健康統計学 第5回

今回は、相関と回帰（テキスト33〜44ページ）について学習します。

テキスト

- 『やさしい保健統計学 改訂第5版』縣 俊彦著（南江堂）

今回の内容

1. 相関
2. 回帰
3. Excelで相関係数と回帰直線を計算
4. Excelで散布図と回帰直線を作成

相関 (correlation)

2種類のデータの間に何らかの関係がある場合、統計学的な関係性がみられるときに、「**相関がある**」や「**相関関係がある**」といいます。

- データの大小に関して、一方の値が変わるにつれて、もう一方の値も変わる
  - 身長と体重
  - 収縮期血圧と拡張期血圧

データの尺度と相関関係

データを大雑把に、量的データ（比例尺度、間隔尺度）と質的データ（順序尺度、名義尺度）に分けるときに、データの尺度によって、相関関係を表す指標は異なります。次の表を参考にしてください。

2つのデータの尺度	相関関係を表す指標
量的データ×量的データ	ピアソンの積率相関係数
順位データ×順位データ	スピアマンの順位相関係数
量的データ×質的データ	相関比
質的データ×質的データ	クラメールの連関（関連）係数

この授業では、よく利用される、ピアソンの積率相関係数とスピアマンの順位相関係数を扱います。

相関係数 (correlation coefficient)

相関の種類

- 線形相関：相関（関係）を示すグラフ（散布図）が1本の直線で近似できる
  - 順相関：相関が正の場合（散布図が右肩あがりの傾向）
  - 逆相関：相関が負の場合（散布図が右肩さがりの傾向）
  - 無相関：相関がない場合（散布図がまばらになっている）
- 非線形相関：相関を示すグラフが指数関数や2次・3次関数のように曲線状になる

偏差積和

- 偏差積和（偏差の積の総和）S_{xy} とは、偏差（各データと平均の差）の積の総和である。

$$
\begin{aligned}
S_{xy} &= \sum_{i=1}^{n} d_x d_y \\
&= \sum_{i=1}^{n} (x_i - \bar{x})(y_i - \bar{y})
\end{aligned}
$$

  - 標本数: n
  - 偏差: d_x , d_y
- 偏差の積とデータの分布は次のようなイメージになる

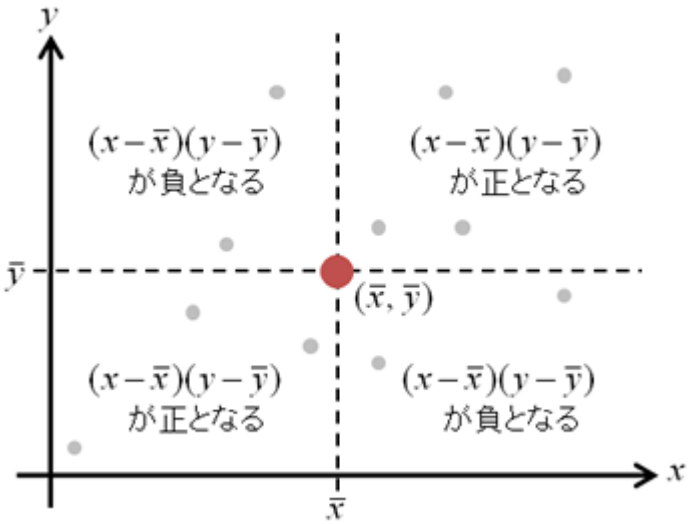

相関係数（ピアソンの積率相関係数）

- 相関係数（ピアソン(Pearson)の積率相関係数） r は、相関の程度をあらわし、次の値をとる。
  （一般に相関係数といえばコレ）

$$-1 \leq r \leq +1$$

  - 完全相関：相関係数がちょうど±1の場合
  - 無相関：相関係数が0の場合

- 相関係数 r は、次の式で求められる

$$\begin{aligned} r &= \frac{\frac{1}{n}\sum_{i=1}^{n}(x_i-\bar{x})(y_i-\bar{y})}{s_x s_y} \\ &= \frac{\frac{1}{n}S_{xy}}{s_x s_y} \end{aligned}$$

