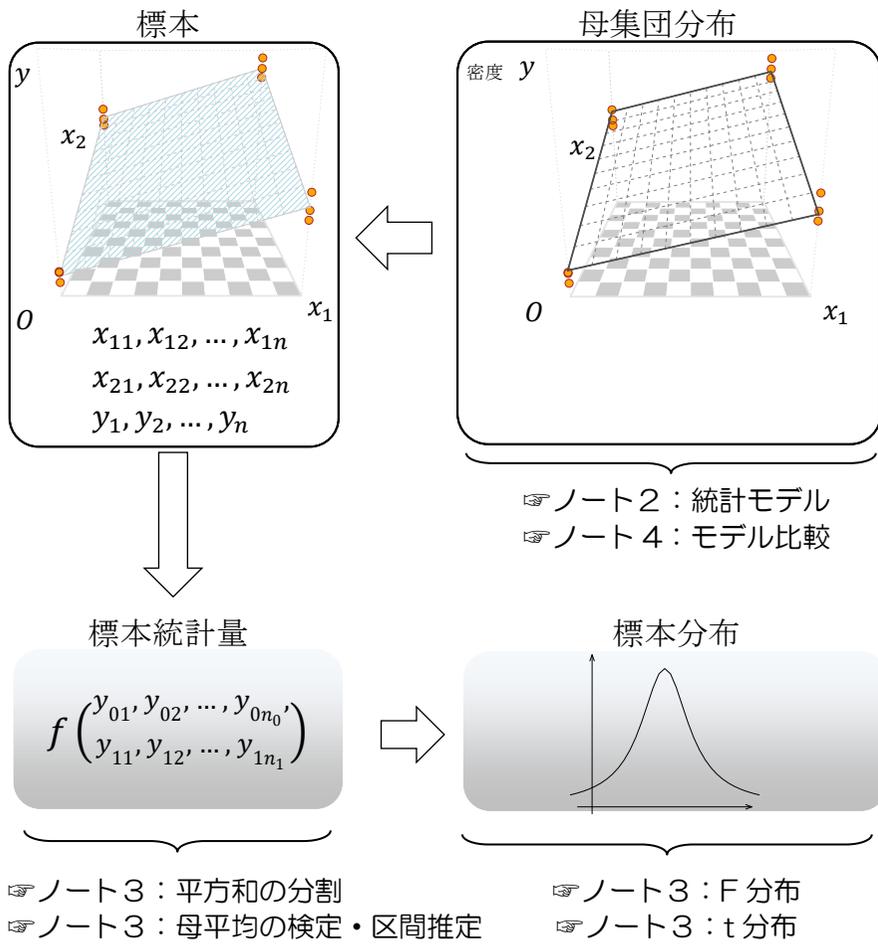


見取り図



データの形式

ID	独立変数 1	独立変数 2	...	予測変数 p	応答変数
1	1	0	...	2	2.1
2	0	1	...	1	3.2
⋮	⋮	⋮	⋮	⋮	⋮
n	1	0	...	0	1.5

(1) 目的 (リサーチクエスション)

三つ以上の群に差があるのかを見出したいとき、つまり複数の名義尺度からなる独立変数から従属変数を値を予測するモデルを作りたい際に実施する手法。

(2) 考え方

前項で扱った重回帰分析は、複数の独立変数で従属変数の値を予測するモデルを作成する方法だったが、これらの独立変数が全て名義尺度だった際に、行う統計分析を分散分析と呼ぶ。

このため、分散分析は重回帰分析の特殊な場合としてみなすことができる。ただし、この分散分析は「実験 experiment」という研究手法と密接に結びついて発展してきたため、実験デザインを反映した特殊な情報を活用する。より正確に言えば、研究者は、理想的な分散分析が行えるよう効率的な実験デザインを組み立てて研究を行う。

