

## 完全情報最尤法を用いた令和5年度理科②の周辺平均

荘島 宏二郎, 橋本 貴充, 宮澤 芳光, 石岡 恒憲, 大津 起夫, 前川 眞一 (大学入試センター)

令和5(2023)年1月に実施された第3回大学入学共通テストの理科②において得点調整が実施された。本研究では、20点差以上ついた物理・生物の平均点差のうち、選択科目における受験者集団の学力差によって、どれくらいの割合が説明できるのかを統計分析によって検討した。具体的には、モデルとして多変量正規分布を、欠測メカニズムとしてランダム欠測を仮定し、完全情報最尤法によってモデルの母数(多変量正規分布の平均ベクトルと共分散行列)を推定した。用いたデータは、中間集計データ(22万人、全体の約45%)であった。その結果、平均点差は、13.73点(57.4%)に縮小した。

キーワード：共通テスト, 理科②, 得点調整, 完全情報最尤法, ランダム欠測

### 1 はじめに

令和5(2023)年1月に実施された第3回大学入学共通テスト(以下、共通テスト)では、理科②において得点調整が実施された(大学入試センター, 2023a)。得点調整は、原則として、得点調整対象科目間に20点以上の平均点差が生じ、これが試験問題の難易差に基づくものと認められる場合には、得点調整を行う(大学入試センター, 2022, pp.52-53)とされている。ただし、受験者数が1万人に満たない科目については、得点調整対象科目から外れるという付則がある。

表1は、2023年1月18日(水曜日)付で(大学入試センター, (2023b)が公表した各科目テストの基本統計量のうち、理科②の4科目について抜粋したものである。水曜日時点で公表される統計資料は、中間発表と呼ばれ、全体の半分弱である約22万人の集計結果となっている。このうちの56,212人が物理を受験し、彼らの平均点が64.46点であった、ということである。その他の科目も同様である。

表1 理科②の基本統計量(中間発表 221,659人)

科目	n	平均	Max	Min	SD
物理	56,212	64.46	100	0	22.80
化学	67,665	49.95	100	0	20.14
生物	21,500	40.55	96	0	15.14
地学	656	49.12	100	0	21.50

表1より、物理と生物の平均点差が約24点であることが分かる。20点以上の差は、最終結果まで維持され、この差が科目の難易差に基づくことと判断されたことにより得点調整が実施された。なお、地学は、受験者数が1万人に満たなかったため、得点調整の対象か

ら外れ、物理・化学・生物(物化生)の3科目のみで調整が行われた。

ところで、平均点差には、科目間の難易差のほかに受験者の学力差も混入している。一般的に、物理選択者の学力は高いので、物理(および化学)の平均点が高かったのは、物理選択者の学力が高いことも一因である。図1は、物化生選択者別の国語・数学・英語(国数英)の平均点を示している。物理選択者(と化学選択者)の国数英の平均点は生物選択者のそれらよりも高いことが分かる。




図1 物化生選択者別の国数英の平均値 (ただし200点満点の国語は0.5を掛けて表示)

規則で「平均点差20点以上」が得点調整実施の前提条件となっているのは、平均点差が素朴な意味で科目間の難易差を代弁しているからである。しかし、実際には、科目間の平均点差には、科目間難易差と選択受験者間学力差が混交しているため<sup>1)</sup>、平均点差から科目間難易差を見積もることは難しい。本研究では、完全情報最尤法(full-information maximum likelihood, FIML; Arbuckle, 1996)を用いて、「仮に全員が物化

生を受けたら平均点がそれぞれ何点になるのか」ということを推測することで、平均点差に含まれる選択受験者間学力差の除去を試みる<sup>2)</sup>。

共通テストは、全体で10の時間区分(コマ)に分けられて各教科科目が実施されている。受験者は、各自必要な科目を選択して受験するため、受験しなかった科目の得点は欠測データとなる。平均点は、選択した(観測された)受験者の得点から算出するため、選択受験者の学力が高い(低い)と平均点が高く(低く)なるという性質がある。