  - 標本数: n
  - 標準偏差: s_x , s_y
  - 偏差積和: S_{xy}

- または、次の式でも求められる（統計量だけから計算できる）

$$\begin{aligned} r &= \frac{1}{s_x s_y}\left(\frac{\sum x_i y_i}{n} - \bar{x}\bar{y}\right) \\ &= \frac{1}{s_x s_y}\left(\frac{T_{xy}}{n} - \bar{x}\bar{y}\right) \end{aligned}$$

  - 積和（2変数の積の合計）：

$$T_{xy} = \sum_{i=1}^{n} x_i y_i$$

共分散（covariance）

- 共分散 s_{xy} は、偏差積和を標本数で割ったもの。

$$
\begin{aligned}
s_{xy} &= \frac{1}{n} S_{xy} \\
&= \frac{1}{n} \sum_{i=1}^{n} (x_i - \bar{x})(y_i - \bar{y}) \\
&= \frac{1}{n} \sum_{i=1}^{n} d_x \cdot d_y
\end{aligned}
$$

- 標本数: n
- 偏差: d_x , d_y

- 共分散 s_{xy} を使うと、相関係数は次のように表せる。

$$
r = \frac{s_{xy}}{s_x s_y}
$$

偏差平方和

- 偏差平方和 S_{xx} または S_{yy} は、偏差の二乗の合計を計算したもの

$$
\begin{aligned}
S_{xx} &= \sum_{i=1}^{n} {d_x}^2 \\
&= \sum_{i=1}^{n} (x_i - \bar{x})^2
\end{aligned}
$$

$$
\begin{aligned}
S_{yy} &= \sum_{i=1}^{n} {d_y}^2 \\
&= \sum_{i=1}^{n} (y_i - \bar{y})^2
\end{aligned}
$$

- x と y についての偏差平方和 S_{xx} と S_{yy} を使うと、相関係数は次のように表せる。

$$
\begin{aligned}
r &= \frac{S_{xy}}{\sqrt{S_{xx} S_{yy}}} \\
&= \frac{\sum_{i=1}^{n} (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n} (x_i - \bar{x})^2 \sum_{i=1}^{n} (y_i - \bar{y})^2}}
\end{aligned}
$$

相関関係と因果関係

相関関係から因果関係を確定するときの注意点

何でもよいから2組のデータの関係性を調べればよいわけではありません。次のような5つの因果関係が認められる場合に、相関関係を調べることが有効になります。

1. 関連の時間性
    - 原因は結果の前にあるか
2. 関連の密接性
    - 原因が結果に密接に関連するか

3. 関連の特異性
    - 原因が結果にどの程度かかわっているか
4. 関連の普遍性
    - 対象や時期、方法などが異なっていても、類似した結果が得られるか
5. 関連の合理性
    - 従来の理論や経験から考えて矛盾がないか

疑似相関（見かけの相関）

直接の相関はないが、**何かある要因が2つの事象と相関している**ために、2つの事象に相関がみられるケースがあります。

このような場合を「**疑似相関**」といいます。つまり、相関関係があるからといって、それが必ずしも因果関係であるとは限らない場合です。

- 「ビアホールでの生ビールの売り上げ数」と「アイスクリーム店のお客の数」
    - 2つの事象には「気温」「天候」などが相関している
- 「進行性の疾患をもつ患者の疾患についての知識」と「その疾患の進行度」
    - 2つの事象には「疾患の内容」「治療期間」などが相関している

相関の程度

相関係数の値から、相関の程度を次のように記述できます。

-1.0≦相関係数r<-0.7	強い負の相関がある
-0.7≦相関係数r<-0.4	かなりな負の相関がある
-0.4≦相関係数r<-0.2	やや負の相関がある
-0.2≦相関係数r≦0.2	ほとんど相関がない
0.2<相関係数r≦0.4	やや正の相関がある
0.4<相関係数r≦0.7	かなりな正の相関がある
0.7<相関係数r≦1	強い正の相関がある

