

読めば必ずわかる分散分析の基礎

第2版 2003年12月5日

小野 滋

この解説書は、分散分析の基礎について、

可能な限りわかりやすく、かつ詳しく

説明することを目的としています。

簡潔さは犠牲にし、長くてくどいかわりに、

読めばわからずにはられない

説明を目指したいと思います。

なお、説明中に用いる記号は、後藤ほか(編)「心理学マニュアル 要因計画法」(北大路書房)に準じています。

目次

第I部 はじめに	3
1 予備知識	3
2 なぜ分散には2種類あるのか?	6
3 平方和, 自由度, 平均平方	11
4 なぜ分散分析が必要か?	12
第II部 基礎編	14
5 構造モデル	15
6 分散分析の前提	16
7 分散分析の発想	17
8 平方和の分解	19
9 平均平方の算出	21
10 平均平方の意義	22
11 F検定	25
12 まとめ: 1要因の分散分析	26

第1部

はじめに

1 予備知識

この解説書では、全くの初学者を念頭において、できるかぎり易しい説明を試みます。それでも、説明の都合上、データ解析と実験研究について、ある程度の知識が必要です。

そこで、読み進めるのにどうしても必要だと思われる予備知識を、17項目にまとめてみました。以下のリストに目を通して、もし理解できない箇所があったら、その箇所を復習してから、先に進んで下さい。

量的データの記述

- 1.1 量的データの全体的な大きさをあらわす指標として、平均が用いられることが多い。データ x_1, x_2, \dots, x_n の平均 \bar{x} (「エックス・バー」) は、

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

として求められる。

- 1.2 量的データのばらつきをあらわす指標として、分散と標準偏差(SDともいう)が用いられることが多い。データ x_1, x_2, \dots, x_n の分散 s^2 は、

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

として求められる。また標準偏差 s は、

$$s = \sqrt{s^2}$$

として求められる。

母集団と標本

- 2.1 ある変量について、分析者が関心を持っている値の全体を、母集団と呼ぶ。
- 2.2 いっぽう、手元にあるデータの集まりを、標本と呼ぶ。標本のなかに含まれている値の数を、標本のサイズと呼ぶ。
- 2.3 標本はいわば、母集団から取り出した(抽出した)値の集まりである、と考えることができる。標本の性質をもとに、母集団の性質を推測するためには、標本は次の2つの性質を備えていなければならない:

不偏性：母集団から偏りなく抽出されていること
 独立性：個々のデータが、互いに影響を及ぼしていないこと
 これらの性質を備えている標本のことを、無作為標本と呼ぶ。

確率分布

- 3.1 とりうる実現値にそれぞれ確率が割りふられている変数のことを、確率変数という。また、それぞれの実現値に確率が割りふられているようすのことを、確率分布という。
- 3.2 重要な確率分布のひとつに、正規分布がある。平均 0, 分散 1 の正規分布を、とくに標準正規分布と呼ぶ。

母集団特性の推定

サイズ n の無作為標本から、母集団の性質について推定するとき、

- 4.1 母平均 μ (「ミュー」) の推定のためには、標本平均 \bar{x} を用いるとよい。
- 4.2 母分散 σ^2 (「シグマの二乗」) の推定のためには、標本分散 s^2 を少し大きめに修正した不偏分散

$$u^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

を用いるとよい。

仮説検定

- 5.1 仮説検定と呼ばれる手法は、次の 4 つの段階からなる。
1. 帰無仮説 (H_0) を設定する。
 2. 検定統計量を定める。
 3. 決められた有意水準のもとでの棄却域を定める。
 4. 標本から検定統計量の値を求め、棄却域と比較して、帰無仮説の棄却の有無を決定する。
- 5.2 有意水準は、「帰無仮説が真のとき、誤って帰無仮説を棄却してしまう」確率をあらわしている。5% ないし 1% がよく用いられる。

実験研究の基礎概念

- 6.1 実験とは、いくつかの変数の値を研究者が操作し、それが別の変数にどう影響するか、を調べる研究のことである。
- 6.2 したがって実験研究では、変数は次の 3 つのどれかに分類されることになる。
- 従属変数 測定される変数。“原因-結果” という文脈でいえば、結果の側。
 - 独立変数 研究者が操作する変数。要因, 処理, 説明変数, などともいう。
 - 剰余変数 従属変数に影響を与えるかもしれないのに、研究者が操作していない変数。
- 6.3 独立変数のとる値は、いくつかに限られるのがふつうである。このとき、それぞれの値を水準という。

-
- 6.4 独立変数が複数ある実験の場合，水準と水準の組み合わせのことをセルという。
- 6.5 あるセルのなかにある測定値の数のことを，繰り返し数と呼ぶ。
- 6.6 心理学での実験研究においては，独立変数（要因）の操作のしかたを，つぎの2種類におおまかにわけることができる。
- 被験者間要因：要因の各水準ごとに，異なる被験者が用意される場合
- 被験者内要因：各被験者が，その要因のすべての水準の下で実験を行う場合

2 なぜ分散には2種類あるのか?

予備知識 4.2 として挙げた「不偏分散」については、多くの人が納得のいかない思いをします。なぜ、本来の分散(標本分散)のほかに、不偏分散が必要なのでしょう? この2つはどのように使い分ければ良いのでしょうか?

