

第1回 生物統計学とは？

A. 授業の枠組み

1. 講義について

農業、農学実験においてはどんなにていねいな実験をしたとしても数値にはかなりのばらつきがある。ばらつきを考慮しないで平均だけで実験の結果を議論するならば大きな誤りを犯す可能性がある。このように生物、農業などで得られるばらつきのあるデータから適切な結論を得るための統計学が生物統計学である。この授業では実際のデータに当てはめていくことで統計的な考え方を身につけるようになるのが望ましい。したがって、自分でデータを使った計算を必ずこなし、授業に積極的に参加して、統計的考え方を育てることが必要である。

毎回、なるべく多くの学生に質問する予定である。

授業ではノートパソコン（授業ではエクセルおよびエクセルに付属する分析ツールの使い方を説明する）をかならず持参のこと。授業で説明に使うエクセルのバージョンはExcel2003を基準にする。しかし、それ以外のバージョン（Excel2007, 2010）でもかまわない。

授業のホームページ <http://www.ipc.shimane-u.ac.jp/food/kobayashi/> に資料などをのせておく。

2. 宿題について

宿題は原則として次回の授業の前日（通常は、授業の翌週の月曜日）午後1時までに生物資源科学部2号館204号室の前にあるかごに提出すること。

宿題はホームページにエクセルファイルで提供する。レポートは答案のタブのところを印刷して、提出する。授業の前にレポートを返却する。間違えた問題を訂正して、再提出ができる。再提出するときは、再提出となった元のレポートといっしょに再提出のレポートを提出すること。再提出の締め切りは1月31日とする。

3. 成績について

以下の3つから成績を判定する。

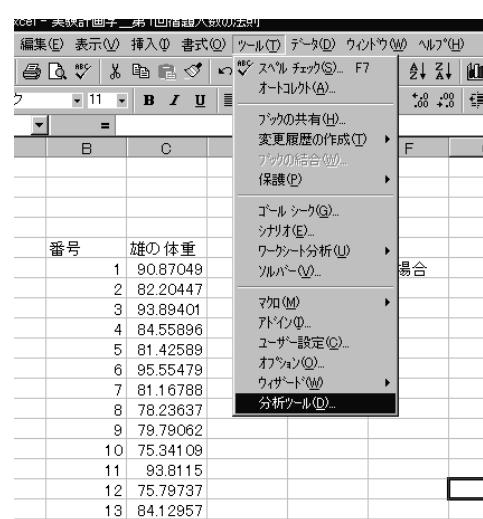
- ① 授業参加 質問への受け答え、疑問点を質問したかなど
- ② 宿題
- ③ 期末試験（ノート、参考資料、ノートパソコンの持ち込み可、通信機能の使用は不可）

B. エクセルの分析ツールの組み込み

1. Excel2003の場合（あるいはそれ以前のバージョン）

- ① 分析ツールが組み込まれているかを確認する

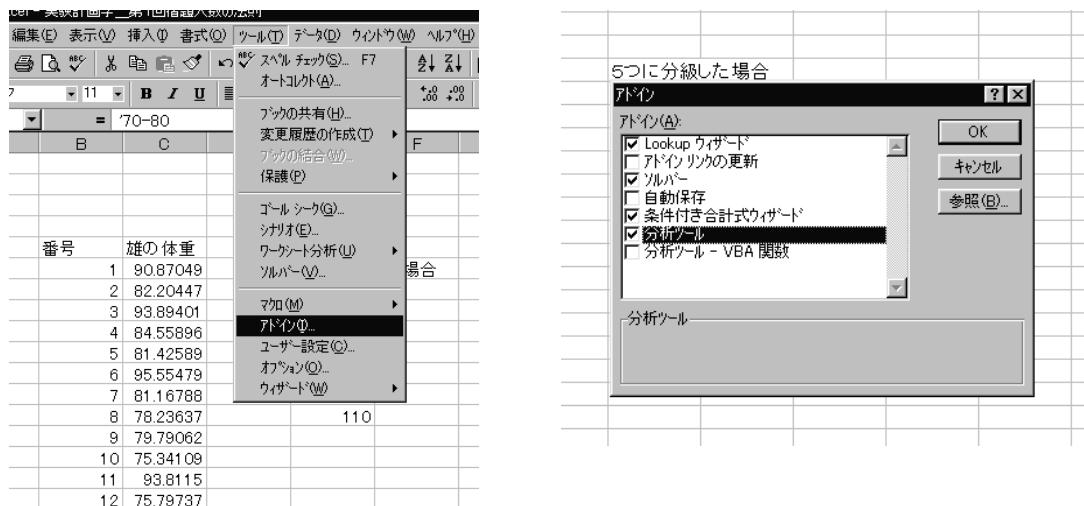
ツール→分析ツールで分析ツールを起動する。ツールをクリックしたときに出てくるプルダウンメニューに分析ツールがないときは、②の方法で分析ツールを組み込む。