例えば、分散分析は、独立変数の数で一元配置分散分析 (独立変数が 1 個)、二元配置分散分析 (独立変数が二個) などに分類される。一元配置とは異なり、二元配置では各独立変数の組み合わせ (独立変数 1 が 0、独立変数が 1、など) が同じサンプルサイズとなっているかどうかが大になる。実験の組み立てにより、分散分析の調整がどのように必要となるかを中心に学びを進めてほしい。

(3) 具体的なデータの例

ID	Item	R1	R2	R3	R4	独立変数 1	独立変数 2	実験協力者	従属変数
1	1	Since yesterday	I have been walking	with	my friends.	0	0	山田	
2	1	Yesterday	I have been walking	with	my friends.	1	0	山田	
3	1	Since yesterday	I walked	with	my friends.	0	1	山田	
4	1	Yesterday	I walked	with	my friends.	1	1	山田	
5	2	Since yesterday	I have been cooking	with	my friends.	0	0	山田	
6	2	Yesterday	I have been cooking	with	my friends.	1	0	山田	
7	2	Since yesterday	I cooked	with	my friends.	0	1	山田	
8	2	Yesterday	I cooked	with	my friends.	1	1	山田	
:									
93	24	Since yesterday	I have been swimming	with	my friends.	0	0	山田	
94	24	Yesterday	I have been swimming	with	my friends.	1	0	山田	
95	24	Since yesterday	I swam	with	my friends.	0	1	山田	
96	24	Yesterday	I swam	with	my friends.	1	1	山田	
97	Filler 1		I am excited.					山田	
98	Filler 2		I am surprised.					山田	
:									
288	Filler 196		I am satisfied.					山田	

📖 ノート0 あらすじ：研究の流れ

○ 基礎：実験の流れ

(1) 実験の実施

フェーズ1：実験の計画・実施

- 手順1：先行研究を踏まえ、問うべきリサーチクエスチョンを立てる。
- 手順2：リサーチクエスチョンに答えを出すのに必要な証拠(データ)がどのようなものかを考える。
- 手順3：独立変数と従属変数を決め、それらを測定する実験を作り上げる。

フェーズ2：実験を実施する

- 手順1：大学における研究倫理委員会の承認を得る。
- 手順2：実験協力者(被験者)を集め、データを集める。

(2) 予備解析

フェーズ3：予備解析

基本的な統計量の算出やグラフ化を行い、標本データへの予備的考察・分散分析の仮定等をチェック。

(3) 推測統計学の枠組みに基づく分析

フェーズ4：モデル選択

- 手順1：母集団の構造を表したモデルを複数作る
- 手順2：モデル比較を行い、ベストなモデルを選択

フェーズ5：分散分析

- 手順1：平方和を分解する
- (例1) $SS_y = SS_A + SS_e$ 一元配置
- (例2) $SS_y = SS_A + SS_B + SS_{A \times B} + SS_e$ 二元配置
- 手順2：残差平方和 SS_e に比して独立変数の平方和($SS_A, SS_B, SS_{A \times B}$)が大きいと言えるかF検定する

