

3.3.1 重回帰モデルにおける回帰係数の意味

結論： 他の変数の影響を取り除いての被説明変数への影響を表す。

$k = 2$ の単純なモデル：

$$Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + u_i, \quad i = 1, 2, \dots, n$$

ある基準の下で， β_1, β_2 の解を $\hat{\beta}_1, \hat{\beta}_2$ とする。

最小二乗法によって，

$$\min_{\hat{\beta}_1, \hat{\beta}_2} \sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i})^2$$

を解く。

$\hat{\beta}_1, \hat{\beta}_2$ について微分して，それぞれゼロとおく。

すなわち，

$$\begin{aligned} -2 \sum_{i=1}^n X_{1i}(Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i}) = 0 &\longrightarrow \sum_{i=1}^n X_{1i} Y_i = \hat{\beta}_1 \sum_{i=1}^n X_{1i}^2 + \hat{\beta}_2 \sum_{i=1}^n X_{1i} X_{2i} \\ -2 \sum_{i=1}^n X_{2i}(Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i}) = 0 &\longrightarrow \sum_{i=1}^n X_{2i} Y_i = \hat{\beta}_1 \sum_{i=1}^n X_{2i} X_{1i} + \hat{\beta}_2 \sum_{i=1}^n X_{2i}^2 \end{aligned}$$

行列表示で，

$$\begin{pmatrix} \sum_{i=1}^n X_{1i} Y_i \\ \sum_{i=1}^n X_{2i} Y_i \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^n X_{1i}^2 & \sum_{i=1}^n X_{1i} X_{2i} \\ \sum_{i=1}^n X_{2i} X_{1i} & \sum_{i=1}^n X_{2i}^2 \end{pmatrix} \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix}$$

となり, $\hat{\beta}_1, \hat{\beta}_2$ は次のように得られる。

$$\begin{aligned} \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} &= \begin{pmatrix} \sum X_{1i}^2 & \sum X_{1i}X_{2i} \\ \sum X_{1i}X_{2i} & \sum X_{2i}^2 \end{pmatrix}^{-1} \begin{pmatrix} \sum X_{1i}Y_i \\ \sum X_{2i}Y_i \end{pmatrix} \\ &= \frac{1}{(\sum X_{1i}^2)(\sum X_{2i}^2) - (\sum X_{1i}X_{2i})^2} \begin{pmatrix} \sum X_{2i}^2 & -\sum X_{1i}X_{2i} \\ -\sum X_{1i}X_{2i} & \sum X_{1i}^2 \end{pmatrix} \begin{pmatrix} \sum X_{1i}Y_i \\ \sum X_{2i}Y_i \end{pmatrix} \\ &= \begin{pmatrix} \frac{(\sum X_{2i}^2)(\sum X_{1i}Y_i) - (\sum X_{1i}X_{2i})(\sum X_{2i}Y_i)}{(\sum X_{1i}^2)(\sum X_{2i}^2) - (\sum X_{1i}X_{2i})^2} \\ \frac{-(\sum X_{1i}X_{2i})(\sum X_{1i}Y_i) + (\sum X_{1i}^2)(\sum X_{2i}Y_i)}{(\sum X_{1i}^2)(\sum X_{2i}^2) - (\sum X_{1i}X_{2i})^2} \end{pmatrix} \end{aligned}$$

2つ目の等式では, 2×2 の逆行列の公式が用いられている。

(*) 復習 :

$$\begin{pmatrix} a & b \\ c & d \end{pmatrix}^{-1} = \frac{1}{ad-bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$$

また, $\sum_{i=1}^n X_{ji}X_{li}$, $\sum_{i=1}^n X_{ji}Y_i$ をそれぞれ $\Sigma X_{ji}X_{li}$, $\Sigma X_{ji}Y_i$ と表記する。

