[V:Po]	48	P [B:R]	48	I	2	1.00	1.00	1	1	24				1	24				θ_I
				T	2	1.00	1.00	1	1	24				1	24				θ_T
				I#T	4	1.00	1.00	1	1	24				1	24				θ_{IT}
				Resíduo	40	1.00	1.00	1	1	24				1	24				
W[V:Po:Q]	1242	U[B:R:P]	1242			1.00	1.00	1	1					1					
Total	1296																		

Nota: GL: Número de graus de liberdade. EMS: Esperança do Quadrado Médio. A-eff.: eficiência A. E-eff.: eficiência E. Ordem: Ordem de balanço.

A análise do esqueleto da ANOVA (Tabela 4) expõe que: (i) B está confundido com V, (ii) Po e V#Po estão confundidos com R[B], (iii) I, T e T#I estão confundidos com P[B:R], o qual está confundido com Q[V:Po] e (iv) W[V:Po:Q] está confundido com U[B:P:S]. Além disso, foi identificada uma única fonte residual associada a P, ortogonal aos efeitos de T, I e sua interação (I#T).

Ademais, o valor da eficiência A igual a 1.00 para todas as fontes confirma que o delineamento é ortogonal. A presença dos EMS permite identificar os denominadores apropriados para os testes de hipótese: o quadrado médio da interação V#Po serve como o denominador para Po e o quadrado médio do resíduo do estrato P[B:R] (e Q[V:Po]) serve como denominador para os demais efeitos de interesse, denominadores os quais estão destacados em laranja na Tabela 4. No entanto, a tabela também revela que as fontes de unidade B e R são exaustivamente confundidas com V e Po, respectivamente; enquanto W[V:Po:Q] está exaustivamente confundido com U[B:P:S], evidenciado pela ausência de uma fonte residual para elas, caracterizando casos de pseudorrepetição.

Dessa forma, ao adotar um modelo de conveniência, o fator B foi removido em favor de V, R em favor de Po, e B:R:P:S:U em favor de V:Po:Q:W. Assim, o modelo de conveniência proposto foi:

$$Média + I * T + Po \mid Média + B:R:P + V + V:Po + \underline{V:Po:Q} + V:Po:Q:W. \quad (17)$$

Em decorrência do uso do modelo de conveniência, os componentes de variância dos termos removidos são integralmente absorvidos pelos fatores que foram mantidos no modelo.

Portanto, a interpretação dos resultados deste modelo deve sempre considerar essas combinações dos componentes de variância.

5.4 Cenário D

Neste cenário, manteve-se a abordagem proposta por Nazareno (2012) para o delineamento da primeira fase. No entanto, não foi incluído o fator de controle *Repetição* na primeira fase, a fim de quantificar o impacto desta simplificação sobre as propriedades do delineamento.

A partir disso, os fatores alocados da primeira fase são Idade das Matrizes (I) e Tempo de Estocagem (T), enquanto os fatores recipientes são Blocos (B), Parcelas (P) e Unidades (U). Nessa fase, os fatores I e T encontram-se cruzados, ao passo que os demais fatores recipientes encontram-se hierarquicamente aninhados, do primeiro ao último estrato. Assim, para a primeira fase, obteve-se o seguinte modelo antecipado:

$$Média + I + T + I:T \mid Média + B + \underline{B:P} + B:P:U.$$

Para a segunda fase do experimento, o modelo antecipado mantém a mesma estrutura utilizada nos demais cenários apresentados. Assim, o modelo antecipado completo, resultante da combinação dos modelos das duas fases, é representado a seguir:

$$Média + I * T + V * Po \mid Média + B + B:P + B:P:U + \underline{V:Po:Q} + V:Po:Q:W.$$

Seguindo para a etapa de seleção do delineamento e construção do diagrama de alocação de fatores, observa-se que o delineamento escolhido permanece o mesmo adotado no Cenário C para ambas as fases. Assim, obteve-se o diagrama de alocação de fatores apresentado na Figura 5.




Figura 5. Diagrama de alocação de fatores, cenário D.

O diagrama de alocação (Figura 5) mostra que na primeira fase, a combinação do fator Idade (I) e Tempo (T) foi alocada às Parcelas (P). Enquanto que na segunda fase, Blocos (B) foram alocados à combinação de Viagem (V) com Posição (Po) e as Parcelas da primeira fase (P) foram alocadas a Parcelas da segunda fase (Q).

Diante disso, o modelo de alocação inicial foi obtido a partir do diagrama de alocação de fatores, sendo representado por:

$$Média + I * T \mid Média + B + B:P + B:P:U + V + Po + V:Po + \underline{V:Po:Q} + V:Po:Q:W.$$

Seguindo com o ajuste do modelo, o modelo de alocação homogêneo difere do modelo inicial pela designação de Posição (Po) como efeito fixo. Assim como no cenário anterior, as interações bloco-tratamento não foram incluídas, uma vez que, pela abordagem adotada, assumiu-se a relação aditiva entre tais fatores. Resultando no seguinte modelo de alocação homogêneo:

$$Média + I * T + Po \mid Média + B + B:P + B:P:U + V + V:Po + \underline{V:Po:Q} + V:Po:Q:W. \quad (4)$$

Como não foram propostas modificações na estrutura de variância-covariância, o modelo de alocação *a priori* é idêntico ao modelo de alocação homogêneo (4).