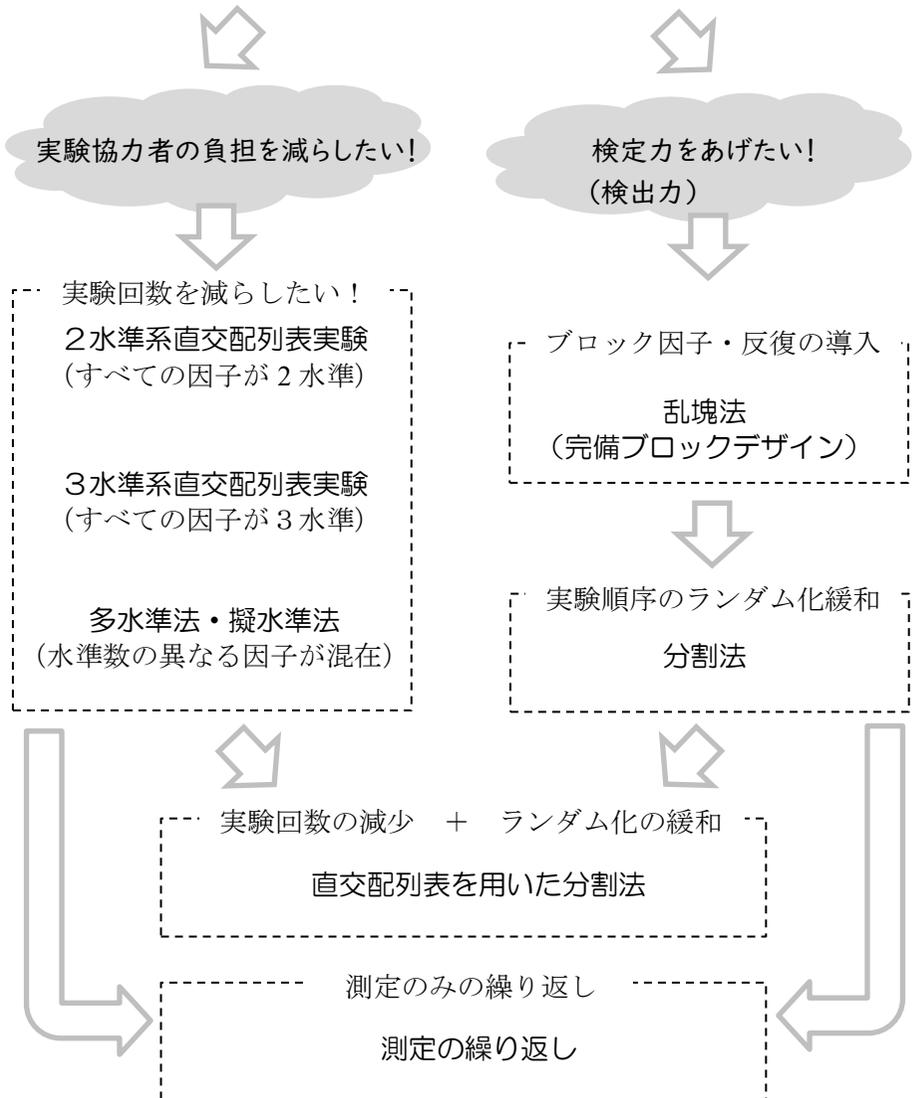
フェーズ6：パラメータへの統計的推測・評価

- 手順1：検討対象の要因における各水準の母平均を推測
- 手順2：検討対象の要因における水準間の差を推測

※点推定・信頼区間・予測区間などの検討

○ 発展：実験の改良

完全無作為化法実験
completely randomized design
各水準に対して完全にランダムに実験を実施



☞ 参考：永田靖 (2000) 『入門実験計画法』東京：日科技連
長畑秀和 (2016) 『R で学ぶ実験計画法』東京：朝倉書店
三輪哲久 (2015) 『実験計画法と分散分析』東京：朝倉書店

① 実験研究

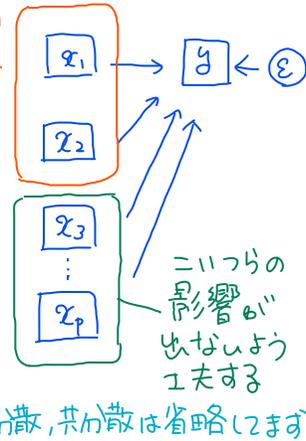


質問

そもそも、実験って何ですか？
なんで必要なんですか？

実験とは、研究者が独立変数を**統制**して従属変数の挙動を調べる研究です。多くの場合、従属変数に影響を与える可能性のある要因（独立変数の候補）は無数に考えられます。しかし実際に研究で扱うのはそのごく一部です。注目している要因以外の変数が従属変数に予期せぬ影響を与えてはいないことを保証するために、独立変数を統制しておくのです。

興味ある変数
興味のない変数



(1) 要因 Factor

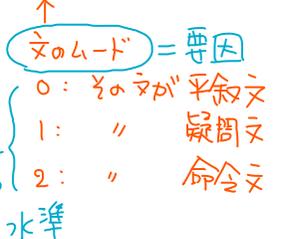
これは、質的な (=離散値を取る) 独立変数のこと。t検定や分散分析では、従属変数に対する要因の効果を検定する。