ただし, $j = 1, 2$, $l = 1, 2$ とする。

一方、次の2つの回帰式を考える。

$$Y_i = \alpha_1 X_{2i} + v_i$$

$$X_{1i} = \alpha_2 X_{2i} + w_i$$

α_1, α_2 の最小二乗推定量を求める。

$$\begin{aligned} \min_{\hat{\alpha}_1} \sum_{i=1}^n (Y_i - \hat{\alpha}_1 X_{2i})^2 &\longrightarrow -2 \sum_{i=1}^n X_{2i} (Y_i - \hat{\alpha}_1 X_{2i}) = 0 &\longrightarrow \sum_{i=1}^n X_{2i} Y_i = \hat{\alpha}_1 \sum_{i=1}^n X_{2i}^2 \\ \min_{\hat{\alpha}_2} \sum_{i=1}^n (X_{1i} - \hat{\alpha}_2 X_{2i})^2 &\longrightarrow -2 \sum_{i=1}^n X_{2i} (X_{1i} - \hat{\alpha}_2 X_{2i}) = 0 &\longrightarrow \sum_{i=1}^n X_{2i} X_{1i} = \hat{\alpha}_2 \sum_{i=1}^n X_{2i}^2 \end{aligned}$$

を解いて、最小二乗推定量 $\hat{\alpha}_1, \hat{\alpha}_2$ をそれぞれ求めると、

$$\hat{\alpha}_1 = \frac{\sum X_{2i} Y_i}{\sum X_{2i}^2}, \quad \hat{\alpha}_2 = \frac{\sum X_{2i} X_{1i}}{\sum X_{2i}^2}$$

となる。

$\hat{\alpha}_1, \hat{\alpha}_2$ を用いて, v_i, w_i の残差 \hat{v}_i, \hat{w}_i を下記のようにそれぞれ求める。

$$\hat{v}_i = Y_i - \hat{\alpha}_1 X_{2i}, \quad \hat{w}_i = X_{1i} - \hat{\alpha}_2 X_{2i}$$

\hat{v}_i, \hat{w}_i は Y_i, X_{1i} から X_{2i} の影響を取り除いたものと解釈できる。

更に, 次の回帰式を考える。

$$\hat{v}_i = \gamma \hat{w}_i + \epsilon_i$$

γ の最小二乗推定量 $\hat{\gamma}$ は $\hat{\beta}_1$ に一致することを示す。

$$\min_{\hat{\gamma}} \sum_{i=1}^n (\hat{v}_i - \gamma \hat{w}_i)^2$$

を解くと，

$$\hat{\gamma} = \frac{\sum \hat{w}_i \hat{v}_i}{\sum \hat{w}_i^2}$$

となり，変形していくと，

$$\begin{aligned} \hat{\gamma} &= \frac{\sum \hat{w}_i \hat{v}_i}{\sum \hat{w}_i^2} = \frac{\sum (X_{1i} - \hat{\alpha}_2 X_{2i})(Y_i - \hat{\alpha}_1 X_{2i})}{\sum (X_{1i} - \hat{\alpha}_2 X_{2i})^2} \\ &= \frac{\sum X_{1i} Y_i - \hat{\alpha}_1 \sum X_{1i} X_{2i} - \hat{\alpha}_2 \sum X_{2i} Y_i + \hat{\alpha}_1 \hat{\alpha}_2 \sum X_{2i}^2}{\sum X_{1i}^2 - 2\hat{\alpha}_2 \sum X_{1i} X_{2i} + \hat{\alpha}_2^2 \sum X_{2i}^2} \end{aligned}$$

$$\begin{aligned}
& \sum X_{1i}Y_i - \frac{(\sum X_{2i}Y_i)(\sum X_{1i}X_{2i})}{\sum X_{2i}^2} \\
= & \frac{\sum X_{1i}^2 - \frac{(\sum X_{1i}X_{2i})^2}{\sum X_{2i}^2}}{\sum X_{1i}^2 - \frac{(\sum X_{1i}X_{2i})^2}{\sum X_{2i}^2}} \\
= & \frac{(\sum X_{2i}^2)(\sum X_{1i}Y_i) - (\sum X_{1i}X_{2i})(\sum X_{2i}Y_i)}{(\sum X_{1i}^2)(\sum X_{2i}^2) - (\sum X_{1i}X_{2i})^2} = \hat{\beta}_1,
\end{aligned}$$

となる。

すなわち、「 Y_i から X_{2i} の影響を取り除いた変数」を被説明変数、「 X_{1i} から X_{2i} の影響を取り除いた変数」を説明変数とした回帰係数が β_1 に等しい。

