

相関係数の求め方(標準偏差と分散の求め方を含む)

x 軸のデータと y 軸のデータに関連性があるかの判定には、相関係数を用いるのが一般的。

相関係数と言えば、一般的には「ピアソンの積率相関係数」ということらしい。

相関係数 r は次の式で表される。

$$\text{相関係数} = \frac{\text{共分散}}{\sqrt{x\text{軸の分散} \times y\text{軸の分散}}}$$

x 軸データを $x_i (i=1 \rightarrow n)$ 、その平均を \bar{x} とすると分散は次の式で表される。

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

不偏分散とか言うのが正しいらしいが、 n で割るか $n-1$ で割るかはいろいろある模様。

但し、実は(後述するが)相関係数を求めるのには影響がない。

y 軸についての分散も同様。共分散は、次の式となる。

$$\text{共分散} = \frac{\sum_{i=1}^n (x_i - \bar{x}) \times (y_i - \bar{y})}{n-1}$$

尚、標準偏差の式は次の通り。

$$\text{標準偏差} = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$$

見ての通り分散の平方根となっているので、標準偏差を求める過程で分散も求められる。

寧ろ、分散を元に標準偏差を求めていると言うべきか。

標準偏差については、お馴染みだと思うので詳細は省略。

ここまでで、相関係数(と標準偏差)を求める手段は揃った。実装に入る前に、式を変形してみる。

分散を求める式をよく見ると、平均値との差を(2乗してから)集計するので集計前に平均値が必要になる。

平均値自体は全データにアクセスしないと得られないので、都合2回アクセスする必要ができて都合が悪い。

しかし、次のように変形することができる。

その理屈を説明できるほど判っていないのが難だが……

便宜上、ついでに平均を使って書き直してある。

$$\text{分散} = \frac{\sum (x_i \times x_i) - \frac{\sum x_i \times \sum x_i}{n}}{n-1} = \frac{\sum (x_i \times x_i) - \bar{x} \times \sum x_i}{n-1}$$

また、共分散も同じように変形できる。

$$\text{共分散} = \frac{\sum (x_i \times y_i) - \frac{\sum x_i \times \sum y_i}{n}}{n-1} = \frac{\sum (x_i \times y_i) - \bar{x} \times \sum y_i}{n-1}$$

すると、当然標準偏差はこうなる。

$$\text{標準偏差} = \sqrt{\frac{\sum (x_i \times x_i) - \frac{\sum x_i \times \sum x_i}{n}}{n-1}} = \sqrt{\frac{\sum (x_i \times x_i) - \bar{x} \times \sum x_i}{n-1}}$$

これらの式は事前に平均値を求めておく必要がないので、データには一回アクセスすれば済む。

つまり、データを読み捨てるケースでも使えると言う次第。

実はこの方式、関数電卓の標準偏差の機能そのものだったり。

データエントリー時に、総計 ($\sum x_i$) と平方和 ($\sum x_i^2$) と件数 (n) を更新するだけで済むので。

ここでやっと本題の相関係数の式に戻って。

$$\text{相関係数} = \frac{\text{共分散}}{\sqrt{x\text{軸の分散} \times y\text{軸の分散}}}$$

$$r = \frac{\frac{\sum (x_i \times y_i) - \bar{x} \times \sum y_i}{n-1}}{\sqrt{\frac{\sum (x_i \times x_i) - \bar{x} \times \sum x_i}{n-1} \times \frac{\sum (y_i \times y_i) - \bar{y} \times \sum y_i}{n-1}}}$$

分母に (n - 1) を掛ければすっきりする。また、これが分散の分母が n でも n-1 でも構わない理由になる。

$$r = \frac{\sum (x_i \times y_i) - \bar{x} \times \sum y_i}{\sqrt{(\sum (x_i \times x_i) - \bar{x} \times \sum x_i) \times (\sum (y_i \times y_i) - \bar{y} \times \sum y_i)}}$$

勿論、この式でも標準偏差と同様に 1 パスアクセスで計算できる。

計算手順を纏めると、次のようになる。

```
while データがある {
    Σ x = Σ x + xi
    Σ y = Σ y + yi
    Σ xx = Σ xx + xi * xi
    Σ yy = Σ yy + yi * yi
    Σ xy = Σ xy + xi * yi
    n = n + 1
}
xBar = Σ x / n // x 軸平均
yBar = Σ y / n // y 軸平均
sxx = Σ xx - xBar * Σ x
syy = Σ yy - yBar * Σ y
sxy = Σ xy - xBar * Σ y
xstdev = √(sxx / (n - 1)) // x 軸標準偏差
ystdev = √(syy / (n - 1)) // y 軸標準偏差
r = sxy / √(sxx * syy) // 相関係数
```

最後に、相関の強さについてまとめておく。

1.0～0.7	強い正の相関がある
0.7～0.4	中程度の正の相関がある
0.4～0.2	弱い正の相関がある
0.2～-0.2	ほとんど相関がない
-0.2～-0.4	弱い負の相関がある
-0.4～-0.7	中程度の負の相関がある
-0.7～-1.0	強い負の相関がある