Desse modo, o modelo de alocação homogêneo (4) serviu como base para a obtenção da tabela de anatomia, que posteriormente foi complementada com as esperanças dos quadrados médios, resultando no esqueleto da ANOVA. O resultado dessa etapa é apresentado na Tabela 5.

Tabela 5. Esqueleto da ANOVA para o modelo de alocação homogêneo do Cenário D.

Unidades da Segunda Fase		Unidades da Primeira Fase		Tratamentos da Primeira Fase		A-eff.	E-eff.	Ordem	Esperança do Quadrado Médio (EMS)									
Fonte	GL	Fonte	GL	Fonte	GL				σ_{VPoQW}^2	σ_{VPoQ}^2	σ_{VPo}^2	σ_V^2	σ_μ^2	σ_{BPU}^2	σ_{BP}^2	σ_B^2	σ_μ^2	θ
Média	1	Média	1			1.00	1.00	1	1	24	216	432	1296	1	24	216	1292	θ_μ
V	2	B	2			1.00	1.00	1	1	24	216	432		1	24	216		
Po	1	B	1			1.00	1.00	1	1	24	216			1	24	216		θ_{Po}
V#Po	2	B	2			1.00	1.00	1	1	24	216			1	24	216		
Q[V:Po]	48	P [B]	48	I	2	1.00	1.00	1	1	24				1	24			θ_I
				T	2	1.00	1.00	1	1	24				1	24			θ_T
				I#T	4	1.00	1.00	1	1	24				1	24			θ_{IT}
				Resíduo	40	1.00	1.00	1	1	24				1	24			
W[V:Po:Q]	1242	U[B:P]	1242			1.00	1.00	1	1					1				
Total	1296																	

Nota: GL: Números de graus de liberdade. EMS: Esperança do Quadrado Médio. A-eff.: eficiência A. E-eff.: eficiência E. Ordem: Ordem de balanço.

A análise da tabela de anatomia (Tabela 5) expõe que: (i) V, Po e a interação V#Po estão confundido com B, (ii) I, T e T#I estão confundidos com P[B], o qual está confundido

com $Q[V:Po]$ e (iv) $W[V:Po:Q]$ está confundido com $U[B:P:S]$. Foi identificada, também, uma única fonte residual associada a P , ortogonal aos efeitos de T , I e à interação $I\#T$.

Ademais, o valor da eficiência A igual a 1.00 para todas as fontes confirma que o delineamento é ortogonal. A presença dos EMS permite identificar os denominadores apropriados para os testes de hipótese: a interação $V\#Po$ serve como o denominador para Po e o resíduo do estrato $Q[V:Po]$ e $P[B]$ serve como denominador para os demais efeitos de interesse, os quais estão destacados em laranja na Tabela 5. No entanto, a tabela também revela que a fonte de variação B está exaustivamente confundida com V e Po , assim como $W[V:Po:Q]$ está com $U[B:P:S]$.

Dessa forma, ao adotar um modelo de conveniência, o fator B foi removido em favor de V e Po , e $B:P:S:U$ em favor de $V:Po:Q:W$. Assim, o modelo de conveniência proposto foi:

$$Média + I * T + Po \mid Média + B:P + V + V:Po + \underline{V:Po:Q} + V:Po:Q:W.$$

5.5 Discussão Comparativa

A partir dos cenários apresentados, buscou-se identificar a estrutura experimental que proporcionasse o menor nível de confundimento para os fatores de interesse, associada à máxima eficiência e à menor ordem de balanço.

Nos cenários que consideraram a segregação temporal ocasionada pelo fator Idade (I) durante as coletas dos ovos e assim consideram um delineamento em parcelas subdivididas para a primeira fase e as interações bloco-tratamento, observou-se que o Cenário A, que inclui o fator de controle Repetição (R) para ser confundido com Posição (Po), apresentou-se superior ao Cenário B. Isso em função da ausência de confundimento entre fatores da mesma camada (*aliasing*) e por não ter confundimentos entre camadas (*confounding*) que comprometem os testes de hipóteses dos fatores de interesse. Ademais, o delineamento do Cenário A mostrou-se ortogonal, o que garante eficiência máxima na estimação dos contrastes e independência entre as fontes de variação.

Por outro lado, nos cenários que não consideraram a segregação temporal do fator Idade (I) e assim consideram um delineamento em esquema fatorial e não consideram as interações bloco-tratamento, tanto o Cenário C quanto o Cenário D resultaram em delineamentos ortogonais, sem confundimentos que afetassem os testes de hipóteses dos

fatores de interesse. Assim, ambos são adequados. Entretanto, com base no princípio da parcimônia, o Cenário D foi considerado o mais apropriado, por apresentar uma estrutura experimental mais simples, sem incluir o fator de controle Repetição (R) na primeira fase.

