

最高桁の数

～ ベンフォード則と不正経理の捜査 ～

「数学で身に付ける柔らかい思考力」 ダイヤモンド社

ロブ・イースタウェイ／ジェレミー・ウィンダム 著 水谷淳 訳 より

1. 新聞に載っている数字を調べよう

今日の新聞の第1面を見るとたくさんの数字が載っている。「16兆円の景気対策・・・」「10月入学を採用・・・」「84年以降・・・」「30万人余りと米国へ・・・」。

これらの数字はお互いに無関係であって、ほぼランダムにとってきた数字とと思ってよい。本によると、実は、これらの数字はある傾向の分布をするというのだ。たとえば、1から始まる数字は、どれくらいあるだろうか。2から始まる数字はどうだろう。3から始まる数は？普通、1から9まで同じくらいの割合だと思うが、そうではないらしい。

実は、ランダムに取ってきた数が1で始まる確率は、他の数字に比べてずっと高く、約半分の数が1か2で始まるのだ。そして、9から始まる数は稀なのだ。

2. ベンフォード則

新聞に載っているたくさんの数字の統計をとると、次の表に近い結果を得られる。

数	1	2	3	4	5	6	7	8	9
割合 (%)	30	18	12	10	8	7	6	5	4



Frank Albert. Benford, Jr. (1883-1948)

この分布は、1939年、ゼネラル・エレクトリック社の技術者フランク・ベンフォードが発見したもので、都市の人口、株価、川の長さ、スポーツの成績など様々な数に当てはまる。サンプル数が十分に多く、値の範囲が制限されていないものであれば、どのようなものにも当てはまる。この分布に従うことを発見者の名をとって、**ベンフォード則**に従うという。(値の範囲が制限されるもの、例えば、電話番号は桁数が限られておりベンフォード則には従わない。)

3. ベンフォード則と不正経理の捜査

ベンフォード則に纏わる面白い話題がある。1990年代初め、会計学校講師のマーク・ニグリニは、学生たちに企業収支のデータについて、あることを調べるように課題を出した。それは、「企業収支の各数値の最高桁の数字がベンフォード則に従った分布を示すかどうか確かめよ」というものだった。

ある学生が親戚の経営する金物屋の帳簿を調べたところ、その数字の分布はベンフォード則の分布とは全く違うものになった。それは、1から始まる数値はベンフォード則によれば30%のはずなのに、この帳簿では93%もあった。そして、残りはすべて8か9で始まる数値だった。つまり、この帳簿に何かおかしいところがあるということを示す結果となってしまったのだ。これをきっかけに、多くの会計士が不正経理を発見する方法としてベンフォード則を採用するようになったそうである。念のため、私の知る大学の会計の先生にこの話題について尋ねたところ「寡聞にして存じ上げません」ということだったので、日本では、それほどポピュラーではないのかもしれない。

4. ベンフォード則が成り立つ理由


ベンフォード則の厳密な証明は難しいらしいので、ここでは感覚的に説明する。1桁の数1～4が書いてある4枚のカードから1のカードを引く確率は0.25であるが、カードの枚数を増やしていくと1のカードを引く確率は下がり、1～9ではその確率は $1 \div 9 = 0.11$ まで下がる。ところが、1～10になると、1から始まるカードは1と10の2枚になり、それらを引く確率は $2 \div 10 = 0.2$ へと跳ね上がる。さらに、カードが11, 12, 13, ...と増えていくと、その確率は上がっていき19枚のとき、 $11 \div 19 = 0.58$ にまでなる。

	1～4	～5	～6	～7	～8	～9	～10	～11	～12
1から始まる数の個数	I	I	I	I	I	I	2	3	4
1から始まる数の割合	0.25	0.20	0.17	0.14	0.13	0.11	0.20	0.27	0.33

～13	～14	～15	～16	～17	～18	～19	～20	～21	～22	～23
5	6	7	8	9	10	11	11	11	11	11
0.38	0.43	0.47	0.50	0.53	0.56	0.58	0.55	0.52	0.50	0.48

しかし、その先10枚、20枚と増やしていくと確率はまた下がり99枚のとき、1から始まるカードを引く確率は $11 \div 99 = 0.11$ となる。そして、100枚以上になると確率は再び上がり、199枚になると1から始まるカードを引く確率は $111 \div 199 = 0.56$ となる。この確率をグラフにしてみると以下のようなになる。

1で始まる確率



カードの枚数を増やしていくと、確率は0.11と0.58の間を上下し続け、平均すると0.3くらいになる。

実は、この値はベンフォード則によって予測できて、数字Nから始まる番号のカードを引く確率は、正確には以下の式で求められる。

$$\log_{10}(N+1) - \log_{10} N$$

たとえば、 $N=1$ とすると、 $\log_{10} 2 - \log_{10} 1 = \log_{10} 2 = 0.301$ となる。


5. ポアンカレのルーレット定理による説明

10倍するごとに1桁上がる構造を円周で考えよう。今、10倍すると1周、さらに10倍すると2周という対応を考える。たとえば、1からスタートするならば、1は0周、10倍して10は1周、さらに10倍して100は2周、という具合だ。すると、1や10や100は、対数関数 $\log_{10} x$ で周回数と対応させることができ、 $\log_{10} 1 = 0$ (周)、 $\log_{10} 10 = 1$ (周)、 $\log_{10} 100 = 2$ (周)となる。そして、2～9の1桁の数は、0周から1周の間にあることになり、それらが何周に相当するかは、次のように求められる。

$$\log_{10} 2 = 0.301 \text{ (周)}, \log_{10} 3 = 0.477 \text{ (周)}, \log_{10} 4 = 0.602 \text{ (周)}, \log_{10} 5 = 0.699 \text{ (周)},$$

$$\log_{10} 6 = 0.778 \text{ (周)}, \log_{10} 7 = 0.845 \text{ (周)}, \log_{10} 8 = 0.903 \text{ (周)}, \log_{10} 9 = 0.954 \text{ (周)}$$

すなわち、2は0.30周、3は0.48周、4は0.60周、・・・、9は0.95周といった具合である。



ベンフォード則では、最高桁の数だけに注目しているので、それが何桁の数であるかは無視することになる。たとえば、284,572,341 という数は、 2.84572341×10^8 と表せるから、8周を通り過ぎ、更に $\log_{10} 2 = 0.301$ (周) よりもう少し通り過ぎたところにあるが、 $\log_{10} 3 = 0.477$ (周) よりは手前にあるということになる。このことは、最高桁が2の数は、それが何桁の数であっても、0.30周から0.48周の間のどこかにあることを意味している。したがって、無作為に取ってきた数の最高桁が2である確率は、 $\log_{10} 3 - \log_{10} 2 = 0.48 - 0.30 = 0.18$ という計算になる。