一般化： 次の回帰モデルを考える。

$$Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + \cdots + \beta_k X_{ki}$$

j 番目の回帰係数 β_j の意味は、「 Y_i から $X_{1i}, \dots, X_{j-1,i}, X_{j+1,i}, \dots, X_{ki}$ (すなわち, X_{ji} 以外の説明変数) の影響を取り除いた変数」を被説明変数、「 X_{ji} から $X_{1i}, \dots, X_{j-1,i}, X_{j+1,i}, \dots, X_{ki}$ (すなわち, X_{ji} 以外の説明変数) の影響を取り除いた変数」を説明変数とした回帰係数となる。

3.3.2 決定係数 R^2 と自由度修正済み決定係数 \bar{R}^2 について

また, 決定係数 R^2 についても同様に表される。

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} = 1 - \frac{\sum_{i=1}^n \hat{u}_i^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}$$

ただし, $\hat{Y}_i = \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \dots + \hat{\beta}_k X_{ki}$, $Y_i = \hat{Y}_i + \hat{u}_i$ である。

R^2 は, 説明変数を増やすことによって, 必ず大きくなる。なぜなら, 説明変数が増えるこ

とによって、 $\sum_{i=1}^n \hat{u}_i^2$ が必ず減少するからである。

補足： 簡単化のために、説明変数が2つの場合を考える。

最小二乗法とは、

$$Y_i = \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \hat{u}_i$$

からの残差平方和：

$$S(\hat{\beta}_1, \hat{\beta}_2) = \sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i})^2$$

を最小にするような $\hat{\beta}_1, \hat{\beta}_2$ を求める。

すなわち，下記の最適化問題を解くことになる。

$$\min_{\hat{\beta}_1, \hat{\beta}_2} S(\hat{\beta}_1, \hat{\beta}_2)$$

一方，説明変数が1つの場合，

$$Y_i = \hat{\beta}_1 X_{1i} + \hat{u}_i$$

からの残差平方和：

$$S_*(\hat{\beta}_1) = \sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i})^2$$

を最小にするような $\hat{\beta}_1$ を求める。

$S(\cdot, \cdot)$ と区別するために $S_*(\cdot)$ としている。

$S(\cdot, \cdot)$ と $S_*(\cdot)$ との関係は,

$$S_*(\hat{\beta}_1) = S(\hat{\beta}_1, 0)$$

となる ($\hat{\beta}_2 = 0$ という制約が付いていることに注意せよ)。

すなわち, この場合, 下記の最適化問題を解くことになる。

$$\min_{\hat{\beta}_1} S_*(\hat{\beta}_1) = \min_{\hat{\beta}_1} S(\hat{\beta}_1, 0)$$

したがって,

$$\min_{\hat{\beta}_1, \hat{\beta}_2} S(\hat{\beta}_1, \hat{\beta}_2) \leq \min_{\hat{\beta}_1} S(\hat{\beta}_1, 0)$$

となる。

このように、 R^2 を基準にすると、被説明変数にとって意味のない変数でも、説明変数が多いほど、よりよいモデルということになる。この点を改善するために、自由度修正済み決定係数 \bar{R}^2 を用いる。

$$\bar{R}^2 = 1 - \frac{\sum_{i=1}^n \hat{u}_i^2 / (n - k)}{\sum_{i=1}^n (Y_i - \bar{Y})^2 / (n - 1)},$$

$\sum_{i=1}^n \hat{u}_i^2 / (n - k)$ は u_i の分散 σ^2 の不偏推定量であり、 $\sum_{i=1}^n (Y_i - \bar{Y})^2 / (n - 1)$ は Y_i の分散の不偏推定量である。分散や不偏推定量の意味は、統計学の知識を必要とし、後述する。

R^2 と \bar{R}^2 との関係は、

$$\bar{R}^2 = 1 - (1 - R^2) \frac{n - 1}{n - k},$$

となる。さらに、

$$\frac{1 - \bar{R}^2}{1 - R^2} = \frac{n - 1}{n - k} \geq 1,$$

という関係から、 $\bar{R}^2 \leq R^2$ という結果を得る。($k = 1$ のときのみ、等号が成り立つ。)