Esses resultados demonstram a aplicabilidade do paradigma de alocação de fatores como ferramenta de auxílio ao planejamento experimental. Tal abordagem permite identificar os confundimentos, quantificar a eficiência das fontes de variação e, consequentemente, subsidiar a escolha e entendimento do delineamento mais adequado aos objetivos da pesquisa. Essa clareza é essencial para a coerência científica e a confiabilidade na comunicação dos resultados obtidos.

6 CONSIDERAÇÕES FINAIS

O presente trabalho teve como objetivo demonstrar a aplicabilidade do paradigma de alocação de fatores no processo de experimentação, destacando seu potencial como ferramenta de apoio tanto ao planejamento experimental quanto à tomada de decisões. Os resultados obtidos evidenciaram sua utilidade na compreensão e na avaliação da estrutura experimental. A aplicação dessa metodologia, aliada ao uso do pacote *dae* no software *R*, especialmente por meio da função ‘`DesignTwoPhaseAnatomies()`’, possibilitou identificar de forma clara as relações de confundimento entre as fontes de variação e a eficiência na estimação dos contrastes das mesmas.

Com o estudo de caso, mostrou-se como o paradigma de alocação de fatores auxilia no planejamento experimental, permitindo identificar confundimentos, quantificar as eficiências das fontes de variação e, consequentemente, fundamentar a definição do delineamento mais adequado aos objetivos da pesquisa. Dessa forma, o estudo contribui para a área de experimentação ao ampliar o entendimento sobre a metodologia do paradigma de alocação de fatores. Destaca-se por ser o primeiro material em língua portuguesa a detalhar essa abordagem em conjunto com as funções do pacote *dae*. Tal contribuição representa um avanço no acesso e na disseminação dessa ferramenta entre estudantes, pesquisadores e profissionais, favorecendo sua incorporação na experimentação agrícola.

Contudo, ressalta-se que o estudo de caso foi desenvolvido com base na estrutura dos delineamentos e em cenários supostos, sem a utilização de valores reais das variáveis respostas. Dessa forma, o trabalho não abordou o impacto direto da aplicação do paradigma nas análises estatísticas finais e nas inferências sobre os resultados, apesar de o cálculo das eficiências apresentadas neste trabalho não dependerem da variável resposta. Portanto, recomenda-se que pesquisas futuras apliquem o paradigma de alocação de fatores em experimentos com dados disponíveis, conduzindo tanto o planejamento quanto a análise sob essa perspectiva. Essa continuidade permitirá consolidar empiricamente a aplicabilidade e os benefícios da metodologia, especialmente quando associada às ferramentas computacionais do pacote *dae*.

REFERÊNCIAS

- DE ANDRADE, Dalton Francisco; OGLIARI, Paulo José. **Estatística para as ciências agrárias e biológicas: com noções de experimentação**. Editora da UFSC, 2007.
- BOX, George; JONES, Stephen. Split-plot designs for robust product experimentation. **Journal of Applied Statistics**, v. 19, n. 1, p. 3-26, 1992.
- BOX, Fisher. R.A. Fisher and the Design of Experiments, 1922-1926. **The American Statistician**, v. 34, n. 1, p. 1-7, 1980.
- BRIEN, C. J. Analysis of variance tables based on experimental structure. **Biometrics**, p. 53-59, 1983.
- BRIEN, C. J. Multiphase experiments in practice: A look back. **Australian & New Zealand Journal of Statistics**, v. 59, n. 4, p. 327-352, 2017.
- BRIEN, C. J. Designing, understanding and modelling two-phase experiments with human subjects. **Statistical Methods in Medical Research**, v. 31, n. 4, p. 626-645, 2022.
- BRIEN, C. *dae: Functions Useful in the Design and ANOVA of Experiments*. **R package version 3.2.30**, 2024. Disponível em: <https://CRAN.R-project.org/package=dae>.
- BRIEN, C. J; BAILEY, R. A. Decomposition tables for experiments I. A chain of randomizations. **The Annals of Statistics**, p. 4184-4213, 2009.
- BRIEN, C. J.; BAILEY, R. A. Multiple randomizations (with discussion). **Journal of the Royal Statistical Society: Series B (Statistical Methodology)**, v. 68, n. 4, p. 571-609, 2006.
- BRIEN, C. J.; HARCH, B. D.; CORRELL, R. L.; BAILEY, R. A. Multiphase experiments with at least one later laboratory phase. I. Orthogonal designs. **Journal of Agricultural, Biological, and Environmental Statistics**, v. 16, n. 3, p. 422-450, 2011.
- BRIEN, C. J.; SERMARINI, R. A.; DEMÉTRIO, C. G. B. Exposing the confounding in experimental designs to understand and evaluate them, and formulating linear mixed models for analyzing the data from a designed experiment. **Biometrical Journal**, v. 65, n. 7, p. 2200284, 2023.
- BUTLER, D. G.; TAN, M. K.; CULLIS, B. R. Improving the accuracy of selection for late maturity α -amylase in wheat using multi-phase designs. **Crop and Pasture Science**, v. 60, n. 12, p. 1202-1208, 2009.
- COCHRAN, W. G.; COX, G. M. **Experimental Designs** (2nd Edit) John Wiley and Sons. **New York**, 1957.
- DEAN, Angela; VOSS, Daniel (Ed.). **Design and analysis of experiments**. New York, NY: Springer New York, 1999.
- FEDERER, W. T. **Experimental Design: Theory and Application**. New York: The Macmillan Company, 1955.