この性質を修正する1つのやり方として、欠測となっている受験者の分も含めて平均点を推測することがある。例えば、物理を選択しなかった受験者を含めた全受験者の物理の得点の平均値を推測することがある。仮に全員が物化生を受けたときのそれら3科目の平均値を知ることができれば、そこで得られた平均点差は、学力差が除去されて残った科目間の難易差とすることができる。

欠測を考慮した分析という意味で、同様な試みを行った先行研究として、ランダムフォレストを用いた方法(石岡, 2011)、非線形因子分析を用いた方法(大津, 2011)、加算モデルを用いた方法(前川, 2020)、傾向スコアを用いた方法(吉村・荘島, 2004; 荘島・橋本・宮澤・石岡・前川, 2022)などがある。なお、共通テストの前身である大学入試センター試験に対して、FIMLを適用した例は、荘島・大津・田栗(2006)やShojima, Otsu, Mayekawa, Taguri, & Yanai(2007)にあるが、得点調整における平均点差に着目した分析ではなく、科目間の相関構造や因子構造に着目した分析であった。また、荘島・石塚・橋本(2007)では、FIMLを用いた科目の平均点にも触れているが、全体として得点調整の枠組みを論じており、FIMLはそのうちの手法の1つとして取り上げられているのみで詳述されていない。本研究では、FIMLを用いた科目間平均点差に焦点化して論じることを目的とする。

## 2 方法

### 2.1 データ

1月18日(水曜日)付けで公表された221,659人の中間集計データを用いる。これは、最終集計の約45%の受験者に関するデータである<sup>3)</sup>。

また、分析に用いる科目は、表2に挙げた19科目とした。共通テストは全部で31科目あるのに、なぜこれら19科目を選択したのかについては、これらは受験者数の多い主要科目だからである。英語以外の外国語など、中間発表の時点で受験者数が2,000人に満

たない12の少人数科目は除いた。

表2 分析に用いる19科目

教科	科目
国語	国語
地歴	世界史B, 日本史B, 地理B
公民	現代社会, 倫理, 政治経済, 倫理政治経済
数学	数学1A, 数学2B
理科①	物理基礎, 化学基礎, 生物基礎, 地学基礎
理科②	物理, 化学, 生物
外国語	英語R, 英語L

したがって、分析対象は、中間集計221,659人のうち、19科目のどれか1科目以上を受験した者で221,497人であった。つまり、データのサイズは、221,497(人)×19(科目)である。ただし、1人当たりの平均受験科目数は5.65科目(SDは2.32)であり、68.9%のデータは欠測している。

### 2.2 モデル

FIMLを適用するにあたり、2つの仮定を必要とする。1つはモデル、もう1つは欠測メカニズムである。本節ではモデルについて説明する。本研究では、多変量(19変量)正規分布を仮定する。したがって、多変量正規分布における平均ベクトルと共分散行列(SDと相関行列)が母数である。多変量正規分布の妥当性については、第4.1節で議論する。

### 2.3 欠測メカニズム

FIMLを適用する上で必要な2つ目の仮定である欠測メカニズム(星野, 2009; 高井・星野・野間, 2016)について本節で説明する。欠測メカニズムとは、欠測データの起こり方について分類したものであり、それらは完全ランダム欠測(missing completely at random, MCAR)、ランダム欠測(missing at random, MAR)、非ランダム欠測(missing not at random, MNAR)の3タイプである。

MCARは、欠測がどこで起こるのか、あたかもサイコロで決めたかのように(得点とは無関係に)、完全にランダムに起こる状況である。病気や忌引き、災害を理由に、ある科目の受験を取りやめたならば欠測となり、MCARに該当するであろう。

MARは、ある科目の得点が観測か欠測かに関する確率が、観測されている得点に依存している場合である。一般に、共通テストは学力が高いほど多科目受験型になる傾向がある。学力が低いほど少数科目受験型となる傾向がある。共通テストの一因子性は高く、実

際に本データを固有値分解したときの第1固有値の寄与率は64.2%である<sup>4)</sup>。したがって、ある科目が欠測するかどうかは、他の科目（特に、英数国などの主要科目）の得点からある程度推測できる。すなわち、観測された得点が低いほど、全体的に少数科目型となって欠測しやすくなる。完全にMARが成立するとは考えにくいですが、部分的に成立すると考え、本研究では、欠測メカニズムにMARを仮定する。FIMLは、MARのときに母数を偏りなく推定する方法である。