② 要因と水準

※ 水準 Level

これは、要因のとる値のこと

例：実験協力者の性（要因）⇒男（水準1）女（水準2）



(2) 交絡 Confounding

ある独立変数の効果を見たいのに他の要因が連動して絡んできてどの要因に効果があるかわからない状況。

③ ミニマルペア

例1 ミニマルペア

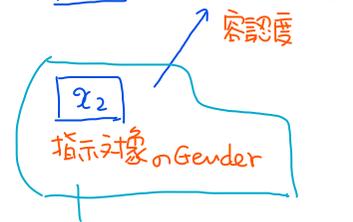
- [1] a. He is a good boy. 5
- b. He am a good girl. 1
- [2] a. He is a good boy. 5
- b. He am a good boy. 1

容認度



例2 被験者の特徴

- [1] a. He is a good boy. 英語母語話者 5
- b. He a good boy. 英語母語話者 3
- [2] a. He is a good boy. DC 育ちの英語母語話者 5
- b. He a good boy. DC 育ちの英語母語話者 1



これを統制して、確実にYに影響を与えるのか
X1だと感じる状況をつくる!

(3) 統制

① 操作可能性

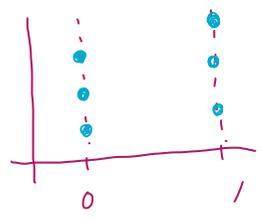
研究者が独立変数の値を変化させられるかということ。

例1：性別 研究する側が変更することはできない。

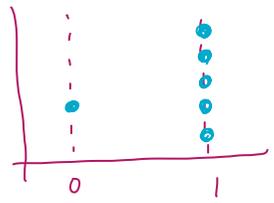
例2：刺激文 研究する側が変更することができる。

① バランス / アンバランス

(1) バランスのとれたデータ



(2) アンバランスなデータ



② 統制 Control

交絡を避けるためターゲットの要因以外の要因が従属変数に影響を持たないように偏りを調整すること。

(統制1) **一定化**: 変数値を固定し偏りを調整。
例: 実験協力者を東京方言話者に限る

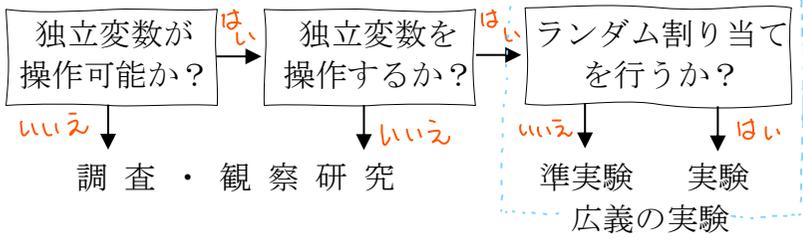
(統制2) **バランス化**: 変数値を同数にし偏りを調整。
例: 実験協力者を男女同数にする

