

## 付録 B エクセルの使い方

統計学を勉強しても、やはり実際に自分で使ってみないと理解は十分ではありません。ここでは、実際に統計分析を使う方法のひとつとして、エクセルの使い方を解説します。本稿は、藪友良『入門 実践する統計学』（2012年、東洋経済新報社）の付録 B をアップデートしたものです。データは、本書ウェブサイトからファイル `appendix_b_data.xlsx` をダウンロードしてください。

### B.1 分析ツール

エクセルについている分析ツールという機能を使えば、さまざまな統計分析が可能です。まず、この機能を使えるように設定します。もし[データ]タブに[データ分析]という項目があれば、本節は無視してください。[データ分析]がなければ、以下の手順に従って設定します<sup>1</sup>。


エクセル画面左上の[ファイル]タブをクリックします(下画面参照)。



そして左列の一番下にある[オプション]をクリック(下画面参照)。




そうすると、[Excel のオプション]ウィンドウ画面がでますから、下画面から[アドイン]を選んで、下画面下にある[設定]をクリックします。



<sup>1</sup> ここではエクセル 2007 に基づいて説明をしています。本節のやり方で設定できないときは、ヘルプ機能で分析ツールを検索し、そこで示されている方法に従って設定してください。

それから下画面で[分析ツール]をチェックして OK とします。




これで[データ]タブの一番右に[データ分析]という項目が加わります。

## B.2 無作為抽出

1章では無作為抽出の方法として、10面体のサイコロを用いる方法を説明しました。しかし、エクセルを使えば無作為抽出を容易に行うことができます(エクセルのシート「ID」参照)。

たとえば、1000人の学生から10人を無作為抽出するときは、まず全員に1から1000までの番号(ID)を付けます。次に、[データ]タブの[データ分析]をクリックします。そして、[サンプリング]を選んでからOKをクリックします。



すると、左下の画面が出てきます。ここで□に情報を入力します。A列の2行から1001行まで番号が記録されていますから、入力範囲として、 $\$A\$2:\$A\$1001$ を入力します。入力が面倒であれば、↑ボタンを押して、データの入力範囲を画面上で範囲指定することもできます。また、10人を無作為

抽出しますから、データの個数に 10 を入力します。そして OK を押すと右下の画面となり、乱数が抽出されます。この場合、選ばれた乱数は 949、853、517、284、956、628、396、67、739、3 です。この番号に対応した 10 人の学生を選べば無作為抽出は完了です<sup>2</sup>。無作為抽出ですから、みなさんは異なる番号が抽出されたと思います。

	A	B
1	949	
2	853	
3	517	
4	284	
5	956	
6	628	
7	396	
8	67	
9	739	
10	3	

### B.3 特性値の計算方法

エクセルを使った特性値の計算方法を説明します。エクセルにはさまざまな特性値を計算するため、多くの関数が定義されています。たとえば、平均であれば=AVERAGE(配列)とすれば、配列指定したデータを使って、平均を計算してくれます（配列はデータ入力範囲）。代表的関数には

平均=AVERAGE（配列）、中央値=MEDIAN（配列）、最頻値=MODE（配列）、標本分散=VAR（配列）、標本標準偏差=STDEV（配列）、標本共分散=COVAR（配列 1, 配列 2）、標本相関係数=CORREL（配列 1, 配列 2）

などがあります。標本共分散と標本相関係数は 2 変数の関係をとらえる指標ですから、配列を 2 つ指定します。

下画面は GDP を 1991～2004 年まで記録したものです(エクセルのシート「GDP」参照)。A 列には時間（年）、B 列には GDP が記録され、C 列では

<sup>2</sup>無作為抽出すると、同じ番号が重複することがあります。番号の重複を認める方法を復元抽出、認めない方法を非復元抽出といいます。たとえば、番号 1～100 から 3 つを抽出したとき、乱数として 91、7、91 が抽出されたとしましょう。復元抽出なら、選ばれた乱数は 91、7、91 ですが、非復元抽出なら（もう一度抽出したところ乱数 80 が得られたとする）、選ばれた乱数は 91、7、80 です。非復元抽出は同一母集団からの抽出とならず、i.i.d.の仮定は満たされません。ただし、母集団規模が十分に大きければどちらでも変わりません。