なお、標本数が少ない場合は、母相関係数の推定や検定（後日説明）が必要となります。

順位相関係数（rank correlation coefficient）

相関がない場合や順位に意味がある・順位だけしかわからない場合には、順位データ（データを小さいほうから並べた順位）をもとに、相関を求める方法が有効になります。

- 英語のテストの順位と数学のテストの順位の相関
- 2つの銘柄の株価の相関（経済分野）
- 薬と奇形児発生の相関（医学分野）

また、順位尺度のデータだけでなく、比例・間隔尺度のデータについても何らかの順位を求めることで適用できます。

- スピアマン（Spearman）の順位相関係数 r_s は、相関係数と同様、次の値をとる。

$$-1 \leq r_s \leq +1$$

- 同一順位の場合は、次のように扱う（平均順位）
    - 2位が2つある場合：2位と3位の中間 (2+3)/2=2.5位を順位とする
    - 4位が3つある場合：4位と5位と6位の中間 (4+5+6)/3=5位を順位とする
- 順位相関係数は、次のようにして求められる。

$$r_s = 1 - \frac{6\sum_{i=1}^{n} d_i^2}{n^3 - n}$$

- 標本数: n
- i 番目の順位差: d_i

データ1の順位	データ2の順位	順位差 d	順位差の二乗 d^2
x_1	y_1	$d_1 = x_1 - y_1$	${d_1}^2$
x_2	y_2	$d_2 = x_2 - y_2$	${d_2}^2$
x_3	y_3	$d_3 = x_3 - y_3$	${d_3}^2$
…	…	…	…
x_n	y_n	$d_n = x_n - y_n$	${d_n}^2$
計		0	$\sum_{i=1}^{n} {d_n}^2$

回帰 (regression)

データをもとに、ある変数（**従属変数**または**目的変数**）を別の変数（**独立変数**または**説明変数**）で予測する式を作るための統計的手法を、「**回帰分析**」（regression analysis）といいます。

とくに、独立変数が1つだけの場合を**単回帰分析**といいます。複数の独立変数で1つの従属変数を予測する場合は重回帰分析といいます。

回帰直線 (regression line)

回帰直線

- 散布図の各点 (x_i, y_i) が近くに分布するような直線を回帰直線という。

$$y = ax + b$$

  - 回帰係数（回帰直線の傾き）：a
  - 回帰直線のy切片（x=0 のときのyの値）：b
  - 独立変数（説明変数：予測に使う変数）：x
  - 従属変数（目的変数、基準変数：予測したい変数）：y

- なお、回帰式は必ず $(\bar{x}, \bar{y})$ を通る

最小二乗法（least squares method）

- 観測値（または実測値） y_i と 推定値（または予測値） $\hat{y}_i$ との差（残差 ϵ ）の2乗の和が最小になるような a と b を求める。
  - 次の値が最小となるような、a と b を求める。

$$\sum_{i=1}^{n} (y_i - \hat{y}_i)^2$$

  - 残差の二乗 ϵ^2 を足したものを、残差平方和 S_ϵ という

$$S_\epsilon = \sum \epsilon^2 = \sum_{i=1}^{n} (y_i - \hat{y}_i)^2$$

回帰式の計算

- x を独立変数（横軸）、y を従属変数（縦軸）としたときの回帰式（ y への x からの回帰式）は次のようになる。

$$y = r \cdot \frac{s_y}{s_x} x + \left(\bar{y} - \frac{s_{xy}}{{s_x}^2} \cdot \bar{x} \right)$$

  - なお、回帰式を $y = ax + b$ とすると、 a と b は次のようになる。

$$a = r \cdot \frac{s_y}{s_x} = \frac{s_{xy}}{{s_x}^2}$$
$$b = \bar{y} - \frac{s_{xy}}{{s_x}^2} \cdot \bar{x} = \bar{y} - \bar{x}a$$

  - 相関係数: r
  - 2変数の標準偏差: s_x , s_y
  - 2変数の共分散（偏差積和の平均）

$$s_{xy} = \frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})$$

- 回帰式を変形すると、次のようになる。

$$\begin{aligned} y - \bar{y} &= \frac{s_{xy}}{{s_x}^2}(x - \bar{x}) \\ &= \frac{S_{xy}}{S_{xx}}(x - \bar{x}) \end{aligned}$$

  - 2変数の平均値: $\bar{x}$, $\bar{y}$
  - 2変数の偏差積和: S_{xy}

$$S_{xy} = \sum_{i=1}^{n} d_x \cdot d_y = \sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})$$