そこで、以下に3通りの説明(梅, 竹, 松)を用意しました。先に進むほど、突っ込んだ議論になります。

すくなくとも、梅コースの内容については、きちんと理解してください。竹コース・松コースは、読み飛ばしてもかまいません。

2.1 梅コース

データ x_1, x_2, \dots, x_n について、全体的な大きさをあらわす指標としては、平均

$$\text{平均 } \bar{x} = \frac{1}{n} \sum_{i=1}^n x$$

がよく用いられる。

また、値のばらつきをあらわす指標としては

$$\text{標本分散 } s^2 = \frac{1}{n} \sum_{i=1}^n (x - \bar{x})^2$$

$$\text{不偏分散 } u^2 = \frac{1}{n-1} \sum_{i=1}^n (x - \bar{x})^2$$

の2種類がよくもちいられる。

データについて述べる際、標本分散 s^2 (ないし標本標準偏差 s) を用いるべきか、それとも不偏分散 u^2 (ないし不偏標準偏差 u) を用いるべきかは、記述の目的によって決まる問題である。

- 手元のデータそのものについての要約に重点がある場合には、標本分散を
- 母集団についての推測に重点がある場合には、不偏分散を

用いるのが理にかなっている。もっとも、どちらを使ってもおかしくないケースも多い。

2.2 竹コース

手元にあるデータ x_1, x_2, \dots, x_n が、ある母集団からの無作為標本だとみなせる場合について考える。母集団のなかには無限個の (ないし、非常に多くの) 値が含まれていると考えられるが、それら無限個の値にも、平均や分散があると考えられるだろう。ここで、母平均 (母集団の平均) を μ 、母分散 (母集団の分散) を σ^2 と表記することにする。

では、手元にあるデータから、母集団の性質を推測する方法について考えてみよう。

母平均の推定量 まず、母平均 μ を推定するためには、標本のどのような性質に着目すればよいだろうか。いろいろな考え方がありうるが、一般的にいて、標本平均 \bar{x} に着目するやり方が、一番優れていることがわかっている。そこで、母平均 μ の推定のためには、標本平均 \bar{x} を用いる。

母分散の推定量 ところが、母分散 σ^2 の推定という問題は、さほど簡単ではない。標本の分散 s^2 は、一般的にいて、 σ^2 よりも少し小さめの値になってしまう。なぜか?

もともと分散とは、「それぞれの値と平均との距離 (偏差) の二乗の平均」をあらわすものである。だから、 σ^2 の推定量としては、本来は $\frac{1}{n} \sum (x_i - \mu)^2$ がふさわしいのである。

しかし現実には、母平均 μ の値はわからないので、標本平均 \bar{x} で代用せざるを得ない。ところが $\frac{1}{n} \sum (x_i - \bar{x})^2$ は、本来の推定量 $\frac{1}{n} \sum (x_i - \mu)^2$ よりも、少し小さめになってしまう。なぜなら、いま任意の値 c について $\sum (x_i - c)^2$ を求めることにすると、その値が一番小さくなるのは、 c が \bar{x} に一致するときだからである。

そこで、 s^2 を少し大きめに修正したものを、 σ^2 の推定量にすればいい、という考え方が登場する。この修正された分散を「不偏分散」と呼んでいる。ここで、

$$\text{不偏分散 } u^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

であるということがわかっている (2.3 参照)。母分散 σ^2 の推定のためには、この不偏分散 s^2 を用いる。なお、不偏分散と区別するために、本来の分散を「標本分散」と呼ぶことがある。

2.3 松コース

では、なぜ不偏分散 u^2 の分子は $n - 1$ なのだろうか? どうしても気になってしかたがないあなたのために、徹底的な説明をお送りしよう。

2.3.1 確率変数と期待値

まず、期待値という概念を導入する。少し抽象的な話になるので、ゆっくり読み進めてほしい。

数学の世界では、取りうる値 (実現値) に確率が割り振られているような変数のことを、確率変数と呼んでいる。ある確率変数 Y について、その確率分布の平均を、 Y の期待値 $E(Y)$ と呼ぶ。

たとえば、「サイコロを振ったときに出る目」という変数 X は、実現値 $(1, 2, 3, 4, 5, 6)$ に確率が割り振られているので (すべて $1/6$)、確率変数だということができる。その期待値 $E(X)$ は、サイコロを無限回振って手にはいる、無限個の目 $(1, 1, 1, \dots, 2, 2, 2, \dots, 6, 6, 6)$ の平均値、すなわち 3.5 である。

ある変数の期待値 いま手元に、ある変数についての n 個のデータ x_1, x_2, \dots, x_n があるとしよう。これらのデータは、いわば X という謎のサイコロを n 回振って手に入れた値だ、とみなすことができる。つまり、変数 X は、確率変数だとみなすことができるわけである。

その期待値 $E(X)$ とは、「データサイズ n が無限大にまで大きくなったときに、そこから得られる平均」のことである。手元のデータがなんらかの母集団の無作為標本であるならば、「無限大の大きさの標本」とは、すなわち母集団のことになる。だから、これは母平均 μ をあらわしている。すなわち、

$$E(X) = \mu \tag{1}$$

ある変数のばらつきの期待値 つぎに、変数 X のあるひとつのデータと、その母平均 μ とのずれの大きさについて考えてみたい。そのためには、ずれの絶対値 $|X - \mu|$ について考えればよいだろう。しかし、絶対値は数学的に扱いが面倒なので、そのかわりに、ずれの二乗 $(X - \mu)^2$ について考えることにする。

その期待値 $E[(X - \mu)^2]$ とは、「無限大のサイズの標本について、すべてのデータからそれぞれの $(X - \mu)^2$ を求めた、その平均」のことである。さきにもたのように、「無限大の大きさの標本」は

母集団に相当するから、結局これは母分散 σ^2 のことである。すなわち、

$$E[(X - \mu)^2] = \sigma^2 \quad (2)$$

データの平均の期待値 では、上の n 個のデータから求める統計量、たとえば平均 \bar{X} について考えてみよう。この値は、その値が確率的に決まるという意味で、いわば \bar{X} という謎のサイコロを 1 回振って手に入れた値だ、とみなすことができる。つまり、標本平均 \bar{X} もまた、確率変数だとみなすことができる。