GDP 成長率（変化率）を計算しています。たとえば、C 列の 3 行目は 0.0245 となっていますが、これは  $(B3-B2)/B2$  として計算できます<sup>3</sup>。そして、このセル（C3）をコピーして、C 列の 4～15 行までに貼り付ければ変化率を全て計算できます。ここで GDP の平均は  $=AVERAGE(B2:B15)$ 、GDP と成長率の相関は  $=CORREL(B3:B15, C3:C15)$  として計算できます（計算すると、それぞれ 4934272 と 0.1009）。

	A	B	C	D	E	F
1		GDP(名目)	成長率			
2	1991	4722614			$=AVERAGE(B2:B15)$	
3	1992	4838375	0.02451206			
4	1993	4806615	-0.006564187			
5	1994	4869469	0.013076562			
6	1995	4957357	0.018048785			
7	1996	5064795	0.021672436			
8	1997	5104658	0.007870605			
9	1998	5013835	-0.017792181			
10	1999	4966058	-0.009529033			
11	2000	5027831	0.012439041			
12	2001	4923467	-0.020757261			
13	2002	4887244	-0.007357214			
14	2003	4935532	0.009880415			
15	2004	4961970	0.005356667			

#### B.4. 図の描き方

ここでは図の書き方を説明します。下画面では、1991～2004 年までの GDP が記録されています。図を描くためには、まず、下画面のようにデータ範囲を指定します。指定が終わってから、[挿入]タブをクリックし、折れ線マーク  をクリックします（折れ線以外に、散布図、縦棒、横棒、円グラフなどもあります）。

<sup>3</sup> 1992 年の変化率は、1991～92 年の変化分（B3-B2）を 1991 年の値（B2）で割ったものです。



そして折れ線の中で、自分が描きたい図の種類を選択します。ここでは、左上の図を選びましょう。




そうすると、下図が出てきます。横軸は年、縦軸は GDP の規模となっています。このままではあまりきれいな図ではありませんから、微調整して図を見やすくする必要があります。作成された図をクリックして、[デザイン]タブを選ぶと、さまざまな微調整ができるようになります。また、図の軸をクリックし、書式設定を選ぶことでも調整ができます。




## B.5 標本相関係数の計算

エクセルを使って標本相関係数を計算しましょう。5章ではトヨタ、ホンダ、ユニクロの株価の動きを紹介しました。ここでは、これら3系列の標本相関係数を計算します(エクセルのシート「株価」参照)。まず、[データ]タブの[データ分析]をクリックします。そして、[相関]をクリックしてOKします。



すると、左下の画面が出てきます。ここで□に情報を入力します。B~D列の1~31行にデータが記録されていますから、入力範囲として、**\$B\$1:\$D\$31**を代入します。ただし、最初のセルはデータ名ですから、[先頭行をラベルとして使用]をチェックしてください。そうすると、最初のセルをラベルとして認識してくれます。そしてOKすると、右下の画面が出てきます。同じ系列同士では相関係数は1となりますから、対角要素は全て1です。トヨタとホンダの相関係数は0.960、トヨタとユニクロの相関係数は-0.697、ホンダとユニクロの相関係数は-0.629となっています。



## B.6 確率の計算

ここでは確率変数の確率を計算する方法を説明します。

$Z$  は標準正規確率変数とします。確率  $P\{Z < z\}$  を求めたい場合、`=NORMSDIST(z)` と入力します。たとえば、 $P\{Z < 1.96\}$  を求めるには `=NORMSDIST(1.96)` と入力すれば 0.9750 が得られます（エクセルのシート「確率、臨界値の計算」参照）。