  - 偏差平方和: S_{xx}

$$S_{xx} = \sum_{i=1}^{n} {d_x}^2 = \sum_{i=1}^{n}(x_i - \bar{x})^2$$

標準誤差（standard error）

- 予測値と実測値のずれ（予測値 $\hat{y}$ との誤差；残差 ϵ ）について考える

$$\hat{y} = ax_i + b + \epsilon$$

- 残差の標準偏差を、標準誤差 s_ϵ という

$$\begin{aligned} s_\epsilon &= \sqrt{\frac{\sum_{i=1}^{n}(y_i - \hat{y})^2}{n-2}} \\ &= \sqrt{\frac{S_\epsilon}{n-2}} \end{aligned}$$

  - $n-2$ で割っているのは、2つの係数を推定したことによる自由度（後日説明）の修正のため

決定係数（coefficient of determination）

- 相関係数の二乗を決定係数（または寄与率） R^2 という。

$$\begin{aligned} R^2 &= \left(\frac{1}{n}\frac{S_{xy}}{s_x s_y}\right)^2 \\ &= \frac{{S_{xy}}^2}{n^2 \cdot {s_x}^2 {s_y}^2} \\ &= \frac{{S_{xy}}^2}{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2} \\ &= \frac{{S_{xy}}^2}{S_{xx} S_{yy}} \end{aligned}$$

- 偏差平方和と残差平方和を使うと、次のように書くこともできる

$$
\begin{aligned}
R^2 &= \frac{S_{\hat{y}\hat{y}}}{S_{yy}} \\
&= \frac{\sum(\hat{y}_i - \overline{\hat{y}})^2}{\sum(y_i - \overline{y})^2} \\
&= 1 - \frac{S_e}{S_{yy}}
\end{aligned}
$$

- 決定係数は、0から1の値をとる。

$$
0 \leq R^2 \leq 1
$$

- 推定（回帰式）の精度を表す指標である
  - 「従属変数 y の分散の何%を予測値 $\hat{y}$ の分散が説明しているか」を示す
    - 別の言い方をすると、「説明変数が従属変数の何%にあたる部分に影響を与えているか（寄与しているか）」を示す
  - だいたい、0.5以上であれば精度が高いといえる

回帰の概念

- 予測値 $\hat{y}$ と従属変数の平均 $\overline{y}$ との差は、一般に独立変数 x とその平均 $\overline{x}$ との差より小さくなる
  - →予測値と平均の差 $(\hat{y} - \overline{y})$ との差は、独立変数と平均の差 $(x - \overline{x})$ との差より小さくなる
  - →予測値は独立変数に比べて平均に近づく
- 統計学的な現象で、「回帰効果」や「平均への回帰」ともいう
  - （例）1回目の試験の結果が偏っていた（とくに良い、悪いなど）人について、2回目の試験結果を調べると、その平均値は1回目の結果よりも1回目の全体の平均値に近くなる（時間的には逆で考えてもよい）
  - （例）父親と子どもの身長を比較して、とくに身長の高い父親でも、とくに身長の低い父親からでも、子どもたちの身長は父親たちの身長より平均に近くなる
  - （例）とくに身長の高い人たちの父親の身長は、子どもたちの身長よりも平均に近い（全体の身長の分布は、父親たちも子どもたちも同じ）

Excelで相関と回帰を計算

相関を計算

相関係数

- 2つの配列データの相関係数は、**CORREL**関数を利用します。

CORREL（相関係数の値を返す）

- 書式：CORREL(配列1, 配列2, ...)
- 引数：配列1 ... ：データが入力されたセルの範囲
- 引数：配列2 ... ：もう一方のデータが入力されたセルの範囲
- 例：データがA1～A10セルとB1～B10までのセルの数値から、相関関数を計算する

```
=CORREL(A1:A10, B1:B10)
```

- ピアソンの積率相関係数は、**PEARSON**関数を利用します。

PEARSON（ピアソンの積率相関係数 r の値を返す）

- 書式：PEARSON(配列1, 配列2)
- 引数：配列1 ... ：独立変数に対応するセルの範囲
- 引数：配列2 ... ：従属変数に対応するセルの範囲
- 例：独立変数がA1～A10セル、従属変数がB1～B10までのセルの数値から、積率相関関数を計算する

```
=PEARSON(A1:A10, B1:B10)
```