FINNEY, D. J. The fractional replication of factorial arrangements. **Annals of Eugenics**, v. 12, n. 1, p. 291-301, 1943.

FISHER, R. A. **The design of experiments**. London: Oliver and Boyd, 1937.

JANK, L.; VALLE, CB do; RESENDE, R. M. S. Breeding tropical forages. **Crop Breeding and Applied Biotechnology**, v. 11, p. 27-34, 2011.

JANK, Liana et al. Melhoramento genético de *Panicum maximum*. **Melhoramento de forrageiras tropicais**, v. 1, p. 55-87, 2008.

JARRETT, R. G.; FAREWELL, V. T.; HERZBERG, A. M. Random effects models for complex designs. **Statistical Methods in Medical Research**, v. 29, n. 12, p. 3695-3706, 2020.

JARRETT, Richard G.; RUGGIERO, Katya. Design and analysis of two-phase experiments for gene expression microarrays—Part I. **Biometrics**, v. 64, n. 1, p. 208-216, 2008.

KERR, M. K. Design considerations for efficient and effective microarray studies. **Biometrics**, v. 59, n. 4, p. 822-828, 2003.

NAZARENO, Aérica Cirqueira. Ambiência pré-porteira: avaliação das condições bioclimáticas e das operações pré-eclosão na qualidade de pintos de corte. **Piracicaba: Tese (Doutorado em ciência: Física do Ambiente Agrícola)**, 2012.

MCINTYRE, G. A. Design and analysis of two phase experiments. **Biometrics**, v. 11, n. 3, p. 324-334, 1955.

MEAD, R. The non-orthogonal design of experiments. **Journal of the Royal Statistical Society: Series A (Statistics in Society)**, v. 153, n. 2, p. 151-178, 1990.

MONTGOMERY, Douglas C. **Design and analysis of experiments**. John Wiley & sons, 2017.

R Core Team. R: A Language and Environment for Statistical Computing. Vienna: R Foundation for Statistical Computing, 2025. Disponível em: <https://www.R-project.org/>.

RENCER, Alvin C.; SCHAALJE, G. Bruce. **Linear models in statistics**. John Wiley & Sons, 2008.

SERMARINI, R. A.; BRIEN, C.; DEMÉTRIO, C. G. B.; DOS SANTOS, A. Impact on genetic gain from using misspecified statistical models in generating p-rep designs for early generation plant-breeding experiments. **Crop Science**, v. 60, n. 6, p. 3083-3095, 2020.

SMITH, A. B.; LIM, P.; CULLIS, B. R. The design and analysis of multi-phase plant breeding experiments. **The Journal of Agricultural Science**, v. 144, n. 5, p. 393-409, 2006.

WALWYN, R.; ROBERTS, C. Therapist variation within randomised trials of psychotherapy: implications for precision, internal and external validity. **Statistical Methods in Medical Research**, v. 19, n. 3, p. 291-315, 2010.

WOOD, J. T.; WILLIAMS, E. R.; SPEED, T. P. Non-orthogonal block structure in two-phase designs. **Australian Journal of Statistics**, v. 30, n. 1, p. 225-237, 1988.

