

グループ別レーティングによる評価の妥当性

花岡 桃香† 三浦 孝夫†

法政大学理工学部創生科学科

東京都小金井市梶野町 3-7-2

1. 前書き

レーティングは集合の要素に数値指標を与える手法であり、スポーツ、政治、商品、ウェブページなどで利用されている。中でも 1952 年に考案された BradleyTerry モデルは各要素の勝率を強さの比として要素の強さを求めている。このモデルはレイトを与えたい対象同士の一対比較データをすべて利用する想定で作られている統計手法である。このためすべてのデータを参照できないような膨大な情報の処理に使用することができない。これに対してサンプリングはデータの一部を抽出して母集団を推定する手法であり、中でも層化抽出はその精度向上を見込むことができる。このことから、レーティングで用いるデータに同様の操作を行うことで、一部のデータから精度の高いレーティングを行うことができるのではないかと考えた。

本研究では層化抽出の考え方をを用いて、データを階層に分けて抽出することで階層ごとのレーティング結果を求め、各層の結果を合算して最終的な評価とする層化レーティングを提案する。すべてのデータを使用したレーティングの結果と層化レーティングの結果を Kendall の順位相関係数で比較することで、層化レーティングがデータ全体の特徴を正しく表現しているか評価する。

2. 層化抽出

層化抽出はサンプリング手法の 1 つであり、大きさ N の母集団 U を層と呼ばれる部分母集団 U_1, \dots, U_L に分割し、各層から独立に確立抽出を行うものである。各層のサンプル数には複数の配分決定方法がある。比例配分は層のサイズに比例してサンプル数を算出する方法である。比例配分による層化抽出では各層ごとの平均がばらつくほど単純無作為抽出に比べて精度の高い抽出を行うことができる。一方、ネイマン配分は層のサイズと各層の標準偏差に比例してサンプル数を算出する。ネイマン配分による層化抽出では各層ごとの分散がばらつくほど比例配分による層化抽出に比べて精度の高い抽出を行うことができる。

3. BradleyTerry モデル

エージェント $1, 2, \dots, m$ が存在し、それぞれの強さを $V = \{V(1), V(2), \dots, V(m)\}$ を求めるものとする。BT モデルでは $V(a)/V(b) = n(ab)/n(ba)$ を満たす V を求める。ただし、すべての対戦カードの間でこの比が成り立つことはまずない。最尤推定で最もこの比が成り立つ式を求めると次になる。

$$V(a) = \frac{W(a)}{\sum_{b \neq a} (n(ab) + n(ba)) / (V(a) + V(b))}$$

$$W(a) = \sum_{b=1..m} n(ab)$$

層化レーティングでは階層ごとに求めた結果から 1 つの総合的な評価を求める。しかし BT モデルは複数の評価項目を合算することが想定されているモデルではない。評価項目としての重要度に差がある場合単純な合計や平均では正確な総合評価をすることができない。この問題を解消するために、各層に評価項目の重要度に応じた重みをつけることにする。

4. Saaty 行列

Saaty 行列は階層型意思決定モデル (Analytic Hierarchy Process) の手法の一つで、評価項目の重み w を算出することができる。 $n(ab)/n(ba)$ が評価項目 b に対する評価項目 a の重要度の比であると考えられる。この前提から m 個の評価項目の一対比較の行列を作成する。この行列の、固有値が m となるような固有ベクトル w を評価項目の重みであるとする。

5. 提案手法

これらの手法を用いて層化レーティングの手順を説明する。ここではあるケーキ店の 3 つのケーキの人気を調査するため利用客の中から 10 人を抽出してアンケートを行った場合を考える。

まず評価対象のデータを複数の階層に分類する。今回は男性と女性という 2 つの層に分けて考える。

次に階層内でデータの抽出を行い、抽出したデータを用いて層ごとのレイトを算出する。これにより男性に人気のケーキと女性に人気のケーキといった 2 つのレイトが出来上がる。

表 1 男女別人気ケーキのレイト

| | 男性 | 女性 |
|-----|-----|-----|
| 抹茶 | 0.3 | 0.6 |
| チョコ | 0.5 | 0.1 |
| チーズ | 0.2 | 0.3 |