その期待値 $E(\bar{X})$ とは、「もし標本抽出を無限回繰り返し、標本平均が無限個手に入ったら、それらの平均はなにか」を意味する。当然それは、母平均 μ に一致する。すなわち、

$$E(\bar{X}) = \mu \quad (3)$$

である。

ところでこの式は、「標本平均 \bar{X} は母平均 μ の不偏推定量 (偏りのない推定量) だ」ということに対応している。このように、

「標本から得られる統計量 は、母集団の特性 $\times \times$ の不偏推定量だ」ということを、
 $E(\quad) = \times \times$ とあらわすことができる。

データの平均のばらつきの期待値 さて、標本平均 \bar{X} は、母平均 μ からさほど遠くない推定を与えてくれることもあれば、大きく外してしまうこともあるだろう。そのばらつきの程度について考えてみたい。そのためには、推定のずれの絶対値 $|\bar{X} - \mu|$ の期待値について考えればよいだろう。しかし、絶対値は数学的に扱いが面倒なので、そのかわりに、推定のずれの二乗の期待値 $E[(\bar{X} - \mu)^2]$ について考えることにしよう。

証明は省くが、次の式が成り立つことがわかっている。

$$E[(\bar{X} - \mu)^2] = \frac{\sigma^2}{n} \quad (4)$$

この式は、「母平均 μ を、標本平均 \bar{X} を用いて推定するとき、その推定のずれは、母集団の値のばらつき σ^2 が大きいときに大きく、標本サイズ n が大きいときに小さい」という、ごくあたりまえの事柄に対応している。

2.3.2 なぜ $n-1$ か

では、いよいよ本題に戻ろう。まず、 u^2 の分子の部分を変形する。

$$\begin{aligned}
 & \sum (x_i - \bar{x})^2 \\
 &= \sum [(x_i - \mu) + (\mu - \bar{x})]^2 \\
 &= \sum (x_i - \mu)^2 + 2 \sum (x_i - \mu)(\mu - \bar{x}) + \sum (\bar{x} - \mu)^2 \\
 &= \sum (x_i - \mu)^2 - 2(\bar{x} - \mu) \sum (x_i - \mu) + n(\bar{x} - \mu)^2 \\
 &= \sum (x_i - \mu)^2 - 2(\bar{x} - \mu)(\sum x_i - n\mu) + n(\bar{x} - \mu)^2 \\
 &= \sum (x_i - \mu)^2 - 2(\bar{x} - \mu)(n\bar{x} - n\mu) + n(\bar{x} - \mu)^2 \\
 &= \sum (x_i - \mu)^2 - 2n(\bar{x} - \mu)^2 + n(\bar{x} - \mu)^2 \\
 &= \sum (x_i - \mu)^2 - n(\bar{x} - \mu)^2
 \end{aligned}$$

第1項 $\sum (x_i - \mu)^2$ の期待値は、

$$\begin{aligned}
 E[\sum (x_i - \mu)^2] &= E[(x_1 - \mu)^2] + E[(x_2 - \mu)^2] + \cdots + E[(x_n - \mu)^2] \\
 &= \sigma^2 + \sigma^2 + \cdots + \sigma^2 \quad \text{式(2)} \\
 &= n\sigma^2
 \end{aligned}$$

第2項 $n(\bar{x} - \mu)^2$ の期待値は、

$$\begin{aligned}
 E[n(\bar{x} - \mu)^2] &= n \times E[(\bar{x} - \mu)^2] \\
 &= n \times \frac{\sigma^2}{n} \quad \text{式(4)} \\
 &= \sigma^2
 \end{aligned}$$

従って

$$\begin{aligned}
 E\left[\sum (x_i - \bar{x})^2\right] &= n\sigma^2 - \sigma^2 = (n-1)\sigma^2 \\
 E\left[\frac{1}{n-1} \sum (x_i - \bar{x})^2\right] &= \sigma^2
 \end{aligned}$$

であり、不偏分散 u^2 が母分散 σ^2 の不偏推定量であることがわかる。

3 平方和，自由度，平均平方

今後の説明の都合上，いくつかの用語を紹介しておく。

平方和 2 種類の分散

$$\begin{aligned} \text{標本分散 } s^2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \\ \text{不偏分散 } u^2 &= \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \end{aligned}$$

は，分子 $\sum (x - \bar{x})^2$ が共通している。この部分は，偏差の平方（二乗のこと）の合計なので，偏差平方和と呼んだり，単に平方和(SS と略記する)と呼んだりする。変動と呼ぶこともある。

自由度 いっぽう，不偏分散の分子の部分 $n-1$ を，この平方和の自由度(df と略記する)と呼ぶ。

自由度とは，自由に値をとることができる変数の数を指す用語である。たとえば，3 つの変数 X_1, X_2, X_3 があるとしよう。これらの変数の値について，平均と平方和を求める式は，

$$\begin{aligned} \text{平均 } \bar{X} &= \frac{X_1 + X_2 + X_3}{3} \\ \text{平方和 } SS &= (X_1 - \bar{X})^2 + (X_2 - \bar{X})^2 + (X_3 - \bar{X})^2 \end{aligned}$$

となる。さて，平方和の式の右辺には，3 つの変数が登場するが， \bar{X} が決まっているとすると，自由に動ける変数は 2 つしかない(もし $\bar{X} = 10, X_1 = 9, X_2 = 10$ ならば， X_3 の値は 11 に決まってしまう)。このことを指して，この平方和の自由度は 2 である，と言う。

平均平方 平方和を自由度で割ったもののことを，平均平方と呼ぶ(MS と略記する)。従って，2章で示したのは，「標本の平均平方は母分散の不偏推定量である」ということであった，といいかえることができる。

4 なぜ分散分析が必要か?