APÊNDICES

→ APÊNDICE A

```
#####
# Script em R utilizado para o estudo de caso - Cenário A
#####

# --- Pacotes necessários -----
#
library(dae)      # Contém as funções de delineamento experimental
library(dplyr)    # Facilita a manipulação e organização dos dados

# --- Etapa 1: Definição da estrutura do experimento -----
#
# Define a estrutura de parcelas e subparcelas de acordo com o diagrama
# experimental.

# Fase 1: Delineamento em parcelas subdivididas (Split-Plot)
nB <- 3          # Blocos (B)
nR <- 2          # Repetições (R)
nP <- 3          # Parcelas principais (P) - fator Idade (I)
nS <- 3          # Subparcelas (S) - fator Tempo de Estocagem (T)
nU <- 24         # Unidades observacionais (U)

# Fase 2: Delineamento fatorial em blocos (estrutura semelhante a CBD)
nV <- 3          # Viagem (V)
nPo <- 2         # Posição (Po)

# Fatores de tratamento
levelsT <- c("T1", "T2", "T3")
levelsI <- c("I1", "I2", "I3")

# --- Etapa 2 e 3: Geração e randomização da Fase 1 (nível de Parcelas/P) -----#

# Geração dos fatores de unidade experimental na Fase 1
fase1.units <- fac.gen(generate = list(B = nB,
                                       R = nR,
                                       P = nP,
                                       S = nS))

# Geração dos fatores de tratamento da Fase 1
fase1.trat <- fac.gen(generate = list(T = levelsT,
                                       I = levelsI),
                    times = nB * nR)

# Randomização do delineamento em parcelas subdivididas
fase1.random <- designRandomize(
  allocated = fase1.trat,
```

```

recipient = fase1.units,
nested.recipients = list(R = "B",
                          P = c("B", "R"),
                          S = c("B", "R", "P")),
seed = 2025 # Define a semente para reprodutibilidade
)

# --- Etapa 3.5: Inclusão das Unidades observacionais (U) ----- #
# Replica o delineamento randomizado de potes para cada uma das 24 unidades (U)
# e adiciona um fator identificador de unidades.

fase1.layout <- rep.data.frame(fase1.random, each = nU)
U.factor <- fac.gen(generate = list(U = nU), times = nrow(fase1.random))
fase1.layout <- cbind(fase1.layout, U.factor)

# Reorganização das colunas para maior clareza
fase1.layout <- fase1.layout[, c("B", "R", "P", "S", "U", "T", "I")]

# --- Etapa 4: Ligação entre Fase 1 e Fase 2 ----- #
# É criado um identificador único (QID) para cada parcelas (P).

fase1.layout$PotID <- fac.combine(factors = as.list(fase1.layout[, c("B", "R",
"P", "S")]))

# --- Etapa 5: Implementação do delineamento na Fase 2 - #
# Cria a estrutura da Fase 2 com base nas unidades provenientes da Fase 1.

# Seleciona os 54 potes únicos com seus fatores da Fase 1
unique.pots <- fase1.layout[!duplicated(fase1.layout$PotID),
                             c("PotID", "B", "R", "T", "I")]

# Cria os espaços (slots) que receberão os potes na Fase 2
fase2.slots <- fac.gen(list(V = nV,
                             Po = nPo,
                             Q = 9)) # 9 parcelas por combinação Viagem x
Posição

# Inicializa o data frame para armazenar o delineamento randomizado da Fase 2
fase2.layout <- data.frame()

# Define semente para garantir reprodutibilidade da randomização
set.seed(1821)

# Loop de randomização: associa potes da Fase 1 às posições da Fase 2
for (b in 1:nB) {
  for (r in 1:nR) {
    # 1. Seleciona os 9 potes (Q) do bloco (B) e repetição (R) específicos
    pots.to.randomize <- unique.pots[unique.pots$B == b & unique.pots$R == r, ]

    # 2. Seleciona os 9 espaços correspondentes na Fase 2
    # A correspondência é: Bloco → Viagem (V), Repetição → Posição (Po)

```

```

current.slots <- fase2.slots[fase2.slots$V == b & fase2.slots$Po == r, ]

# 3. Embaralha aleatoriamente os potes
randomized.pots <- pots.to.randomize[sample(nrow(pots.to.randomize)), ]

# 4. Combina os potes randomizados com suas novas posições
temp.lay <- cbind(randomized.pots, current.slots)

# 5. Acrescenta ao delineamento final da Fase 2
fase2.layout <- rbind(fase2.layout, temp.lay)
}
}

# --- Etapa 6: Combinação das Fases 1 e 2 ----- #
# Une a estrutura completa da Fase 1 (com Unidades) ao delineamento randomizado
da Fase 2.

final.layout <- merge(fase1.layout, fase2.layout, by = "PotID", suffixes = c("",
".F2"))

# Organização final das colunas
final.layout <- final.layout %>%
  select(PotID, B, R, P, S, U, I, T, V, Po, Q)

# --- Etapa 8: Análise da estrutura do delineamento experimental ----- #
# Utiliza a função designTwophaseAnatomies() para decompor
# e avaliar a estrutura do delineamento, conforme proposto por Brien.

experiment.anatomy <- designTwophaseAnatomies(
  formulae = list(
    Phase1 = ~ ((V * Po) / Q) / U,
    Phase2 = ~ (B / R / P / S) / U,
    Treatments = ~ B * T * I
  ),
  data = final.layout,
  which.designs = "two-phase"
)

summary(experiment.anatomy$twophase)

```

```

#####
# Script em R utilizado para o estudo de caso - Cenário B
#####

# --- Pacotes necessários ----- #
library(dae)
library(dplyr)

# --- Etapa 1: Definição da estrutura experimental ----- #