- なお、Excel2004以降は、CORREL関数の結果とPEARSON関数の結果は同じになります。

共分散

- 共分散（2種類のデータ間での標準偏差の積の平均値）は、**COVAR**関数または**COVARIANCE.P**関数を利用します。

COVAR（共分散の値を返す）

- 書式：COVAR(配列1, 配列2)
- 引数：配列1 …：データが入力されたセルの範囲
- 引数：配列2 …：もう一方のデータが入力されたセルの範囲
- 例：データがA1～A10セルとB1～B10までのセルの数値から、共分散を計算する

```
=COVAR(A1:A10，B1:B10)
```

COVARIANCE.P（共分散の値を返す）

- 書式：COVARIANCE.P(配列1, 配列2)
- 引数：配列1 …：データが入力されたセルの範囲
- 引数：配列2 …：もう一方のデータが入力されたセルの範囲
- 例：データがA1～A10セルとB1～B10までのセルの数値から、共分散を計算する

```
=COVAR(A1:A10，B1:B10)
```

偏差平方和

- 偏差平方和（標本の平均値に対する各データの偏差の平方和）は、**DEVSQ**関数を利用します。

DEVSQ（偏差平方和の値を返す）

- 書式：DEVSQ(数値1, 数値2, ...)
- 引数：数値1, 数値2 …：データが入力されたセルの範囲
- 例：データがA1～A10セルのセルの数値から、偏差平方和を計算する

```
=DEVSQ(A1:A10)
```

回帰を計算

回帰直線の傾き

- 既知の y と既知の x のデータから回帰直線の傾きには、**SLOPE**関数を利用します。

SLOPE（回帰直線の傾きを返す）

- 書式：SLOPE(配列1, 配列2)
- 引数：配列1 …：既知の y（従属変数）に対応するセルの範囲
- 引数：配列2 …：既知の x（独立変数）に対応するセルの範囲
- 例：既知の y（従属変数）がA1～A10セル、既知の x（独立変数）がB1～B10までのセルの数値から、回帰直線の傾きを計算する

```
=SLOPE(A1:A10，B1:B10)
```

回帰直線のy切片

- 既知の y と既知の x のデータから (線形) 回帰直線のy切片には、**INTERCEPT**関数を利用します。

INTERCEPT (回帰直線の切片を返す)

- 書式 : INTERCEPT(配列1, 配列2)
- 引数 : 配列1 … :既知の y (従属変数) に対応するセルの範囲
- 引数 : 配列2 … :既知の x (独立変数) に対応するセルの範囲
- 例:既知の y (従属変数) がA1～A10セル、既知の x (独立変数) がB1～B10までのセルの数値から、回帰直線のy切片を計算する

```
=INTERCEPT(A1:A10, B1:B10)
```

決定係数

- 既知の y と既知の x のデータからR^2 (決定係数) を求めるには、**RSQ**関数を利用します。

RSQ (r2の値を返す)

- 書式 : RSQ(配列1, 配列2)
- 引数 : 配列1 … :既知の y (従属変数) に対応するセルの範囲
- 引数 : 配列2 … :既知の x (独立変数) に対応するセルの範囲

```
=RSQ(A1:A10, B1:B10)
```

Excelで散布図と回帰直線を作成

2組のデータの関係性を視覚的に把握するには、「**散布図**」を用います。

また、表計算ソフトのExcelでは、作成した散布図を利用して、「**回帰直線**」（単回帰直線）を描いたり、回帰式を表示することができます。

Excelで散布図の作成

散布図の作成

eラーニングの画面からダウンロードできるExcelのファイルを利用してみます。「【練習】相関と回帰」というシートで作成します。

次のようにして、散布図を作成してみましょう。

1. マウスをドラッグして、B2～C22セルを範囲選択する

	A	B	C
1			最高気
2	データ番号	最高気温 (x)	客数 (y)
3	1	31	38
4	2	26	25
5	3	34	37
6	4	32	31
7	5	33	39
8	6	36	53
9	7	33	41
10	8	32	38
11	9	28	44
12	10	38	58
13	11	30	44
14	12	25	31
15	13	26	41
16	14	21	18
17	15	30	54
18	16	28	42
19	17	23	34
20	18	24	39
21	19	33	49
22	20	31	44