(統制3) **ランダム化**: 変数値を無作為にし偏りを調整。
例: 無作為に発生させた番号にかける

③ 研究デザインの強弱

独立変数の操作を組み込んだ研究デザインを強いデザイン、そうでない研究デザインを弱いデザインと呼ぶ。

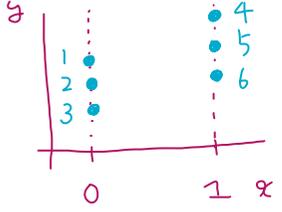
※ 観察研究と実験研究



① 対応のあり/なし

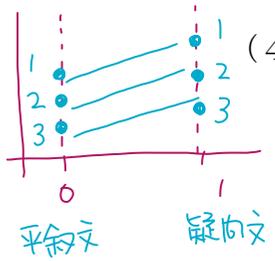
7検定を事例に考えると、

(1) 対応なし



ア×以外 日本人
1~3を答えた人は、
4~6を2いません。

(2) 対応あり



(3) 対応のない要因 vs. 対応のある要因

① 対応のない要因: 異なる水準に含まれる従属変数の値が互いに独立となるような要因のこと。

② 対応のある要因: 異なる水準に含まれる従属変数の値に相関がある要因のこと。

(4) バランスデザイン vs. アンバランスデザイン

① バランスデザイン: 各水準のサンプル数が等しい実験デザイン (理想的なデザイン)。

② アンバランスデザイン: 各水準のサンプル数が異なる実験デザイン。



質問

私の実験、参加者一人一人に288個の文を読んでもらうことになるんだけど…

「でも、そんなに読ませたら。かなり負担だろうし、何より実験の狙いに勘付かれてしまうかもしれない！」と不安になりますよね。このような不都合な状況を改善させるために、実験のサイズを小さくするような実験デザインが考案されています。

(1) 直交配列表実験

少ない実験回数で重要な主効果と交互作用が推定できるように、直交表に因子水準を割り当ててデザインする実験。

- ① 動機：実験回数を少なく抑えたい。
- ② 欠点：交互作用の制限
すべての交互作用は検討できない。
⇒あらかじめ「考慮しない交互作用」を決めておく。

(2) ラテン方格とグレコ・ラテン方格

- ① ラテン方格 Latin square ← 数独のこと!
 n 個のラテン文字を n 行 \times n 列に並べ、どの文字も各行・各列に一度ずつ現れるようにしたもの。
- ② グレコ・ラテン方格 Graeco-Latin square
ギリシャ文字とラテン文字が、単体でも、組み合わせでも、一度ずつ現れるようにしたもの。

(例) ラテン方格

	1	2	3	4
1	A	B	C	D
2	B	A	D	C
3	C	D	A	B
4	D	C	B	A

(例) グレコ・ラテン方格

	1	2	3	4
1	A α	B β	C γ	D δ
2	B γ	A δ	D α	C β
3	C δ	D γ	A β	B α
4	D β	C α	B δ	A γ

④ 数独

1	3	4	2
2	4	1	3
4	2	3	1
3	1	2	4

④ 直交表実験の発想

- 従属変数： Y
- 独立変数₁： X_1
(要因) A_1, A_2, A_3, A_4
- 独立変数₂： X_2
(要因) B_1, B_2, B_3, B_4
- 独立変数₃： X_3
(要因) R_1, R_2, R_3, R_4
- 独立変数₄： X_4
(要因) C_1, C_2, C_3, C_4

要因を割りあてろ!

- X_1 → ラテン文字
- X_2 → ギリシャ文字
- X_3 → 行 (Row)
- X_4 → 列 (Column)

		C_1	C_2	C_3	C_4
		1	2	3	4
R_1	1	A ₁	A ₂	A ₃	A ₄
	2	B ₁	B ₂	B ₃	B ₄
R_2	2	A ₂	A ₁	A ₄	A ₃
	3	B ₃	B ₄	B ₁	B ₂
R_3	3	A ₃	A ₄	A ₁	A ₂
	4	B ₄	B ₃	B ₂	B ₁
R_4	4	A ₄	A ₃	A ₂	A ₁
		B ₂	B ₁	B ₄	B ₃

A_1, B_1, C_1, R_1
 A_3, B_4, C_1, R_3

R_i : A, B, C という水準の
 $A_1 \sim A_4$ } 全ての全2の
 $B_1 \sim B_4$ } 組み合わせ
 $C_1 \sim C_4$ } 総羅!

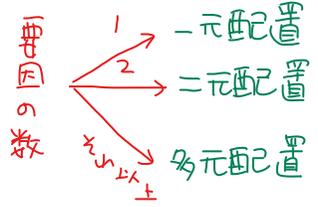
本来なら、 $4^4 = 256$ 調べるけど
 (6通り) 調べるだけで済む!