```

```

# A primeira fase corresponde a um delineamento em parcelas subdivididas
(Split-Plot)
# A segunda fase segue um esquema fatorial em blocos (semelhante a um CBD).

# Primeira fase
nB <- 3      # Blocos (B)
nP <- 3      # Parcelas principais - associadas aos níveis de Idade (I)
nS <- 6      # Subparcelas - associadas aos níveis de Tempo de Estocagem (T)
nU <- 24     # Unidades observacionais (U)

# Segunda fase
nV <- 3      # Viagens (V)
nPo <- 2     # Posições (Po)

# Fatores de tratamento
levelsT <- c("T1", "T2", "T3")
levelsI <- c("I1", "I2", "I3", "I1", "I2", "I3")

# --- Etapa 2 e 3: Geração e randomização da primeira fase ----- #
# As unidades da primeira fase correspondem aos "Potes" (Subparcelas).
pote.units <- fac.gen(generate = list(
  B = nB,
  P = nP,
  S = nS
))

# Fatores de tratamento da primeira fase
pote.treats <- fac.gen(
  generate = list(T = levelsT, I = levelsI),
  times = 3 # replicação para cada bloco
)

# Randomização do delineamento em parcelas subdivididas
pote.lay <- designRandomize(
  allocated = pote.treats,
  recipient = pote.units,
  nested.recipients = list(P = c("B"), S = c("B", "P")),
  seed = 2025 # reprodutibilidade
)

# --- Etapa 3.5: Expansão para as unidades observacionais ----- #
# Cada subparcela (S) contém 24 unidades observacionais (U).
phase1.lay <- rep.data.frame(pote.lay, each = nU)
unidades.factor <- fac.gen(generate = list(U = nU), times = nrow(pote.lay))
phase1.lay <- cbind(phase1.lay, unidades.factor)

# Reorganiza colunas para clareza
phase1.lay <- phase1.lay[, c("B", "P", "S", "U", "T", "I")]

```

```

# --- Etapa 4: Identificação única das unidades da primeira fase ----- #
# Cria um identificador (PotID) que representa cada combinação de B, P e S.
phase1.lay$PotID <- fac.combine(factors = as.list(phase1.lay[, c("B", "P",
"S"))]))

# --- Etapa 5: Estrutura e randomização da segunda fase ----- #
# A segunda fase utiliza os Potes da primeira fase como material experimental.

# Seleciona os 54 potes únicos com seus fatores da primeira fase
unique.pots <- phase1.lay[!duplicated(phase1.lay$PotID),
                           c("PotID", "B", "T", "I")]

# Cria os recipientes da segunda fase
phase2.slots <- fac.gen(list(
  V = nV,
  Po = nPo,
  Q = 9 # Parcelas da segunda fase
))

# Randomização da segunda fase
phase2.lay <- designRandomize(
  allocated = unique.pots,
  recipient = phase2.slots,
  nested.recipients = list(Po = c("V"), Q = c("V")),
  seed = 1821 # reprodutibilidade
)
summary(phase2.lay)

# --- Etapa 6: Integração das fases ----- #
# Junta as informações da Fase 1 e Fase 2 em um único layout final.
final.layout <- merge(phase1.lay, phase2.lay, by = "PotID", suffixes = c("",
".F2"))
summary(final.layout)

# Análise da estrutura experimental segundo Brien
experimento.anatomy <- designTwophaseAnatomies(
  formulae = list(
    Fase2 = ~ ((V * Po) / Q) / U, # Estrutura da segunda fase
    Fase1 = ~ (B / P / S) / U,    # Estrutura da primeira fase
    Tratamentos = ~ B * T * I    # Estrutura dos tratamentos
  ),
  data = final.layout,
  which.designs = "two-phase"
)

# Exibe o sumário da decomposição estrutural
summary(experimento.anatomy$twophase)