$W$  は自由度  $n$  の  $\chi^2$  確率変数とします。このとき、 $P\{\chi^2_{n,\alpha} < W\} = \alpha$  となる  $\chi^2_{n,\alpha}$  の値を計算するには、`=CHIINV( $\alpha$ , n)` と入力します。たとえば、 $\chi^2_{99,0.025}$  を求めるときは、`=CHIINV(0.025, 99)` と入力すれば 128.42 が得られます。また、 $\chi^2_{99,0.975}$  を求めたい場合は、`=CHIINV(0.975, 99)` と入力すれば 73.36 が得られます。

$U$  は自由度  $n$  の  $t$  確率変数とします。このとき、 $P\{t_{n,\alpha} < |U|\} = \alpha$  が成立する  $t_{n,\alpha}$  を計算するには、`=TINV( $\alpha$ , n)` と入力します。たとえば、 $t_{1,0.1}$  は、`=TINV(0.1, 1)` と入力すると、6.314 が得られます。

$V$  は第 1 自由度  $m$ 、第 2 自由度  $n$  の  $F$  確率変数とします。 $P\{F_{m,n} < V\} = \alpha$  となる  $F_{m,n}$  の値を計算するには `=FINV( $\alpha$ , m, n)` と入力します。 $\alpha = 0.05$ 、 $m = n = 2499$  であれば、`=FINV(0.05, 2499, 2499)` として 1.068 が得られます。

## B.7. 回帰分析

回帰分析の仕方とその解釈を説明します。2010/1/1～2010/12/31 の円ドルレートをを使って、為替レートが予測できるのかを調べます（エクセルのシート「円ドル」参照）。 $t$  日の為替レートを  $S_t$  とし、 $t$  日の変化率を

$$dS_t = \frac{S_t - S_{t-1}}{S_{t-1}}$$

と表します。

ここでは被説明変数を  $t$  日の変化率 ( $dS_t$ )、説明変数を  $t-1$  日の変化率 ( $dS_{t-1}$ ) とします。

$$dS_t = \alpha + \beta dS_{t-1} + u_t$$

$\beta$  が 0 から有意に異ならなければ為替の予測はできませんし、 $\beta$  が有意に 0 から異なれば為替の予測が可能だといえます。これは自己回帰 (AR) モデルといわれ、時系列分析で重要なモデルのひとつです（詳しくは、参考文献で紹介されている本を読んでください）。

[データ]タブの[データ分析]をクリックします。そして、[回帰分析]を選択して OK をクリックします。

	A	B	C	D	E	F	G	H	I	J	K	L
1		円ドル(17:00)	t日の変化率	t-1日の変化率								
2	2010/1/6	92.12	0.002448447	-0.01231								
3	2010/1/7	92.79	0.007273122	0.002448								
4	2010/1/8	93.28	0.005280741	0.007273								
5	2010/1/12	91.885	-0.014954974	0.005281								
6	2010/1/13	91.265	-0.006747565	-0.01495								
7	2010/1/14	91.85	0.006409905	-0.00675								
8	2010/1/15	90.955	-0.009744148	0.00641								
9	2010/1/18	90.99	0.000384806	-0.00974								
10	2010/1/19	90.62	-0.004066381	0.000385								
11	2010/1/20	90.905	0.003145001	-0.00407								
12	2010/1/21	91.52	0.006765304	0.003145								
13	2010/1/22	90.43	-0.011909965	0.006765								
14	2010/1/25	90.225	-0.002266947	-0.01191								

すると下画面が表示されます。ここで被説明変数 ( $Y$ ) は C の列( $t$  日の変化率、つまり  $dS_t$ )、説明変数 ( $X$ ) は D の列( $t-1$  日の変化率、つまり  $dS_{t-1}$ )となります。したがって、入力  $Y$  範囲は C の列  $\$C\$1:\$C\$244$  とし、入力  $X$  範囲は D の例  $\$D\$1:\$D\$244$  と範囲指定します<sup>4</sup>。  $Y$  と  $X$  の入力範囲は 1 行目から始めていますが、1 行目はデータの名前 (ラベル) で、データそのものではありません。このため、ラベルにチェックを入れて、データではないことを明示しておきます。また、ここでは有意水準にチェックし、横の空欄に 90 という値を入れておきます。こうすることで信頼区間 90%を計算してくれます。