2. 「挿入」タブの「グラフ」グループにある「散布図」ボタンをクリックする
3. メニューから「散布図 (マーカーのみ)」を選択する

4. グラフが作成される

作成できたら、グラフに次の設定をしてください。

1. メニューの「グラフツール」の「デザイン」にある「グラフ要素を追加」を選択する

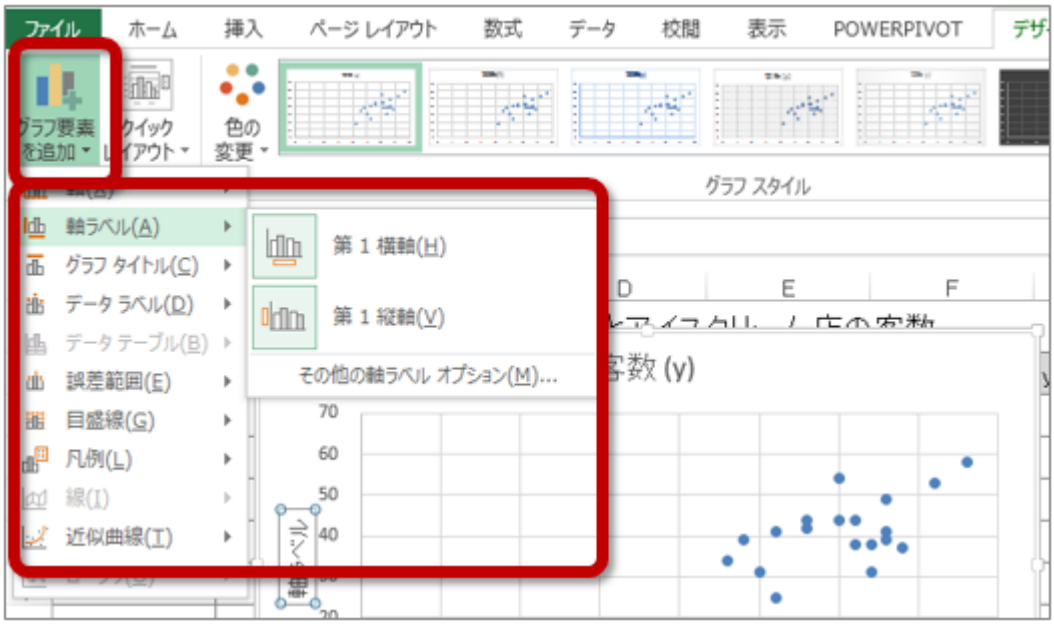

- 縦軸の軸ラベルを追加して、「客数（人）」と設定する
- 横軸の軸ラベルを追加して、「最高気温（℃）」と設定する
- グラフのタイトルを「最高気温とアイスクリーム店の客数」設定する