4.1 水準が3つ以上のときに必要だ

たとえば、次のような問題について考えてみよう。

例題 1 (後藤ほか編, p.30)

生徒の学習形態のちがいが、課題の達成に影響するかどうかを調べるために、あらかじめ学力の等しい生徒をランダムにわけて、3つのグループを構成した。グループ1では一斉指導、グループ2では体験学習、グループ3では仲間による討議学習をおこなった。授業終了後、課題の到達度テストを実施したところ、次の得点(略)が得られた。3つの学習形態のあいだに差はあるか。

この例題について検討する際には、2つの路線がある。

多重比較 ひとつの路線は、この問題を、次の3つの問題と、それに対応する帰無仮説(H_0)に分割する考え方である。

- 一斉指導と体験学習のあいだで、得点のちがいはあるか? ($H_0 : \mu_1 = \mu_2$)
- 体験学習と討議学習のあいだで、得点のちがいはあるか? ($H_0 : \mu_2 = \mu_3$)
- 一斉指導と討議学習のあいだで、得点のちがいはあるか? ($H_0 : \mu_1 = \mu_3$)

これらの帰無仮説(H_0)のそれぞれについて、仮説検定の手法を用いて検討すればよい。

この路線はわかりやすいし、アイデアそれ自体はまちがっていない。しかし、この路線に沿って、単純にt検定を繰り返すのは、統計学的にみて、深刻な誤りである(コラム参照)。このような場合には、多重比較と呼ばれる手法を用いなければならない。

分散分析 もうひとつの路線は、

- 3種類の学習形態の間に、得点のちがいはあるか? ($H_0 : \mu_1 = \mu_2 = \mu_3$)

という問題ひとつだけについて、仮説検定の手法を用いて検討することである。これを可能にしてくれるのが分散分析である。

たいていの場合、多重比較よりも分散分析のほうが簡単だし、結果も解釈しやすい。

分散分析から多重比較へ 分散分析路線の欠点は、仮に「3つの学習形態の間に得点のちがいがあ

る」という結果が得られたとしても、それではどれとどれの間にちがいがあ

4.2 要因が2つ以上あるときに必要だ

この例題では、要因がひとつしかない。しかし、実験研究では、複数個の要因を同時に制御する

コラム：なぜ検定を単純に繰り返してはいけないのか

有意水準5%で検定をおこなうとする。いま帰無仮説 H_0 が真であるとする、誤って H_0 を棄却する確率(タイプIエラーの確率)は0.05である。さて、ひとつの論文のあちこちで、いろいろな問題について別々のデータ解析がおこなわれているとする。検定が3回おこなわれているとしよう。いま、検討されている3つの H_0 がすべて真であるときに、「論文のなかのどこか1箇所以上でタイプIエラーを犯す確率」は、 $1 - 0.95^3 = 0.14$ と、意外に高くなる。10回のときには、実に0.40である。

さらに、異なる検定が同じデータに基づいている場合には、より深刻な問題が生じる。たとえば、A, B, Cの3群間で、A vs. B, B vs. C, C vs. Aの3つの t 検定をおこなったとしよう。いま、Aの標本平均が、運悪く真の平均よりもずっと高かったとすると、その場合、A vs. Bの t 検定でも、A vs. Cの t 検定でも、 H_0 が棄却されやすくなる。従って、検討されている3つの H_0 がすべて真であるときに、「どこか1箇所以上でタイプIエラーを犯す確率」は、 $1 - 0.95^3 = 0.14$ よりも高くなり、予想がつかなくなる。

このように、単純に検定を繰り返すと、

- 全体を通じたタイプIエラーの確率が高くなる。
- データが独立でない場合、タイプIエラーの確率がわからなくなる。

このような場合には、多重比較のための特別な検定手法を用いなければならない。

第 II 部

基礎編

それではいよいよ、分散分析の考え方についての説明をはじめよう。次の例題を用いて説明することにする。

例題 1 (後藤ほか編, p.30)

生徒の学習形態のちがいが、課題の達成に影響するかどうかを調べるために、あらかじめ学力の等しい生徒をランダムにわけて、3つのグループを構成した。グループ1では一斉指導、グループ2では体験学習、グループ3では仲間による討議学習をおこなった。授業終了後、課題の到達度テストを実施したところ、次の得点が得られた。3つの学習形態のあいだに差はあるか。

学習形態	一斉指導	体験学習	討議学習	
	5	8	7	
	4	4	6	
	6	3	8	
	3	3	9	
	3	7	10	
	7	9	9	
	6	8	8	
	5	7	9	
	3	3	7	
	5	4	8	
平均	4.7	5.6	8.1	全平均 6.1
サイズ	10	10	10	

実際の数値を書いているとわかりにくいので、説明文中では下の記号を用いることにする。

要因 A	水準 A_1	水準 A_2	水準 A_3	
	x_{11}	x_{12}	x_{13}	
	x_{21}	x_{22}	x_{23}	
	x_{31}	x_{32}	x_{33}	
	\vdots	\vdots	\vdots	
	x_{n1}	x_{n2}	x_{n3}	
平均	T_1	T_2	T_3	全平均 G
サイズ	n	n	n	

5 構造モデル

まず、例題 1 の特徴を確認しておこう。独立変数(要因) はひとつ、3 水準、水準間にデータの対応がない(いわゆる被験者間要因)。各水準での標本サイズ(繰り返し数) は等しい。