MNARは、欠測されている得点自体が原因で、欠測が生じた場合である。例えば、状況としては少し考えにくいですが、学力が高い受験生がいてマークシートを桁ずれ解答していたとする。受験終了際に桁ずれに気づき、みじめな結果を残すくらいならば、と解答用紙を持って受験会場から去ったならば<sup>5)</sup>、これはMNARであろう（MARではないだろう）。解答用紙が残っていないので欠測であるし、学力が高いのに欠測しているので観測データから当該科目の得点（の低さ）を推測できないからである。

本研究では、ひとまずMARを仮定する。また、MARを仮定することの妥当性については、第4.2節で議論する。

## 2.4 FIML

FIMLは、欠測パターンごとに尤度を構築し、尤度を最大化する母数を得る手法である。まず、多変量正規分布の密度関数を $p(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma})$ とする。ここで、 $\mathbf{x}$ は、確率変数ベクトル、 $\boldsymbol{\mu}$ と $\boldsymbol{\Sigma}$ は、多変量正規分布の母数である平均ベクトルと共分散行列である。

いま、欠測パターン数を $G$ とし（本データでは $G=1842$ ）、受験者 $i$ の欠測パターンが $g$ 番目であれば1、そうでなければ0となる欠測パターン指示子

$$m_{ig} = \begin{cases} 1 & \text{受験者 } i \text{ の欠測パターンが } g \text{ 番目} \\ 0 & \text{それ以外} \end{cases}$$

を考える。そして、データ全体の尤度を

$$p(\mathbf{X}|\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \prod_{i=1}^N \prod_{g=1}^G p(\mathbf{S}_g \mathbf{x}_i | \mathbf{S}_g \boldsymbol{\mu}, \mathbf{S}_g \boldsymbol{\Sigma} \mathbf{S}_g')^{m_{ig}} \quad (1)$$

と構成する。ここで、 $N(=221,497)$ は受験者数、 $x_i$ は受験者 $i$ の得点ベクトル、 $\mathbf{X} = \{\mathbf{x}_i\}$  ( $N \times 19$ )はデータ行列である。

また、 $\mathbf{S}_g$ は、欠測パターン $g$ に対応した得点や母数を取り出す選択行列である。例えば、受験者 $i$ が国語・日本史B・英語R・英語Lの4科目のみを受験したと

すると、受験者 $i$ の得点ベクトルは、

$$\mathbf{x}_i = [x_{i1} \ x_{i2}^{(0)} \ x_{i3} \ x_{i4}^{(0)} \ x_{i5}^{(0)} \ x_{i6}^{(0)} \ x_{i7}^{(0)} \ x_{i8}^{(0)} \ x_{i9}^{(0)}$$

$$x_{i10}^{(0)} \ x_{i11}^{(0)} \ x_{i12}^{(0)} \ x_{i13}^{(0)} \ x_{i14}^{(0)} \ x_{i15}^{(0)} \ x_{i16}^{(0)} \ x_{i17}^{(0)} \ x_{i18} \ x_{i19}]'$$

となる。下付き添え字の1～19は、表2の国語～英語Lまでの最初行左から最終行右までの科目順に対応している。また、上付き添え字の(0)は当該の科目が欠測していることを表している。このとき、この欠測パターンに対応する選択行列は、

$$\mathbf{S}_g = \begin{bmatrix} 10000000000000000000 \\ 00100000000000000000 \\ 00000000000000000010 \\ 00000000000000000001 \end{bmatrix}$$