数値例： 今までと同じ数値例で， \bar{R}^2 を計算する（最新の表を再掲する）。

i	X_i	Y_i	X_i^2	$X_i Y_i$	\hat{Y}_i	\hat{u}_i	$X_i \hat{u}_i$	$\hat{Y}_i \hat{u}_i$	\hat{u}_i^2	Y_i^2
1	5	4	25	20	4.0	0.0	0.0	0.00	0.00	16
2	1	1	1	1	1.2	-0.2	-0.2	-0.24	0.04	1
3	3	1	9	3	2.6	-1.6	-4.8	-4.16	2.56	1
4	2	3	4	6	1.9	1.1	2.2	2.09	1.21	9
5	4	4	16	16	3.3	0.7	2.8	2.31	0.49	16
合計	ΣX_i	ΣY_i	ΣX_i^2	$\Sigma X_i Y_i$	$\Sigma \hat{Y}_i$	$\Sigma \hat{u}_i$	$\Sigma X_i \hat{u}_i$	$\Sigma \hat{Y}_i \hat{u}_i$	$\Sigma \hat{u}_i^2$	ΣY_i^2
	15	13	55	46	13	0.0	0.0	0.0	4.3	43
平均	\bar{X}	\bar{Y}								
	3	2.6								

$\bar{Y} = 2.6$, $\sum_{i=1}^n \hat{u}_i^2 = 4.3$, $\sum_{i=1}^n Y_i^2 = 43$ なので ,

$$R^2 = 1 - \frac{\sum \hat{u}_i^2}{\sum Y_i^2 - n\bar{Y}^2} = 1 - \frac{4.3}{43 - 5 \times 2.6^2} = 1 - \frac{4.3}{9.2} = 0.5326$$

となり , \bar{R}^2 は ,

$$\bar{R}^2 = 1 - \frac{\sum \hat{u}_i^2 / (n - k)}{(\sum Y_i^2 - n\bar{Y}^2) / (n - 1)} = 1 - \frac{4.3 / (5 - 2)}{9.2 / (5 - 1)} = 0.3768$$

となる。

自由度について： 分子について , 残差 \hat{u}_i を求めるためには , $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$ の k 個の推定値を得なければならない。データ数 n から推定値の数 k を差し引いたものを自由度 (degree of

freedom) と呼ぶ。

一方、分母については、 X_{1i} が定数項だとして、 Y_i が定数項を除く $X_{2i}, X_{3i}, \dots, X_{ki}$ に依存しない場合を考える。この場合、 $\beta_2 = \beta_3 = \dots = \beta_k = 0$ とするので、 $\hat{u}_i = Y_i - \hat{\beta}_1$ となる。 \hat{u}_i を得るためには $\hat{\beta}_1$ だけを求めればよい。最小二乗法の考え方に沿って求めれば、 $\hat{\beta}_1 = \bar{Y}$ となる（読者は確認すること）。すなわち、自由度は「データ数 - 推定値の数 = $n - 1$ 」ということになる。

このように、決定係数の第二項目の分子・分母をそれぞれの自由度で割ることによって、自由度修正済み決定係数が得られる。

注意： R^2 や \bar{R}^2 を比較する場合、被説明変数が同じであることが重要である。被説明変数が対数かまたはそのままの値であれば、決定係数・自由度修正済み決定係数の大小比較は意

味をなさない。ただし、被説明変数が異なる場合であっても、被説明変数を上昇率とするかそのままの値を用いるかの比較では、決定係数・自由度修正済み決定係数の大小比較はできないが、誤差項 u_i の標準誤差での比較は可能である (標準誤差の小さいモデルを採用する)。