④ 分散分析の分類

📖 ノート2 母集団：統計モデル

(1) 一元配置分散分析 one-way layout ANOVA model

分散分析の構造を表すモデルには複数の書き表し方がある。ここでは、よく使われる三つのモデルを紹介する。



👉 アドバイス

モデル式の表していることが分からなくなったら、

- ①各記法が図中のどこを指しているか、考えよう！
- ②添え字が観測値の何を指しているか、考えよう！

④ 記法: i, j

通し番号 i 番目のデータ、グループの j 番に属している。

ID	要因	y_{ij}	α_j
1	1	y_{11}	1
2	1	y_{21}	1
3	3	y_{33}	0
...
n	2	y_{n2}	0

① モデル1：グループの平均に注目したモデル

$$y_{ij} = \mu_j + \varepsilon_{ij}$$

↓
ダミー変数
で表現

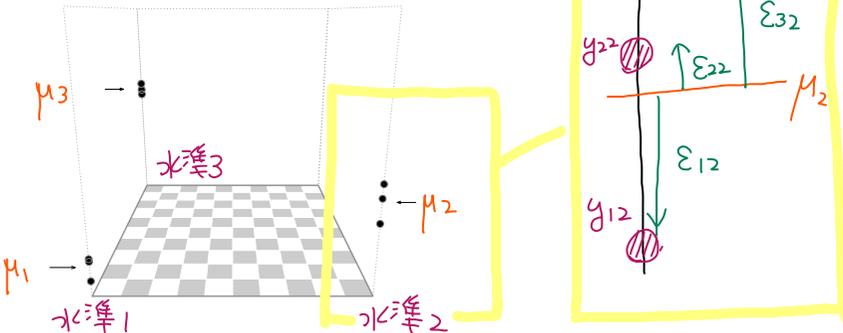
$$y_{ij} = \mu_1 x_{i1} + \mu_2 x_{i2} + \dots + \mu_j x_{ij} + \varepsilon_{ij}$$

$$= \mu_1 \times 1 + \mu_2 \times 0 + \dots + \mu_j \times 0 + \varepsilon_{ij}$$

$$= \mu_1 + \varepsilon_{ij}$$

(例) $j=1$ に属するとき

ε_{ij} は全20



④ ダミー変数

条件に依り、0, 1, 2... のような離散値を与える変数

(α_j は、0/1を返す指示変数を想定)

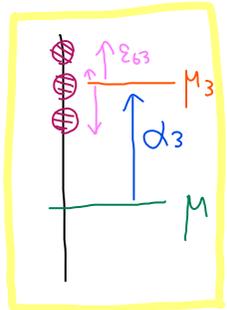
$$\alpha_{ij} = \begin{cases} 1 & \text{1番目のデータが水準 } j \text{ に属するとき} \\ 0 & \text{otherwise} \end{cases}$$

※記法

- y_{ij} IDが i 番目、水準 j に属するデータ
- ε_{ij} IDが i 番目、水準 j に属するデータの独自の効果
- μ 全体平均
- μ_j j 番目の水準の平均
- α_j j 番目の水準の処置効果

- ① 全体平均からの差 ⇒ モデル2
- ② 基準となる水準からの差 ⇒ モデル3

① (*) の位置の拡大図



α_j : j 番目の水準が
 全体の中心 μ から
 どのくらい離れたところ
 表わしたもの
 (=水準 j の効果)