例題 1 のデータについて、「一斉指導群 1 番さんの得点 (5) は、一斉指導を受けた被験者が本来示す得点 (μ_1) に、なんらかの影響 (ε_{11}) が加わったものだ」というふうに考えてみよう。ここでいう“なんらかの影響”とは、学習形態とは無関係な要因すべて、つまり、(この被験者の努力といった) 剰余変数をもたらす影響や、測定の誤差、偶然に生じる値のばらつきなどが含まれる。これをひとことで、誤差と呼ぶことにする。

$$\begin{aligned} \text{一斉指導群 1 番さんの得点 (5)} &= \text{一斉指導群の母平均 } (\mu_1) + \text{誤差 } (\varepsilon_{11}) \\ \text{一斉指導群 2 番さんの得点 (4)} &= \text{一斉指導群の母平均 } (\mu_1) + \text{誤差 } (\varepsilon_{21}) \\ &\vdots \\ \text{体験学習群 1 番さんの得点 (8)} &= \text{体験学習群の母平均 } (\mu_2) + \text{誤差 } (\varepsilon_{12}) \\ &\vdots \\ \text{討議学習群 1 番さんの得点 (7)} &= \text{討議学習群の母平均 } (\mu_3) + \text{誤差 } (\varepsilon_{13}) \\ &\vdots \end{aligned}$$

もっと簡潔に表現してみよう。水準 j ($j = \{1, 2, 3\}$) の母平均を μ_j とすると、水準 j の i 番目の測定値 X_{ij} は $X_{ij} = \mu_j + \varepsilon_{ij}$ とあらわすことができる。

さて、各水準の母平均 μ_1, μ_2, μ_3 の平均を μ とあらわすことにし、 $\mu_1 = \mu + \tau_1, \mu_2 = \mu + \tau_2, \mu_3 = \mu + \tau_3$ とする。ここで μ は、すべての得点の母平均、つまり、学習形態によるちがいを除去した得点の母平均をあらわしている。また τ_1, τ_2, τ_3 は、3 種類の学習形態が持っている、得点への(プラスないしマイナスの)効果をあらわしている。すると、上の式は次のように書き直すことができる。

全体の母平均を μ 、水準 j の効果を τ_j とする。水準 j の i 番目の測定値 X_{ij} は

$$X_{ij} = \mu + \tau_j + \varepsilon_{ij}$$

この数式を、分散分析の構造モデルという。

6 分散分析の前提

さて、分散分析では、誤差 ε_{ij} が平均 0 の正規分布に従い、その分散は等しい、と仮定する。

いいかえれば、

- $\{x_{11}, x_{21}, \dots, x_{n1}\}$ は、平均 $\mu + \tau_1$ の正規分布に従う
- $\{x_{12}, x_{22}, \dots, x_{n2}\}$ は、平均 $\mu + \tau_2$ の正規分布に従う
- $\{x_{13}, x_{23}, \dots, x_{n3}\}$ は、平均 $\mu + \tau_3$ の正規分布に従う
- この3つの正規分布の分散は等しい

と仮定する。

この仮定は、データの性質としては

- 各水準の内側でのデータの分布が、正規分布に近いこと (正規性)
- 各水準の内側でのデータの分散が、だいたい同じであること (等分散性)

に対応する。

例題1のデータについてみると

- 3枚のヒストグラムは、どれもおおまかにいって、左右対称な山形であり、
- 3群の標準偏差は1.35, 2.29, 1.14であり、あまり大きな差はない。

したがって、誤差についての仮定には無理がなさそうだ。

7 分散分析の発想

分散の分析とは？ さて、いま知りたいのは、ガソリンによって燃費に差があるかどうかである。仮説検定の枠組みに従えば、帰無仮説 $H_0: \tau_1 = \tau_2 = \tau_3$ を棄却できるかどうか、を検討することになる。

この問題について検討するためには、 τ_1, τ_2, τ_3 のそれぞれについて推定値を求め、その差を調べればよいのではないかと... という方向に話を進めないのが、分散分析の面白いところである。分散分析では、 τ_1, τ_2, τ_3 そのものについての推定をおこなうのではなく、この3つの効果の分散を推定しようとする。これが「分散分析」という名前の由来である。

ここで、構造モデルの各項の分散について、呼び名と表記を決めておこう。

- X_{ij} の分散、すなわち母集団全体の分散 (全分散) を、 σ_{Total}^2 と表記する。
- τ_j の分散 (つまり $\{\tau_1, \tau_2, \tau_3\}$ の分散) を、要因分散と呼ぶ。 σ_A^2 と表記する*1。
- ϵ_{ij} の分散を、誤差分散と呼ぶ。 σ_{Error}^2 と表記する。

測定値	=	全平均	+	要因の効果	+	誤差
X_{ij}		μ		τ_j		ϵ_{ij}
↓				↓		↓
全分散				要因分散		誤差分散
σ_{Total}^2				σ_A^2		σ_{Error}^2

さて、

- もし学習形態によって得点に差がないならば、 $\tau_1 = \tau_2 = \tau_3 = 0$ なので、 $\sigma_A^2 = 0$ である。
- もし学習形態によって得点に差があるならば、 τ_1, τ_2, τ_3 がなんであれ、 $\sigma_A^2 \neq 0$ である。

だから、 τ_1, τ_2, τ_3 についての推定をおこなわなくても、要因分散 σ_A^2 が0かどうかを判断すれば、用が足りるのである。

要因分散についての検討とは？ ところが、 σ_A^2 の大きさについての検討は、一筋縄ではいかない。

まず、構造モデルの各項について、標本から推定する方法を考えてみると

- 全平均 μ の推定量は \bar{G}

*1 後藤ほか(編)では σ_{Treat}^2 と表記している。なお、 $\sigma_A^2 = \frac{n \sum \tau_j^2}{3-1}$ と定義しておく。