```

```
#####
# Script em R utilizado para o estudo de caso - Cenário C
#####

# --- Pacotes necessários ----- #
library(dae)
library(dplyr)

# --- Etapa 1: Definição da estrutura experimental ----- #
# A primeira fase segue um esquema fatorial (3x3) com Blocos (B) e Repetições
# (R)
# como fatores de bloqueio cruzados.
# A segunda fase possui Viagem (V) e Posição (Po), confusas com Blocos e
# Repetições.

# Primeira fase
nB <- 3      # Blocos (B)
nR <- 2      # Repetições (R)
nP <- 9      # Parcelas (P) = 3 níveis de Idade (I) × 3 níveis de Tempo de
# Estocagem (T)
nU <- 24     # Unidades observacionais (U)

# Segunda fase
nV <- 3      # Viagens (V)
nPo <- 2     # Posições (Po)
nQ <- 9      # Parcelas da segunda fase (Q)

# Fatores de tratamento
levelsI <- c("I1", "I2", "I3")
levelsT <- c("T1", "T2", "T3")

# --- Etapa 2 e 3: Geração e randomização da primeira fase ----- #
# Fatores de unidades da Fase 1 (com B e R cruzados)
pote.units <- fac.gen(generate = list(
  B = nB,
  R = nR,
  P = nP
))
summary(pote.units)

# Fatores de tratamento da Fase 1 (3x3 fatorial)
pote.treats <- fac.gen(
  generate = list(I = levelsI, T = levelsT),
  times = nB * nR
)
summary(pote.treats)

# Randomização dos tratamentos para as parcelas (P)
pote.lay <- designRandomize(
  allocated = pote.treats,
```

```

    recipient = pote.units,
    nested.recipients = list(P = c("B", "R")),
    seed = 2025 # reprodutibilidade
  )
summary(pote.lay)

# --- Etapa 3.5: Expansão para as unidades observacionais ----- #
# Cada parcela (P) contém 24 unidades observacionais (U).
phase1.lay <- rep.data.frame(pote.lay, each = nU)
unidades.factor <- fac.gen(generate = list(U = nU), times = nrow(pote.lay))
phase1.lay <- cbind(phase1.lay, unidades.factor)

# Reorganiza as colunas
phase1.lay <- phase1.lay[, c("B", "R", "P", "U", "I", "T")]
summary(phase1.lay)

# --- Etapa 4: Identificação das unidades da primeira fase ----- #
# Cria identificador único (PotID) para cada combinação de B, R e P.
phase1.lay$PotID <- fac.combine(factors = as.list(phase1.lay[, c("B", "R",
"P")]))

# --- Etapa 5: Estrutura e randomização da segunda fase ----- #
# A segunda fase mapeia B → V (Viagem) e R → Po (Posição).

# Seleciona os 54 potes únicos com seus fatores da primeira fase
unique.pots <- phase1.lay[!duplicated(phase1.lay$PotID),
                           c("PotID", "B", "R", "I", "T")]

# Gera os recipientes da segunda fase
phase2.slots <- fac.gen(list(
  V = nV,
  Po = nPo,
  Q = nQ
))
summary(phase2.slots)

# Inicializa o layout da segunda fase
phase2.lay <- data.frame()

# Randomização estruturada e reprodutível
set.seed(1821)

# Loop: mapeia blocos e repetições para viagens e posições
for (b in 1:nB) {
  for (r in 1:nR) {
    # Identifica os 9 potes do Bloco e Repetição
    pots.to.randomize <- unique.pots[unique.pots$B == b & unique.pots$R == r, ]

    # Mapeia Bloco → Viagem e Repetição → Posição

```

```

viagem_val <- b
posicao_val <- r

# Seleciona os slots correspondentes
current.slots <- phase2.slots[phase2.slots$V == viagem_val & phase2.slots$Po
== posicao_val, ]

# Randomiza os pots
randomized.pots <- pots.to.randomize[sample(nrow(pots.to.randomize)), ]

# Combina a randomização atual
temp.lay <- cbind(randomized.pots, current.slots)

# Adiciona ao layout final da Fase 2
phase2.lay <- rbind(phase2.lay, temp.lay)
}
}
summary(phase2.lay)

# --- Etapa 6: Integração das duas fases ----- #
# Combina as informações da Fase 1 e Fase 2.
final.layout <- merge(phase1.lay, phase2.lay, by = "PotID", suffixes = c("",
".F2"))

# Organização final das colunas
final.layout <- final.layout %>%
  select(PotID,
         B, R, P, U, # Unidades da Fase 1
         I, T,       # Tratamentos
         V, Po, Q)   # Unidades da Fase 2
summary(final.layout)

# --- Etapa 7: Análise da anatomia do delineamento ----- #
# Decomposição da estrutura experimental conforme Brien.

# Análise da anatomia do delineamento experimental
experimento.anatomy <- designTwophaseAnatomies(
  formulae = list(
    Fase2 = ~ ((V * Po) / Q) / U, # Estrutura da segunda fase
    Fase1 = ~ (B / R / P) / U,    # Estrutura da primeira fase
    Tratamentos = ~ I * T        # Estrutura dos tratamentos
  ),
  data = final.layout,
  which.designs = "two-phase"
)

# Exibe o sumário da decomposição estrutural
summary(experimento.anatomy$twophase)