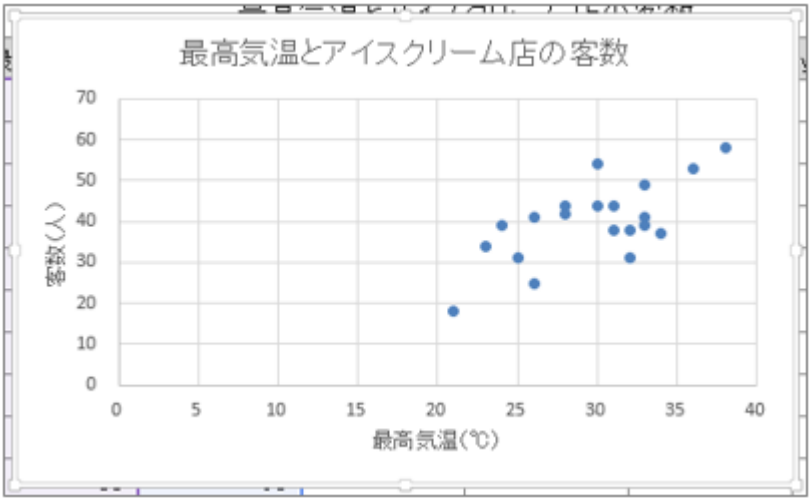

軸の設定

横軸（最高気温）が「0度」から表示されているため、データの分布がグラフの右端に偏ってしまっています。

そこで、横軸の範囲を「**20度～40度**」の範囲に変更してみましょう。

1. グラフの横軸の数字部分を右クリックし、メニューから「横軸の書式設定」を選択する

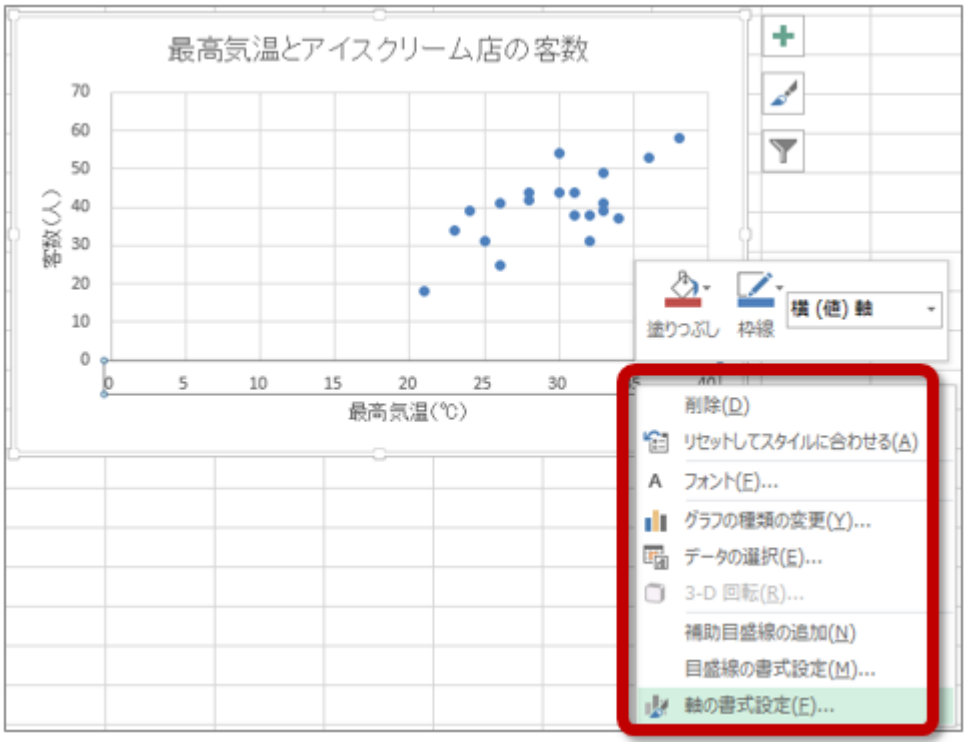

2. 「軸の書式設定」が表示されるので、次のように設定する
    - 「最小値」を「固定」に選択して、入力欄に「20.0」と入力
    - 「最大値」を「固定」に選択して、入力欄に「40.0」と入力
    - 「目盛間隔」を「固定」に選択して、入力欄に「2.0」と入力