- 各水準の効果 τ_j の推定量は $(\bar{T}_j - \bar{G})$
- 誤差 ε_{ij} の推定量は $(x_{ij} - \bar{T}_j)$

以上の推定量を用いて，手元のデータに構造モデルをあてはめると

$$x_{ij} = \bar{G} + (\bar{T}_j - \bar{G}) + (x_{ij} - \bar{T}_j)$$

となる。

$$\begin{array}{l} \text{母集団 } X_{ij} = \boxed{\mu} + \boxed{\tau_j} + \boxed{\varepsilon_{ij}} \\ \quad \quad \quad \uparrow \text{推定} \quad \quad \uparrow \text{推定} \quad \quad \uparrow \text{推定} \\ \text{標本 } x_{ij} = \boxed{G} + \boxed{(\bar{T}_j - \bar{G})} + \boxed{(x_{ij} - \bar{T}_j)} \end{array}$$

ところで，

- (a) 測定値 x_{ij} の平均平方 (平方和を自由度で割ったもの) は，全分散 σ_{Total}^2 の不偏推定量となる (3章参照)。

ならば，

- (b) $(\bar{T}_j - \bar{G})$ の平均平方は，要因分散 σ_A^2 の不偏推定量となるのではないか?
 (c) $(x_{ij} - \bar{T}_j)$ の平均平方は，誤差分散 σ_{Error}^2 の不偏推定量になるのではないか?

$$\begin{array}{l} \text{母集団 } \boxed{X_{ij}} = \mu + \boxed{\tau_j} + 8 \boxed{\varepsilon_{ij}} \\ \quad \quad \quad \downarrow \quad \quad \quad \downarrow \quad \quad \quad \downarrow \\ \quad \quad \quad \sigma_{Total}^2 \quad \quad \quad \sigma_A^2 \quad \quad \quad \sigma_{Error}^2 \\ \quad \quad \quad \uparrow \text{推定 (a)} \quad \quad \quad \uparrow \text{推定? (b)} \quad \quad \quad \uparrow \text{推定? (c)} \\ \text{標本 } \boxed{MS_{Total}} \quad \quad \quad \boxed{MS_A} \quad \quad \quad \boxed{MS_{Error}} \\ \quad \quad \quad \uparrow \quad \quad \quad \uparrow \quad \quad \quad \uparrow \\ \quad \quad \quad x_{ij} \quad \quad \quad (\bar{T}_j - \bar{G}) \quad \quad \quad (x_{ij} - \bar{T}_j) \end{array}$$

先に結論を紹介しておくとして，(c) は正しいが，(b) は正しくない。しかし，この発想じたいは優れているので，このまま話を先に進めてみよう。

8 平方和の分解

まず、各項の平方和を求めてみよう。

$$\text{全体の平方和 } SS_{Total} = \sum_{j=1}^3 \sum_{i=1}^n (x_{ij} - \bar{G})^2$$

$$\text{要因の平方和 } SS_A = \sum_{j=1}^3 \sum_{i=1}^n \{(\bar{T}_j - \bar{G}) - 0\}^2 = n \sum_{j=1}^3 (\bar{T}_j - \bar{G})^2$$

$$\text{誤差の平方和 } SS_{Error} = \sum_{j=1}^3 \sum_{i=1}^n \{(x_{ij} - \bar{T}_j) - 0\}^2 = \sum_{j=1}^3 \sum_{i=1}^n (x_{ij} - \bar{T}_j)^2$$

ここで、

$$SS_{Total} = SS_A + SS_{Error}$$

という関係が成り立っている(コラム参照)。つまり、ここでおこなっているのは、測定値の平方和を分解する作業なのである。

例題1の場合。わかりやすいように、全平均 \bar{G} を左辺に移項している。

(得点 - 全平均) $(x_{ij} - \bar{G})$	=	(水準の平均 - 全平均) $(\bar{T}_j - \bar{G})$	+	(得点 - 水準の平均) $(x_{ij} - \bar{T}_j)$
(5 - 6.1)	=	(4.7 - 6.1)	+	(5 - 4.7)
(4 - 6.1)	=	(4.7 - 6.1)	+	(4 - 4.7)
⋮		⋮		⋮
(8 - 6.1)	=	(5.6 - 6.1)	+	(8 - 5.6)
(4 - 6.1)	=	(5.6 - 6.1)	+	(4 - 5.6)
⋮		⋮		⋮
(7 - 6.1)	=	(8.1 - 6.1)	+	(7 - 8.1)
(6 - 6.1)	=	(8.1 - 6.1)	+	(6 - 8.1)
⋮		⋮		⋮
↓		↓		↓
二乗して合計 $SS_{Total} = 145.47$		二乗して合計 $SS_A = 62.07$		二乗して合計 $SS_{Error} = 83.4$

ここで行ったのは、得点のばらつき 145.47 を、学習形態に由来するばらつき 62.07 と、それ以外のばらつき 83.4 とに分解する作業であった、ということができる。

コラム: なぜ平方和は分解できるのか

構造モデル

$$x_{ij} = \bar{G} + (\bar{T}_j - \bar{G}) + (x_{ij} - \bar{T}_j)$$

の \bar{G} を左辺に移項して

$$x_{ij} - \bar{G} = (\bar{T}_j - \bar{G}) + (x_{ij} - \bar{T}_j)$$

両辺を 2 乗して

$$(x_{ij} - \bar{G})^2 = (\bar{T}_j - \bar{G})^2 + (x_{ij} - \bar{T}_j)^2 + 2(\bar{T}_j - \bar{G})(x_{ij} - \bar{T}_j)$$