次に、Saaty 行列を用いて各層の重みを算出する。このケーキ店で女性が男性の2倍ケーキを買っていくというデータがある。これをそれぞれの層の重要度の比であると考えて行列を作成すると次のようになる。

$$\begin{pmatrix} 1 & 2 \\ 1/2 & 1 \end{pmatrix}$$

この行列のうち固有値が2となる固有ベクトルをもとめると、男性客の重みは0.45、女性客の重みは0.90となった。

このことから、最後に各層の結果に重みをつけて合算する。

抹茶： $0.30 \times 0.45 + 0.60 \times 0.90 = 0.68$

チョコ： $0.50 \times 0.45 + 0.10 \times 0.90 = 0.32$

チーズ： $0.20 \times 0.45 + 0.30 \times 0.90 = 0.36$

このようにして、3つのケーキの総合的なレイトを求めることができる。

6. 実験

本研究では都道府県庁所在地 47 地点における、2019年1月1日から12月31日までの365日間の日照時間を対象とする。単純無作為抽出、比例配分での層化抽出、ネイマン配分での層化抽出でそれぞれ120日分を抽出し、レイティングを行う。層化抽出の際は月ごとに12の階層に分割する。月の重みを算出する際には、その月の一日の平均日照時間（太陽が地平線より上にある時間）を用いる。抽出方法毎の結果と365日すべてのデータから求めたレイティングとのケンドールの順位相関係数を求め、各手法によって求められたレイトが年間の日照時間の順位付けにふさわしいか判断する。

各月の日数と日照時間の分散から、比例配分とネイマン配分での月ごとのサンプル数は次のようになる。

表2 各月のサンプル数

| | 日数 | 日照時間の標準偏差 | 比例配分 | ネイマン配分 |
|-----|----|-----------|------|--------|
| 1月 | 31 | 1.84 | 10 | 10 |
| 2月 | 28 | 1.88 | 10 | 9 |
| 3月 | 31 | 1.95 | 10 | 10 |
| 4月 | 30 | 2.09 | 10 | 10 |
| 5月 | 31 | 2.15 | 10 | 11 |
| 6月 | 30 | 2.14 | 10 | 11 |
| 7月 | 31 | 1.99 | 10 | 10 |
| 8月 | 31 | 2.07 | 10 | 11 |
| 9月 | 30 | 1.95 | 10 | 10 |
| 10月 | 31 | 1.96 | 10 | 10 |
| 11月 | 30 | 1.88 | 10 | 9 |
| 12月 | 31 | 1.82 | 10 | 9 |

この配分を用いて、比例配分とネイマン配分での層化抽出を行い、レイティングを行った。次に、月の平均日照時間から月の重みが次のよ

うに求められる。

表3 月の平均日照時間と重み

| | 平均日照時間 | 月の重み |
|-----|--------|-------|
| 1月 | 10.11 | 0.237 |
| 2月 | 10.92 | 0.256 |
| 3月 | 11.97 | 0.281 |
| 4月 | 13.07 | 0.307 |
| 5月 | 14 | 0.329 |
| 6月 | 14.48 | 0.34 |
| 7月 | 14.27 | 0.335 |
| 8月 | 13.47 | 0.316 |
| 9月 | 12.42 | 0.292 |
| 10月 | 11.33 | 0.266 |
| 11月 | 10.37 | 0.244 |
| 12月 | 9.87 | 0.232 |

各月のレイトと月の重みをかけ合わせて、最終的な層化レイティングでのレイトを求める。

365日すべてのデータを用いて求めたレイトと今回のレイトとのケンドールの順位相関係数は、単純抽出で0.56、比例配分で0.66、ネイマン配分で0.80となる。この結果から、サンプリングを取り入れてレイティングを行うとき、層化レイティングを用いることで本来のレイトとの相関関係は強くなることが確認できる。特にネイマン配分を使用した場合には強い相関がみられる。

7. 結論

データの一部を抜き出してBTモデルでのレイティングを行うとき、単純なサンプリングを用いた場合とネイマン配分を用いた層化レイティングを行った場合とでは、元データとの順位相関係数が0.56から0.80に上昇した。

本実験ではレイトの合算の際にSaaty行列を用いた重みという考え方を利用したが、最適な手法であるとは言い切れない。他の手法についても同様に実験を行い、より精度の高い層化レイティングを検討したい。

参考文献

[1] ランキング手法の関連性の評価, 電子情報通信学会総合大会 学生ポスターセッション, 広島大学, 東広島(Virtual Online) 共著(花岡 桃香, 三浦 孝夫), 平成32年(2020) 3月