「足(た)りゼロ」っていう

② モデル 2 : 零和制約を持つモデル

$$y_{ij} = \mu + \alpha_j + \varepsilon_{ij}$$

全体平均 α_j = からの差

$$\sum_{j=1}^J \alpha_j = 0$$

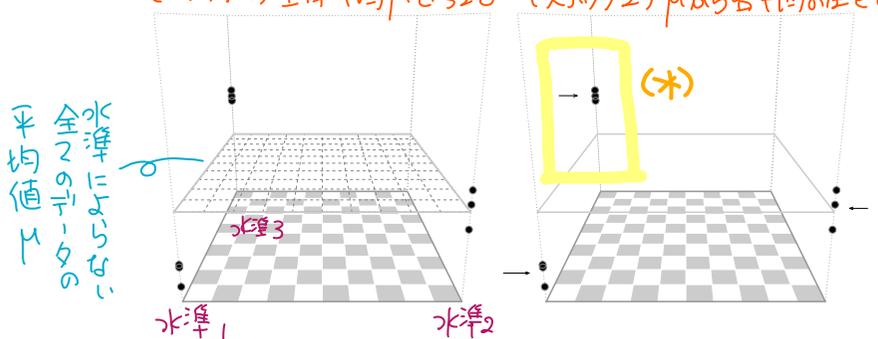
$\varepsilon_{ij} \sim N(0, \sigma^2)$

ダミー変数で表現

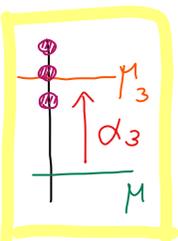
$$y_{ij} = \mu + \alpha_1 x_{1i} + \alpha_2 x_{2i} + \dots + \alpha_j x_{ji} + \varepsilon_{ij}$$

$\varepsilon_{ij} \sim N(0, \sigma^2)$

(ステップ1) 全体平均 μ を表さる (ステップ2) μ から各平均の差を出す。



① (☆) の位置の拡大図



α_j : j 番目の水準が
 基準とした水準の
 中心 μ から
 どのくらい離れたところ
 表わしたもの。

$$y_{ij} = \mu + \alpha_j + \varepsilon_{ij}$$

基準となる水準の平均 α_j = からの差

$$\alpha_1 = 0$$

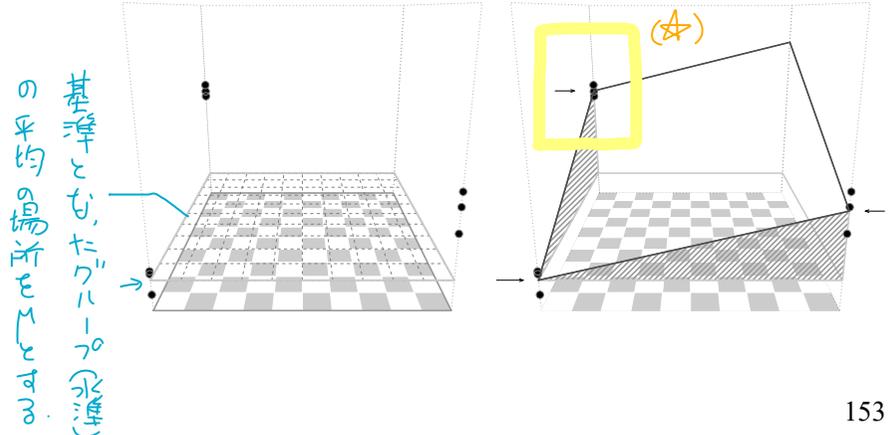
$\varepsilon_{ij} \sim N(0, \sigma^2)$

ダミー変数で表現

$$y_{ij} = \mu + \alpha_2 x_{2i} + \dots + \alpha_j x_{ji} + \varepsilon_{ij}$$

$\varepsilon_{ij} \sim N(0, \sigma^2)$

J-1 個のダミー変数!



(2) 二元配置分散分析 two-way layout ANOVA model

① モデル1 : グループの平均に注目したモデル

$$y_{ijk} = \mu_{jk} + \varepsilon_{ijk}$$

$\varepsilon_{ijk} \sim N(0, \sigma^2)$

↓
ダミー変数
で表現

$$y_{ijk} = \mu_{11}x_{1i} + \mu_{12}x_{2i} + \cdots + \mu_{1K}x_{Ki} \\ + \mu_{21}x_{K+1i} + \mu_{22}x_{K+2i} + \cdots + \mu_{2K}x_{K+Ki} \\ \vdots \\ + \mu_{J1}x_{(J-1)K+1i} + \mu_{J2}x_{(J-1)K+2i} + \cdots + \mu_{JK}x_{(J-1)K+Ki} \\ + \varepsilon_{ijk}$$