となる。この $\mathbf{S}_g$ を用いると、

$$\mathbf{S}_g \boldsymbol{\mu} = [x_{i1} \ x_{i3} \ x_{i18} \ x_{i19}]'$$

となり、観測得点のみを取り出すことができる。同様に、平均ベクトルと共分散行列に対してもこの選択行列を適用することで、

$$\mathbf{S}_g \boldsymbol{\mu} = [\mu_1 \ \mu_2 \ \mu_3 \ \mu_4]'$$

$$\mathbf{S}_g \boldsymbol{\Sigma} \mathbf{S}_g' = \begin{bmatrix} \sigma_1^2 & & & \text{sym} \\ \sigma_{3,1} & \sigma_3^2 & & \\ \sigma_{18,1} & \sigma_{18,3} & \sigma_{18}^2 & \\ \sigma_{19,1} & \sigma_{19,3} & \sigma_{19,18} & \sigma_{19}^2 \end{bmatrix}$$

のように、観測得点に対応する平均と共分散のみを取り出すことができる。

このように構成されている(1)式の尤度は、欠測パターン数だけグループを用意して、全ての母数にグループ間等値の制約を入れた多母集団分析と考えることが可能である。そして、(1)式の尤度を最大化して母数を推定する方法がFIMLである。最大化の方法は、Newton-Raphson法や、Fisherのスコアリング法など、古典的な方法でよい。本研究では後者を用いた。

FIMLはMARのもとで不偏な推定量であるため、仮に欠測があっても母集団の母数（ここでは、平均と共分散行列）を推定することができる。したがって、語弊を恐れずに言えば、「仮に全員が19科目を選択受験したら、そのときの平均ベクトルと共分散行列がどうなるか」ということを2つの仮定の下で推測したものと言える。

### 3 結果

多変量正規性と MAR のもとで、FIML を用いて 19 変量正規分布の平均ベクトルと共分散行列を推定した。このうち、理科②の得点調整に関わる物化生の平均のみを表 2 に示す。

表 2 FIML による理科②物化生の平均・SD

科目	平均	SE (平均)	SD
物理	55.18	0.070	23.60
化学	42.76	0.061	20.95
生物	41.45	0.076	15.77

多変量正規性と MAR の 2 つの仮定の下で、「仮に全員が受けたら」物化生間の最大平均点差は 13.73 点になると分かった。つまり、見かけの平均点差 23.92 点 (表 1) のうち、10.19 点は選択者集団の学力差であり、残る 13.73 点が科目間難易差であると示唆される。

得点調整の真意は、科目間難易差について調整するものであろう。そして、実受験者に対する得点調整の処置として、物化生の最大平均点差の約 24 点は、化学と生物選択者に対して加点することで約 15 点まで縮小した<sup>6)</sup>。すなわち約 9 点を詰めたことになる。科目間難易差は 14 点くらいであると見積もられているので、64% (9/14) くらいは調整によって難易差が軽減されたと思うことができよう。しかし、これはあくまでもモデルに基づく試算の 1 つにすぎないので、本分析結果によって、現実の得点調整を「点差の縮小幅が小さすぎる／大きすぎる」などと単純に評価することはできない。

### 4 結論

結果において、見かけの平均点差 23.92 点のうち、学力差で説明できる部分は 10.19 点であると述べた。しかし、結果の解釈には、注意が必要である。これは、①モデルが多変量正規分布であること、②欠測メカニズムが MAR であること、という 2 つの仮定に依拠した結果ということである。そこで、これら 2 つの仮定が、どれくらい妥当であるかについて議論しておく必要がある。

#### 4.1 多変量正規性の検討

まず、①多変量正規性の仮定である。多変量 (19 変量) 正規分布は、個々の周辺分布も 1 変量正規分布に従うので、各科目の得点分布について Kolmogorov-Smirnov (KS) 検定を行ったところ、19 科目の全て

について有意になった。すなわち、正規分布から逸脱していると判断された。とはいえ、KS 検定は、標本サイズ (受験者数) が大きいとき、どんなに正規分布に近似していても有意になってしまう。そこで、正規性の視覚的な確認のため、図 2 に物化生の 3 科目のみの P-P プロットを示した。




図 2 物化生の P-P プロット

P-P プロットは、プロットが対角線に沿って配置されていれば、分布が正規分布に近いことを意味している。図より、特に、物理は正規分布から大きく逸脱していることが分かる。1 科目でも 1 変量正規分布に従わない科目が存在することは、全体として 19 科目の得点分布が多変量正規分布に従っていないことを示す証左である。しかし、統計分布を仮定するとき、多変量正規分布以外に扱いやすい多変量分布がないのも事実であり、今後の検討が必要である。