合計して

$$\sum_j \sum_i (x_{ij} - \bar{G})^2 = \sum_j n(\bar{T}_j - \bar{G})^2 + \sum_j \sum_i (x_{ij} - \bar{T}_j)^2 + \sum_j \sum_i 2(\bar{T}_j - \bar{G})(x_{ij} - \bar{T}_j)$$

第三項は

$$\begin{aligned} \sum_j \sum_i 2(\bar{T}_j - \bar{G})(x_{ij} - \bar{T}_j) &= 2 \sum_j \{(\bar{T}_j - \bar{G}) \sum_i (x_{ij} - \bar{T}_j)\} \\ &= 2 \sum_j \{(\bar{T}_j - \bar{G}) \times 0\} \\ &= 0 \end{aligned}$$

従って、

$$\begin{aligned} \sum_j \sum_i (x_{ij} - \bar{G})^2 &= \sum_j n(\bar{T}_j - \bar{G})^2 + \sum_j \sum_i (x_{ij} - \bar{T}_j)^2 \\ SS_{Total} &= SS_A + SS_{Error} \end{aligned}$$

であることがわかる。

なお、構造モデルがもっと複雑なものになっても、上記と同じように、全体の平方和を各項の平方和の和に分解することができる。

9 平均平方の算出

次に，それぞれの平方和が持つ自由度について考えておこう。自由度とは，自由に動くことができる値の数なので（3章参照），

- 全体の平方和 SS_{Total} の自由度 = (値の個数 - 1) = $3n - 1$
- 要因の平方和 SS_A の自由度 = (\bar{T}_j の個数 - 1) = $3 - 1$
- 誤差の平方和 SS_{Error} の自由度 = 水準数 × (水準内の値の個数 - 1) = $3(n - 1)$

となる。ここで

$$(3n - 1) = (3 - 1) + 3(n - 1)$$

であり，自由度もまた，平方和と同じように分解されている。

それでは，各項の平均平方（平方和を自由度で割った値）を求めよう。

$$\text{全体の平均平方 } MS_{Total} = SS_{Total} / (3n - 1)$$

$$\text{要因の平均平方 } MS_A = SS_A / (3 - 1)$$

$$\text{誤差の平均平方 } MS_{Error} = SS_{Error} / 3(n - 1)$$

例題 1 の場合:

(得点 - 全平均) $(x_{ij} - \bar{G})$	=	(水準の平均 - 全平均) $(\bar{T}_j - \bar{G})$	+	(得点 - 水準の平均) $(x_{ij} - \bar{T}_j)$
↓		↓		↓
二乗して合計 $SS_{Total} = 145.47$		二乗して合計 $SS_A = 62.07$		二乗して合計 $SS_{Error} = 83.4$
↓		↓		↓
自由度は $3n - 1 = 29$		自由度は $3 - 1 = 2$		自由度は $3(n - 1) = 27$
↓		↓		↓
わり算して $MS_{Total} = 5.02$		わり算して $MS_A = 31.03$		わり算して $MS_{Error} = 3.08$

10 平均平方の意義

この章も、少し面倒な内容を含んでいるので、3通りの説明(梅, 竹, 松)を用意しました。先に進むほど、突っ込んだ議論になります。すくなくとも、梅コースの内容については、きちんと理解してください。竹コース・松コースは、読み飛ばしてもかまいません。

10.1 梅コース

さて、いま私たちが目指しているのは、要因分散 σ_A^2 が0かどうかの判断である。そのためには、 MS_A だけを調べていては不十分である。なぜなら、誤差分散 σ_{Error}^2 が大きいときにも、 MS_A は大きくなってしまうからである。

そこで、 MS_A を MS_{Error} で割った量

$$F = MS_A / MS_{Error}$$

を調べる。

例題1の場合は、

$$F = 31.03 / 3.08 = 10.04$$

F 値は、要因分散 σ_A^2 が0のときに1に近くなり、 σ_A^2 が0でないとき(すなわち、要因の水準によって差があるとき)には1よりも大きな値になる。

10.2 竹コース

以上の内容を，別の角度から説明しよう。

図 1 は，例題 1 のデータを縦に並べ，プロットしたものである。図の上・中・下が，3 種類の学習形態に対応している。黒丸は測定値を，中央の縦の点線は全平均 \bar{G} を，太線は各水準の平均 $\bar{T}_1, \bar{T}_2, \bar{T}_3$ を示している。 MS_{Total} は黒丸のばらつき， MS_A は太線のばらつき， MS_{Error} は黒丸から太線までの垂線の長さのばらつきに相当する。

この図をみるだけで，被験者の属する群によって黒丸の位置が異なっていること，したがって要因の効果がみられることが，直感的にわかるだろう。

では，もしデータが図 2 のようであったらどうだろうか。この図の太線は，図 1 の太線とまったく同じである。しかしこの図の黒丸の布置をみても，要因の効果がみられるとはとても思えない。なぜなら，測定値のばらつきが大きいからである。たしかに，太線にもばらつきはみられるものの，それは単に測定値のばらつきのせいではないか，つまり，もうすこし測定値を増やせば，太線のかたちは簡単に変わってしまうのではないか — という気がするだろう。

このように，要因の効果があるかどうか ($\sigma_A \neq 0$ かどうか) の判断は，誤差 e_{ij} のばらつきと 比べて水準の平均 \bar{T}_j のばらつき が大きいかどうか，に基づいておこなわれるべきである。そ




図 1: 例題 1 のデータ




図 2: もしこんなデータなら...