$\varepsilon_{ijk} \sim N(0, \sigma^2)$

② モデル2 : 零和制約を持つモデル

$$y_{ijk} = \mu + \alpha_j + \beta_k + (\alpha\beta)_{jk} + \varepsilon_{ijk}$$

$\varepsilon_{ijk} \sim N(0, \sigma^2)$

$$\sum_{j=1}^J \alpha_j = 0 \quad \sum_{k=1}^K \beta_k = 0$$

$$\sum_{j=1}^J (\alpha\beta)_{j1} = 0 \\ \sum_{j=1}^J (\alpha\beta)_{j2} = 0 \\ \vdots \\ \sum_{j=1}^J (\alpha\beta)_{jK} = 0$$

$$\sum_{k=1}^K (\alpha\beta)_{1k} = 0 \\ \sum_{k=1}^K (\alpha\beta)_{2k} = 0 \\ \vdots \\ \sum_{k=1}^K (\alpha\beta)_{Jk} = 0$$

↓
ダミー変数
で表現

$$y_{ijk} = \mu + \alpha_1x_{1i} + \alpha_2x_{2i} + \cdots + \alpha_jx_{ji} \\ + \beta_1x_{J+1i} + \beta_2x_{J+2i} + \cdots + \beta_kx_{J+Ki} \\ + \alpha\beta_{11}x_{J+K+1i} + \alpha\beta_{12}x_{J+K+2i} + \cdots + \alpha\beta_{JK}x_{J+K+JKi} \\ + \varepsilon_{ijk}$$

$\varepsilon_{ijk} \sim N(0, \sigma^2)$

③ モデル3：端点制約を持つモデル

$$y_{ijk} = \mu + \alpha_j + \beta_k + \alpha\beta_{jk} + \varepsilon_{ijk}$$

$\varepsilon_{ijk} \sim N(0, \sigma^2)$

$\alpha_1 = 0$

$\beta_1 = 0$

$\alpha\beta_{11} = 0$
 $\alpha\beta_{12} = 0$
 \vdots
 $\alpha\beta_{1K} = 0$

$\alpha\beta_{j1} = 0$
 $\alpha\beta_{21} = 0$
 \vdots
 $\alpha\beta_{J1} = 0$

ダミー変数
で表現

$$y_{ijk} = \mu + \alpha_2 x_{1i} + \alpha_3 x_{2i} + \dots + \alpha_j x_{j-1i} + \beta_2 x_{ji} + \beta_3 x_{j+1i} + \dots + \beta_K x_{j+K-2i} + \alpha\beta_{22} x_{j+K-1i} + \alpha\beta_{23} x_{j+Ki} + \dots + \alpha\beta_{2K} x_{j+2K-2i} + \alpha\beta_{32} x_{j+2K-1i} + \alpha\beta_{33} x_{j+2Ki} + \dots + \alpha\beta_{3K} x_{j+3K-3i} + \dots + \alpha\beta_{j2} x_{jK-K+1i} + \alpha\beta_{j3} x_{jK-K+2i} + \dots + \alpha\beta_{jK} x_{jK-1i} + \varepsilon_{ijk}$$

$\varepsilon_{ijk} \sim N(0, \sigma^2)$

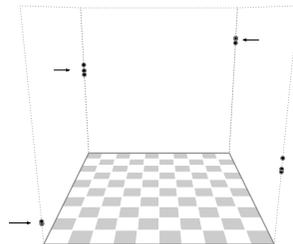
(J-1)
x
(K-1)

※独立なパラメータの数：

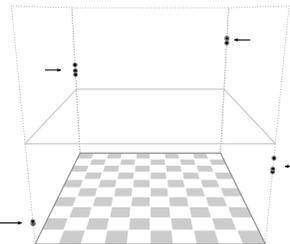
$$1 + (J - 1) + (K - 1) + (J - 1)(K - 1) = JK$$

※ 図による理解

モデル1



モデル2



モデル3