3. 「閉じる」をクリックすると、横軸の表示が変更される

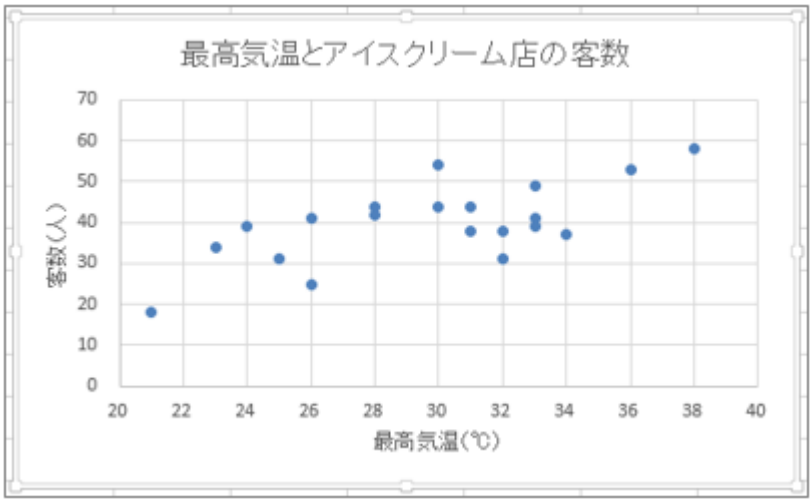

あとは、必要に応じて、縦軸の範囲も設定したり、デザインの変更をすると良いでしょう。

Excelで回帰直線の作成

Excelでは、「近似曲線」という機能で、回帰直線を描くことができます。

1. メニューの「グラフツール」の「レイアウト」にある「近似曲線」→「その他の近似曲線オプション」を選択する

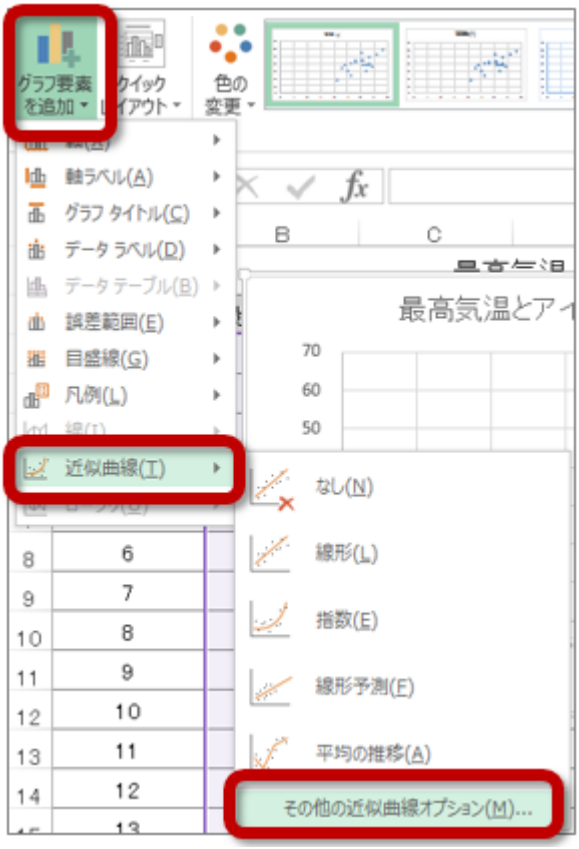

2. 「近似曲線の書式設定」が表示されるので、次のように設定する
    - 「近似または回帰の種類」を「線形近似」に選択する
    - 「予測」の「前方補外」・「後方補外」の入力欄に、それぞれ「0.5」と入力
    - 「グラフに数式を表示する」と「グラフにR-2乗値を表示する」のチェック欄をクリックしてチェックする

3.「閉じる」をクリックすると、散布図のグラフに回帰直線（と回帰式）が表示される

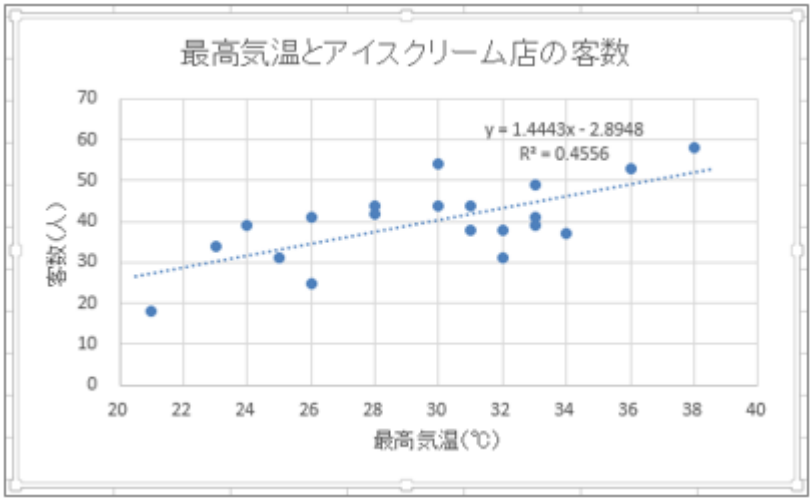

これで、回帰曲線と同時に、回帰式（傾き、y切片）、決定係数(R^2値）が表示されます。