ここで、「水準の平均のばらつき MS_A が、誤差 e_{ij} のばらつき MS_{Error} の何倍あるか」、つまり $F = MS_A/MS_{Error}$ を求めるのである。もし要因の効果がなければ、 MS_A と MS_{Error} は同程度となり、 F は 1 に近くなるだろう。もし要因の効果があるのなら、 F はもっと大きな値になるだろう。

10.3 松コース

以下の説明は、2章の松コース(2.3)を読了した人向けに書かれています。

3章で述べたように、データの平方和を自由度で割ると、母分散の不偏推定量が手にはいる。これを期待値という概念を用いてあらわせば、

$$E(MS_{Total}) = \sigma_{Total}^2$$

さて、要因の平均平方 MS_A の期待値は

$$E(MS_A) = \sigma_{Error}^2 + n\sigma_A^2$$

となる*2。つまり、 MS_A は σ_A^2 の不偏推定量ではなく、 σ_A^2 と σ_{Error}^2 の両方を反映する統計量なのである。

いっぽう、誤差の平均平方 MS_{Error} の期待値は

$$E(MS_{Error}) = \sigma_{Error}^2$$

であり*3、 MS_{Error} は誤差分散 σ_{Error}^2 の不偏推定量である。

さて、

- もし要因の効果がなければ (H_0 が真ならば)、 MS_A と MS_{Error} とは、ともに σ_{Error}^2 の不偏推定量だから、近い値になるはずである。
- いっぽう、要因の効果があるならば (H_0 が偽ならば)、それがどのような効果であれ、 MS_A は大きくなるはずである。

そこで、 $F = MS_A/MS_{Error}$ を検定統計量として、 $H_0 : \sigma_A^2 = 0$ についての仮説検定をおこなうわけである。(σ_A^2 の大きさの推定や、 τ_1, τ_2, τ_3 の推定には、もはや関心が持たれていないことに注目してほしい。)

*2 高校までの数学で導出できる。お試しあれ。

*3 同上。

11 F 検定

それでは, F を検定統計量として, 要因の効果の有無についての仮説検定をおこなうことにしよう。

予備知識 5.1 に挙げたように, 仮説検定は 4 つの段階からなる。

1. 帰無仮説 (H_0) を設定する 帰無仮説は:

$$H_0: \text{要因の効果はない} (\tau_1 = \tau_2 = \tau_3 = 0, \sigma_A^2 = 0)$$

2. 検定統計量を定める すでに説明したように, 検定統計量としては F を用いる。

3. 決められた有意水準のもとでの棄却域を定める さて, 誤差の正規性と等分散性という仮定が成り立っているときに限り (6 章参照), F には以下の性質がある。帰無仮説が真である場合には, F は「自由度 (要因の自由度, 誤差の自由度) の F 分布」と呼ばれる確率分布に従う。いっぽう, 帰無仮説が偽の場合には, F は大きくなる。

そこで, F 分布の右 $\alpha\%$ の範囲を, 有意水準 $\alpha\%$ の棄却域と定めることにする。

例題 1 では: 自由度 (2, 27) の F 分布を用いる。1% 棄却域は $F > 5.49$ である。

4. 棄却の有無を決定する F 値が棄却域に含まれていた場合は, 帰無仮説は棄却される。

例題 1 では: $F = 10.04$ は棄却域に含まれているので, 棄却域は 1% 有意水準で棄却される。従って, 学習形態という要因の効果が認められたと判断される。

ここで, F 値の大きさは効果の大きさをあらわしているわけではない, という点に注意してほしい。前章でみたように, F は効果の大きさ (σ_{Total}^2) をあらわす指標ではない。

12 まとめ: 1 要因の分散分析

どのようなデータであれ、分散分析を用いたデータ分析は、6つの段階からなっている。

1. データの構造についてよく考え、構造モデルを構築する。
2. 誤差の分布についての仮定が、データにあてはまっているかどうか検討する。
3. 平方和を分解し、各項の平均平方を求める。
4. 検討したい要因について、 F を求め、帰無仮説の棄却の有無を判断する。
5. それがないを意味しているのか考えるために、グラフに戻ったり、下位検定に進んだりする。

この解説書では、このうち 1-5 の段階について、いわゆる被験者間 1 要因計画の実験データを例に挙げて、詳しく検討してきた。

ここまでの内容をまとめておこう。1 要因 (k 水準, 水準間にデータの対応なし) の実験の結果、測定値 x_{ij} を得た。ただし、 i は各水準内での測定値の番号 ($1 \sim n_k$)、 j は水準の番号 ($1 \sim k$) とする (下表)。

要因 A	水準 A_1	水準 A_2	...	水準 A_k	
	x_{11}	x_{12}	...	x_{1k}	
	x_{21}	x_{22}	...	x_{2k}	
	x_{31}	x_{32}	...	x_{3k}	
	\vdots	\vdots	...	\vdots	
	$x_{n_1 1}$	$x_{n_2 2}$...	$x_{n_k k}$	
平均	T_1	T_2	...	T_k	全平均 \bar{G}
サイズ	n_1	n_2	...	n_k	

このとき、誤差の正規性と等分散性という仮定の下で、分散分析をおこなうことができる。

分散分析の計算過程は、下のような書式の表にまとめることが多い。これを分散分析表という。

変動因	平方和 (SS)	自由度 (df)	平均平方 (MS)	F
要因 (A)	$\sum_{j=1}^k n_j (\bar{T}_j - \bar{G})^2$	$k - 1$	$\frac{SS_A}{k - 1}$	$\frac{MS_A}{MS_{Error}}$
誤差 ($Error$)	$\sum_{j=1}^k \sum_{i=1}^{n_j} (x_{ij} - \bar{T}_j)^2$	$\sum_{j=1}^k (n_j - 1)$	$\frac{SS_{Error}}{\sum_{j=1}^k (n_j - 1)}$	
全体	$\sum_{j=1}^k \sum_{i=1}^{n_j} (x_{ij} - \bar{G})^2$	$\sum_{j=1}^k n_j - 1$		