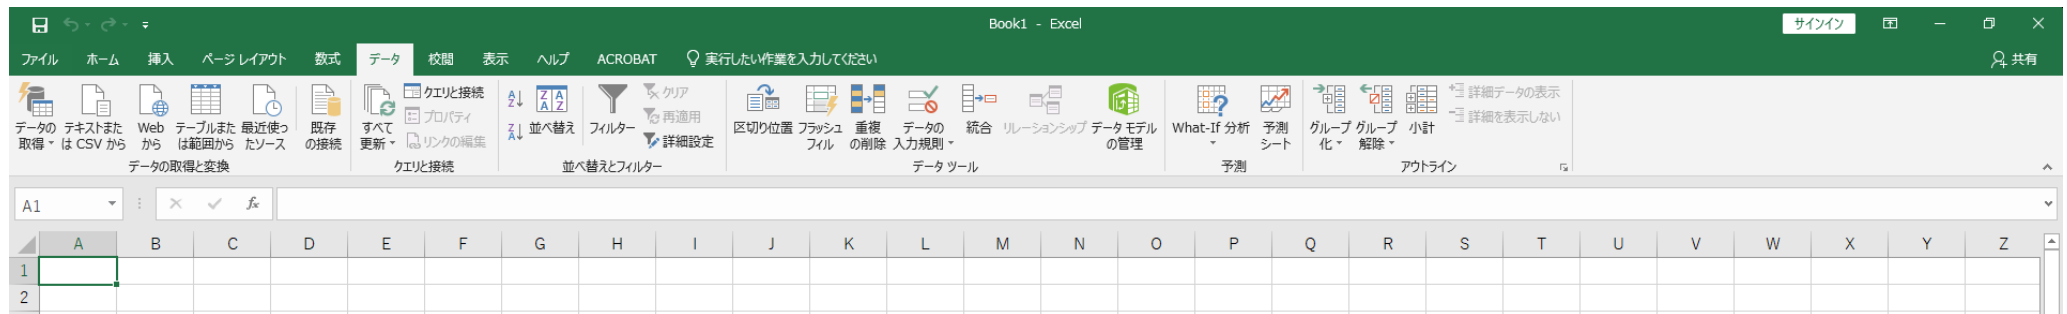
⇒ 関数型の選択

3.4 Excel 2019 による回帰分析

回帰分析が出来るように、Excel 2019 をセットアップする。

Excel 2013, Excel 2016 も同様の手順。

まず、エクセルの最初のページで、「データ」タブをマウスでクリックすると、下記の画面が出てくる。



様々な選択肢があり、一番左（「アウトライン」の右隣の右）に注目。

選択肢は何もない状態。


次に、「ファイル」タブをマウスでクリックすると下記の画面が現れる。



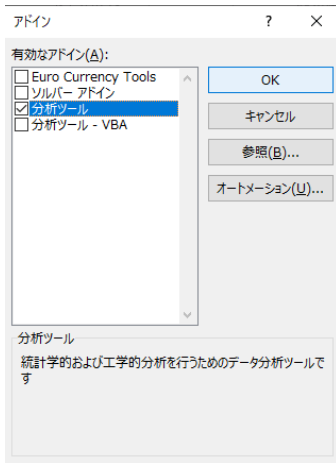
一番左下の「オプション」を選択して、下記の画面が出てくる。




左の下から 2 番目の「アドイン」を選択して、下記の画面が出てくる。



「設定 (G)」 ボタンをクリックして、下記の画面が現れる。



「分析ツール」にチェックを入れて、「OK」ボタンをクリックすると、下記の「データ」タブの画面に戻る。



一番右に「データ分析」のタブが追加される。


これは一度だけ行えばよい。

次回からは自動的に「データ分析」のタブは追加されたままになる。

3.4.1 散布図による回帰分析（単回帰の場合）

今までの数値例で散布図を作成する。


下記のようにデータを入力する。A列にXデータ（説明変数），B列にYデータ（被説明変数）。



The screenshot shows the Excel interface with the 'Insert' tab selected. The data table is as follows:

	A	B	C
1	5	4	
2	1	1	
3	3	1	
4	2	3	
5	4	4	
6			
7			

「挿入」タブを選ぶ。

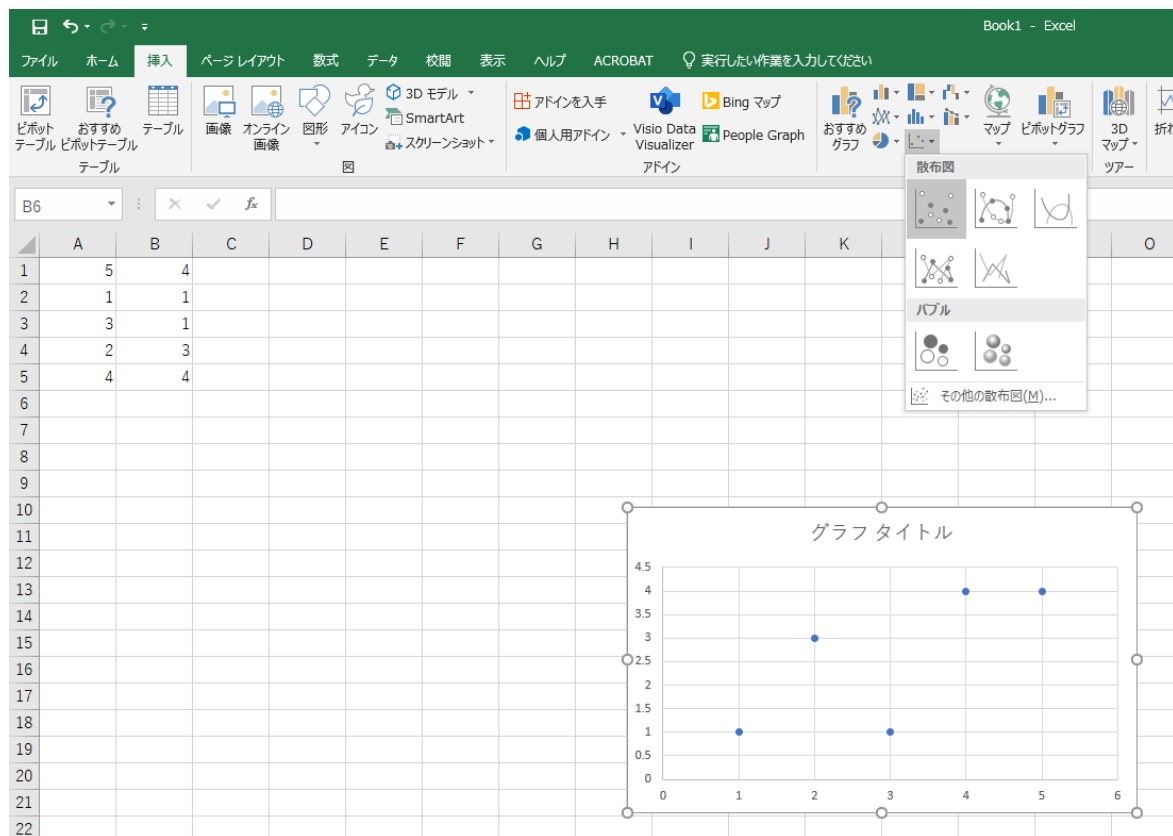


The screenshot shows the Excel interface with the 'Insert' tab selected. The ribbon includes options for 'Charts' (散布図, 折れ線, 縦棒, 勝敗) and 'Tables' (テーブル). A tooltip is visible over the 'Scatter' (散布図) icon, providing instructions on how to insert a scatter plot or bubble chart.

散布図 (X, Y) またはバブル チャートの挿入
この種類のグラフは、値のセットの関係を表示するのに使います。

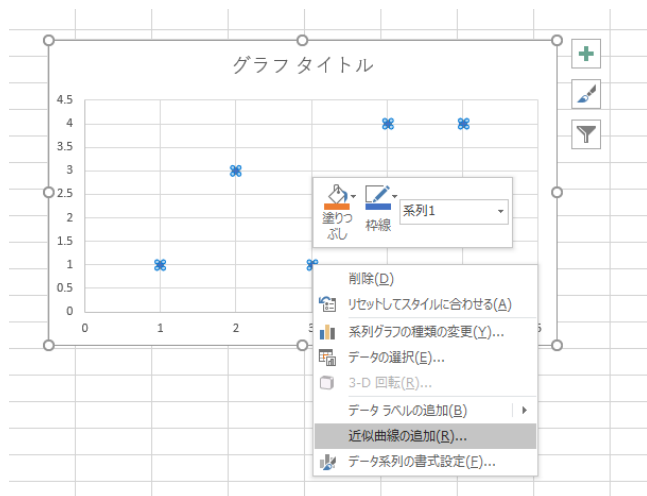
別の種類の散布図グラフとバブル チャートを表示するには、矢印をクリックします。ドキュメント内でプレビューを表示するには、ポインターをアイコンの上に置きます。