```

```
#####
# Script em R utilizado para o estudo de caso - Cenário D
#####

# Pacotes necessários
library(dae)
library(dplyr)

# --- Etapa 1: Definição da estrutura do experimento ----- #
# A Primeira Fase (Fase 1) é um delineamento fatorial em blocos completos
# (RCBD).
# A Segunda Fase (Fase 2) mantém estrutura fatorial, cruzando Viagem e Posição.

# --- Parâmetros da Primeira Fase (Fatorial 3x3 em Blocos) ---
nB <- 6      # Número de Blocos (B)
nComb <- 9   # Combinações fatoriais de Idade (3) x Tempo de Estocagem (3)
nU <- 24     # Número de Unidades (U) dentro de cada Parcela (P)

# --- Parâmetros da Segunda Fase ---
nV <- 3      # Níveis de Viagem (V)
nPo <- 2     # Níveis de Posição (Po)

# --- Fatores de tratamento ---
levelsI <- c("I1", "I2", "I3")
levelsT <- c("T1", "T2", "T3")

# --- Etapa 2 e 3: Geração e randomização da Primeira Fase ----- #
# Gerar unidades da Fase 1: Parcelas (P) aninhadas em Blocos (B)
fase1.units <- fac.gen(generate = list(B = nB, P = nComb))

# Gerar tratamentos fatoriais (Idade x Tempo de Estocagem)
fase1.trat <- fac.gen(generate = list(I = levelsI, T = levelsT), times = nB)

# Randomizar tratamentos às Parcelas dentro de cada Bloco
fase1.lay <- designRandomize(
  allocated = fase1.trat,
  recipient = fase1.units,
  nested.recipients = list(P = "B"),
  seed = 2025 # semente para reprodutibilidade
)

# --- Etapa 3.5: Expansão para Unidades (Ovos) ----- #
# Cada Parcela (P) contém 24 Unidades (U)
fase1.expand <- rep.data.frame(fase1.lay, each = nU)
unidades <- fac.gen(generate = list(U = nU), times = nrow(fase1.lay))
fase1.expand <- cbind(fase1.expand, unidades)

# Reorganizar colunas
fase1.expand <- fase1.expand[, c("B", "P", "U", "I", "T")]

# Criar identificador único de cada Parcela (P)
```

```
fase1.expand$PID <- fac.combine(factors = as.list(fase1.expand[, c("B", "P"))))

# --- Etapa 4: Ligação entre Fase 1 e Fase 2 ----- #
# As Parcelas da Fase 1 (P) tornam-se o material de partida da Fase 2.
# Assim, cada P é alocada em uma combinação de Viagem (V) e Posição (Po).

# Obter 54 parcelas únicas (6 Blocos x 9 Parcelas)
potes.unicos <- fase1.expand[!duplicated(fase1.expand$PID),
                                c("PID", "B", "I", "T")]

# Criar estrutura da Fase 2 (3 Viagens x 2 Posições x 9 Parcelas)
fase2.slots <- fac.gen(list(V = nV, Po = nPo, Q = nComb))

# Inicializar layout da Fase 2
fase2.lay <- data.frame()

# Semente para reprodutibilidade da randomização
set.seed(1821)

# Loop para randomizar e combinar Blocos (B) com Viagens (V) e Posições (Po)
for (b in 1:nB) {
  # 1. Selecionar as 9 Parcelas (P) do Bloco atual
  potes.atual <- potes.unicos[potes.unicos$B == b, ]

  # 2. Definir o mapeamento entre Bloco (B) e Viagem (V)/Posição (Po)
  v_val <- ceiling(b / nPo)
  po_val <- (b - 1) %% nPo + 1

  # 3. Selecionar os 9 Slots correspondentes da Fase 2
  slots.atuais <- fase2.slots[fase2.slots$V == v_val & fase2.slots$Po == po_val,
]

  # 4. Randomizar a ordem das Parcelas e associar aos Slots
  potes.rand <- potes.atual[sample(nrow(potes.atual)), ]
  temp <- cbind(potes.rand, slots.atuais)

  # 5. Adicionar ao layout final da Fase 2
  fase2.lay <- rbind(fase2.lay, temp)
}

# --- Etapa 5: Combinação das duas fases ----- #
# Unir as Unidades (U) da Fase 1 com os fatores da Fase 2
layout.final <- merge(fase1.expand, fase2.lay, by = "PID", suffixes = c("",
".F2"))

# Reorganizar colunas para clareza
layout.final <- layout.final %>%
  select(PID, B, P, U, I, T, V, Po, Q)
```

```

head(layout.final)

# --- Etapa 6: Análise da estrutura do delineamento experimental ----- #
# Utiliza-se a função designTwophaseAnatomies() do pacote 'dae' para decompor
# a estrutura do delineamento em suas fontes de variação.

experimento.anatomy <- designTwophaseAnatomies(
  formulae = list(
    Fase2 = ~ ((V * Po) / Q) / U,
    Fase1 = ~ (B / P) / U,
    Tratamentos = ~ I * T
  ),
  data = layout.final,
  which.designs = "two-phase"
)

# Resumo da estrutura hierárquica e eficiência do delineamento
summary(experimento.anatomy$twophase)

```

→ APÊNDICE B




Figura B.1: Diagrama de Hasse da camada de unidades da primeira fase para os cenários A, referente ao estudo de caso 1.




Figura B.2: Diagrama de Hasse da camada de unidades da primeira fase para os cenários B, referente ao estudo de caso 1.




Figura B.3: Diagrama de Hasse da camada de unidades da primeira fase para os cenários C, referente ao estudo de caso 1.




Figura B.4: Diagrama de Hasse da camada de unidades da primeira fase para os cenários D, referente ao estudo de caso 1.




Figura B.5: Diagrama de Hasse da camada de unidades da segunda fase para os cenários A, B, C e D, referente ao estudo de caso 1.




Figura B.6: Diagrama de Hasse da camada de tratamentos para os cenários A e B, referente ao estudo de caso 1.




Figura B.7: Diagrama de Hasse da camada de tratamentos para os cenários C e D, referente ao estudo de caso 1.