#### 4.2 MAR の検討

実際は、中間発表データの約 22 万人の受験者が、さまざまな理由で欠測を起こすと考えられる。約 421 万 (22 万人 × 19 変量) のデータのうち、約 296 万 (約 7 割) のデータは欠測している。その中には、MCAR によって起こった欠測もあるだろうし、MAR や MNAR で起こった欠測もそれぞれあるのが事実であろうが、多くは単純に (A) 出願に必要なから、(B) 選択できないから、ということによる欠測であろう。

(A) については、例えば、理系学部に出願する予定の受験者が理科①を欠測するのは、理系学部の出願

に不要だからである。その代わり、理科②科目が観測されているので、理科①科目の欠測は、理科②科目の得点が観測されていることによって分かる。

また、(B)については、例えば、世界史Bと地理Bの受験者が日本史Bを欠測しているのは、地歴公民教科は2科目までしか受験できないからである。このとき、日本史Bの欠測は、世界史Bと地理Bが観測されたことによって分かる。また、日本史Aと日本史Bのように、同一名称を含む2つの科目を同時に選択できないため、例えば、日本史Bを選択した受験者の日本史Aの得点は欠測となる。したがって、日本史Bの観測によって日本史Aの欠測が分かる。

つまり、(A)と(B)は、構造的に表れる欠測パターンであるが、いずれも欠測するか否かの情報を観測された科目群が保持しているので、これら欠測パターンの欠測メカニズムとしてはMARと見なすことができる。むろん、このような欠測の全てを観測された科目群によって説明できるわけではないが、「部分的にMARが成立する」「MARを仮定しても全外的外れではない」とは言ってよいだろう。

このように、欠測の全てではないが、大部分は、大学入試センターの受験案内が定めるところの科目選択に関する規則（大学入試センター，2022，pp.3-4）が素直に適用されたことによる結果であるから、欠測の相当部分はMARと見なすことができるだろう。また、仮に病気や災害などによる欠測（MCAR）が起きたとしても、FIMLは、MCARのもとでも正しく母数を推定することができる。

#### 4.3 今後の課題と終わりに

全体の欠測のうち、いったいMNARの割合がどれくらいなのか、ということが問題として残っている。定義上、1つでもMNARによって起こった欠測があるならば、データ全体の欠測メカニズムはMNARとなる。そして、約275万の欠測データのうち、MNARによる欠測が1つもないという可能性はないので、共通テストデータ全体の欠測メカニズムはMNARということになる。この点、どのように欠測が起きたかについて、受験生に面接をするなどしてMNARの種類や割合などを調査し、欠測メカニズムとして組み込むことで、さらに精緻な分析を行うことができる可能性がある。今後の課題としたい。

なお、MARかMNARかの検定としてHausman検定（Hausman, 1978）がある。しかし、この検定を実行するためには、まず、欠測データメカニズムをモデリングして一致性を持つ推定量を構築する必要がある

（高井・星野・野間，2016）ため、MNARに関して未調査の現段階では実行不可能である。今後の課題としたい。しかし、仮にできたとしても観測されなかった欠測データがなければ厳密な意味でMARかMNARの判別はできない（松山，2004）。

少なくとも、観測されたデータから平均・SD・相関を求めるという従来の統計資料は、欠測メカニズムがMCARであるという厳しい条件を暗に仮定されていることについて、自覚的であるべきである。本研究によって、従来、暗に仮定されていたMCARをMARに緩和し、従来よりも真の母数に接近した結果を示すことができた。

#### 注

- 1) その他、原因の特定できない様々な細かい要因も混入していると思われるが、本論文では扱わない。
- 2) 本論文の見解は、著者らの個人的見解であり、所属組織の公式見解ではない。
- 3) 分析に投入する受験者数が一定数いる科目は、中間集計データの平均点は、最終集計データの平均点と大きくても1点ほどしか違わない。したがって、中間集計データが十分に最終集計データを代表していると思なして分析する。
- 4) ただし、倫理政治経済を除いた18科目の共分散行列を固有値分解したときの結果である。倫理政治経済は、倫理および政治経済と同時受験ができないため、この2科目との共分散は計算できないためである。
- 5) マークシート（解答用紙）の持ち帰りは違反行為である。
- 6) 得点が離散値であり、かつ、同一の得点をとる受験者がいるため、正確に15点差にならない。