散布図を選び、さらに、左上の散布図を選ぶと、下記の画面が出る。

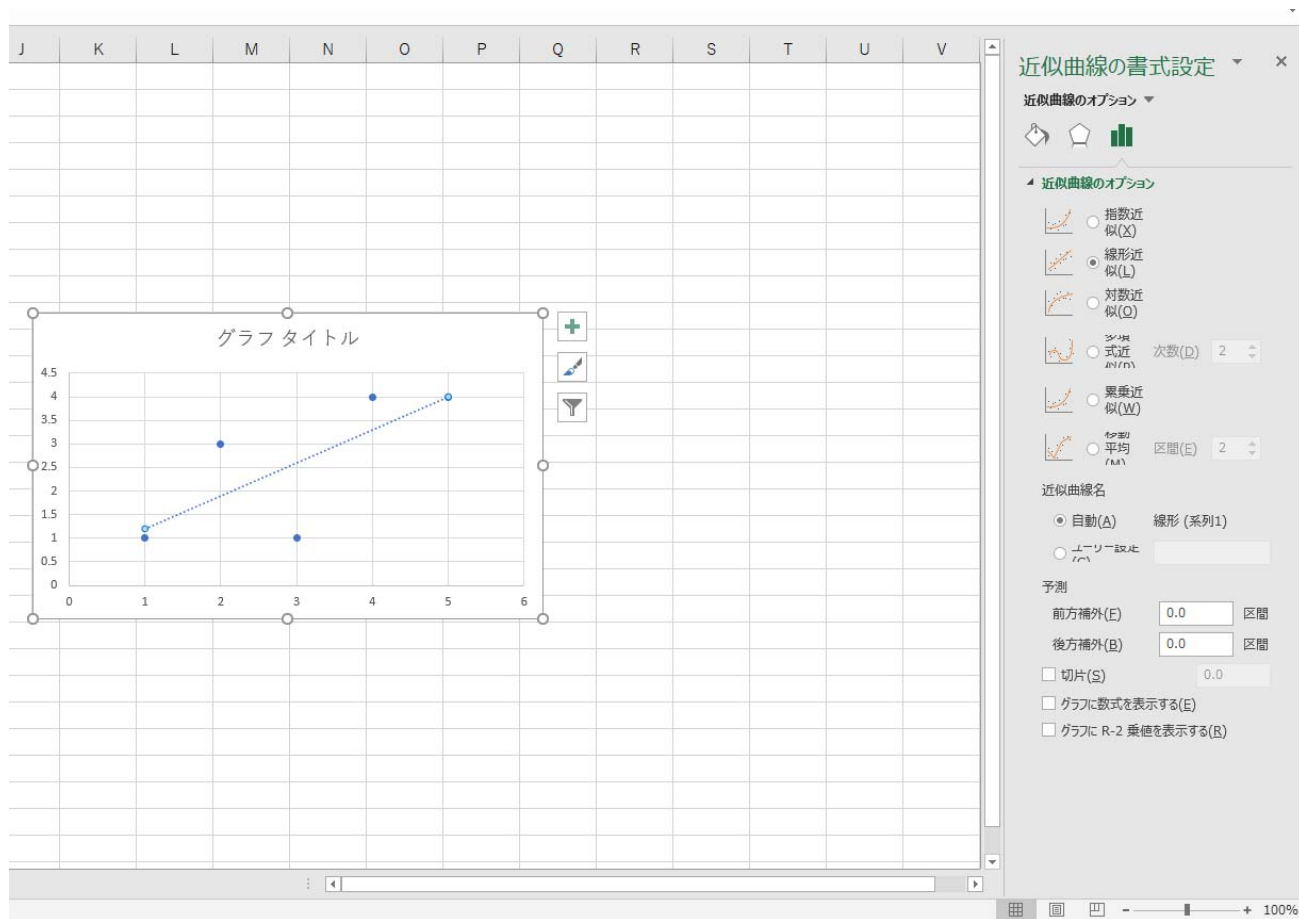


このように、横軸に A 列，縦軸に B 列の散布図が完成する。


グラフ内の 6 点のうちどれか一つをマウスで選び、マウスの右ボタンを押すと、下記の画面になる。



下から2つ目の「近似曲線の追加(R)」を選択して、下記の画面になる。



直線の方程式をグラフ内に表示させるには、右側の近似曲線の書式設定の一番下の「グラフに数式を表示する (E)」にチェックを入れる。決定係数を表示させるには「グラフに R-2 乗値を表示する (R)」にチェックを入れる。下の画面になる。



直線の式は $Y = 0.7X + 0.5$, 決定係数 $R^2 = 0.5326$ と追加される。