最後に OK をクリックすると、以下の画面が表示されます。ここでは重要な情報とその意味を紹介していきます。

<sup>4</sup> 入力  $X$  範囲は 1 変数ではなく、複数の変数を指定することもできます。その場合は多重回帰分析となります。

回帰統計								
重相関 R	0.111537							
重決定 R2	0.012441							
補正 R2	0.008343							
標準誤差	0.006376							
観測数	243							
分散分析表								
	自由度	変動	分散	割された分散	有意 F			
回帰	1	0.000123	0.000123	3.035945	0.082715			
残差	241	0.009796	4.06E-05					
合計	242	0.009919						
	係数	標準誤差	t	P-値	下限 95%	上限 95%	下限 90.0%	上限 90.0%
切片	-0.00053	0.00041	-1.28724	0.199245	-0.00134	0.00028	-0.00121	0.000149
t-1日の変	-0.11097	0.06369	-1.7424	0.082715	-0.23643	0.014487	-0.21614	-0.00581

最初のブロックには、当てはまりの尺度である決定係数などがまとめられています。重決定 R2 は決定係数であり、0.0124 とあまり当てはまりはよくありません。また、補正 R2 は自由度調整済み決定係数であり、0.0083 と低い値ですから、やはり当てはまりはよくありません。観測数はサンプルサイズであり、この場合は 243 となります。

最後のブロック（分散分析表）に、母数 ( $\alpha$ 、 $\beta$ ) の推定値、標準誤差、95% と 90%信頼区間がまとめられています（有意水準をチェックし、90 と入力したため、90%信頼区間も表示）。たとえば、 $\alpha$  は -0.00053、 $\beta$  は -0.11097 と推定されています。それぞれの標準誤差は 0.00041 と 0.06369 です。t 値は推定値を標準誤差で割ったもので、それぞれ -1.28724 ( $= -0.00053/0.00041$ )、-1.7424 ( $= -0.11097/0.06369$ ) となります。この場合、 $\alpha$  に関する t 値は 0 に近いいため、帰無仮説 ( $H_0: \alpha=0$ ) は採択されます。これに対し、 $\beta$  に関する t 値は -1.7424 と 0 から乖離し、有意水準 10% で帰無仮説 ( $H_0: \beta=0$ ) は棄却され、対立仮説が支持されます。90%信頼区間は、母数が 90%の確率でその範囲に含まれることを意味します。たとえば、 $\beta$  は 90%の確率で -0.21614 から -0.00581 の範囲に収まり、信頼区間内に 0 を含みませんから有意な結果といえます。

最後に、p 値は「 $H_0$  が正しいにもかかわらず、t 統計量の絶対値が t 値 ( $t^*$ ) の絶対値より大きな値をとる確率 ( $P\{|t_{\hat{\beta}}| > |t^*|\}$ )」です。たとえば、この表から、 $\beta$  に関する t 値は  $t^* = -1.7424$  で、p 値は 0.082715 となっていま

す。 $p$  値は、 $H_0$  が正しいもとで、 $t$  統計量の絶対値 ( $|t_{\hat{\beta}}|$ ) が  $t$  値の絶対値 ( $|t^*|=1.7424$ ) より大きくなる確率ですから、 $P\{|t_{\hat{\beta}}|>1.7424\}=0.082715$  となっているのです。 $p$  値を見れば何%の有意水準で帰無仮説を棄却できるかが分かります。かりに  $p$  値が 1% を下回っていれば、1% の有意水準でも帰無仮説を棄却できます。この場合、 $\beta$  の  $p$  値 0.082715 は 0.1 を下回りますから、有意水準 10% で帰無仮説は棄却されます。