#### 謝辞

本研究は、大学入試センター理事長裁量裁量研究「共通テストに対応した得点調整方法と成績提供法の検討」の助成を受けたものである。

#### 参考文献

- Arbuckle, J. L. (1996) Full information estimation in the presence of incomplete data. In G. A. Marcoulides & R. E. Schumacker (Eds.), *Advanced Structural Equation Modeling*. Lawrence Erlbaum Associates, Inc. (pp. 243-277).
- 大学入試センター (2022). 「令和5年度大学入学共通テスト（本試験）の得点調整について」大学入試センター (<https://www.dnc.ac.jp/albums/abm.php?d=34&f=abm00000322.pdf&n=> 令和5年度「受験案内」（一括ダウンロード）.pdf) (2023年1月23日).

- 大学入試センター (2023a). 「令和5年度大学入学共通テスト (本試験) の得点調整について」大学入試センター (<https://www.dnc.ac.jp/news/albums/abm.php?d=230&f=abm00003367.pdf&n=> 【プレス発表】 令和5年度大学入学共通テスト (本試験) の得点調整について.pdf) (2023年1月23日).
- 大学入試センター (2023b). 「令和5年度大学入学共通テスト (本試験) 平均点等一覧 (中間集計)」大学入試センター (<https://www.dnc.ac.jp/news/albums/abm.php?d=225&f=abm00003349.pdf&n=> (プレス発表) 令和5年度大学入学共通テスト (本試験) 平均点等一覧 (中間集計).pdf) (2023年1月23日).
- Hausman, J. A. (1978). Specification tests in econometrics. *Econometrica*, **46**, 1251-1271.
- 星野崇宏 (2009). 『調査観察データの統計科学』岩波書店.
- 石岡恒憲 (2011). 「Random Forest を用いた欠測データの補完に基づく大学入試センター試験科目間得点差」『応用統計学』 **40**, 193-209.
- 前川真一 (2020). 成績データから見たセンター試験. 大学入試センター (編) センター試験」をふり返る, 164-187. (<https://www.dnc.ac.jp/albums/abm.php?f=abm00040328.pdf&n=> 「センター試験」をふり返る.pdf) (2021年8月8日).
- 松山裕 (2004). 「経時観察研究における欠測データの解析」『計量生物学』 **25**, 89-116.
- 大津起夫 (2011). 大学入試センター試験における科目別得点の非線形因子分析による比較. 大学入試センター研究紀要, **40**, 1-23.
- Rubin, D. B. (1976). Inference and missing data. *Biometrika*, **63**, 581-592.
- 荘島宏二郎・橋本貴充・宮澤芳光・石岡恒憲・前川真一 (2022). 「傾向スコアを用いた令和3年度共通テスト公民科目間差の試算—国語・英語リーディング・英語リスニングを共変量に用いた場合—」『大学入試研究ジャーナル』 **32**, 122-129.
- 荘島宏二郎・石塚智一・橋本貴充 (2007). 「多重指標モニタリングによる得点調整手続きの試案」『大学入試センター研究紀要』 **36**, 53-70.
- Shojima, K., Otsu, T., Mayekawa, S., Taguri, M., & Yanai, H. (2007). Factor structure of the National Center Test 2005 by the full-information pseudo-ML method. *Behaviormetrika*, **34**, 131-156.
- 荘島宏二郎・大津起夫・田栗正章 (2006). 「自己組織化マップと完全情報最尤法から見た平成17年度センター試験の教科学力構造」『日本テスト学会誌』 **2**, 75-89.
- 高井啓二・星野崇宏・野間久史 (2016). 『欠測データの統計科学』岩波書店.
- 吉村宰・荘島宏二郎 (2004). 「本追モニター調査の結果を利用した傾向スコア加重法による本追試験間の難易度比較」『大学入試センター研究紀要』 **33**, 19-28.