② 分析ツールの組み込み

ツールでプルダウンメニューを引き出し、アドインを選ぶ。右下のようにアドイン（組み込み）するべきプログラムにチェックを入れる。ここでは分析ツールにだけチェックを入れる。

このとき場合によってはエクセルの入ったCDを要求してくる場合がある。このときは自分のパソコンに付属した、あるいは自分のパソコンにインストールしたエクセルのCDを用意する。



2. Excel2007の場合

① 分析ツールが組み込まれているかを確認する

データをクリックし、データ分析があるかを確認する。データ分析がないときは、②の方法で分析ツールを組み込む。



② 分析ツールの組み込み

一番左上のボタンを押し、現れたメニューの下にあるエクセルのオプションを押す。オプションのメニューが出たら、左のフレームメニューからアドインを選ぶ。アドインできるアプリケーションのリストが並び、アクティブでないアプリケーションアドインのリストの中に分析ツールをクリックし、設定をクリックする。次に表示されたアドインのリストの中から、アドイン（組み込み）するべきプログラムにチェックを入れる。ここでは分析ツールにだけチェックを入れる。

このとき場合によってはエクセルの入ったCDを要求してくる場合がある。このときは自分のパソコンに付属した、あるいは自分のパソコンにインストールしたエクセルのCDを用意する。





C. 経験から科学へ

1. 実験して得たデータの解釈

実験をして得たデータの解釈をどうするか？

A, B, Cの3種類の餌を与えたヒツジの成長を調べた。どの餌がいちばんよいか？

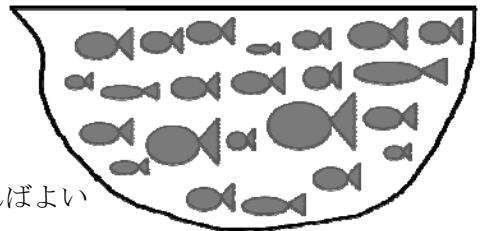
気温が上昇するとブドウの糖度はどうなるか？

データにはばらつきがあるので、1つや2つだけ調べてもそれが本当に正しいかは確信を持てない。ではデータをどのようにとったら確信を持ってもよいのだろうか？

★ 考えてみよう。

池の中の魚の体重を知りたい。魚は池に百匹以上はいて、しかも正確な数はわからない。魚の体重は図のようにかなりまちまちである。

1) 平均体重が知りたいなら何匹調べたらよいだろうか？



() 内に自分の考える数を入れよ

もし池の魚が100匹だと分かっていれば () 匹調べればよい

もし池の魚が10000匹だと分かっていれば () 匹調べればよい

もし池の魚の数が不明だとすれば () 匹調べればよい

2) 同じ形の池が2つあった。しかし、一方は富栄養化していて魚の体重が大きくなつたようだ。

この仮説を証明するには2つの池からそれぞれ何匹を調べたらよいだろうか？

() 内に自分の考える数を入れよ

もし池の魚が100匹だと分かっていれば、それぞれの池から () 匹調べればよい

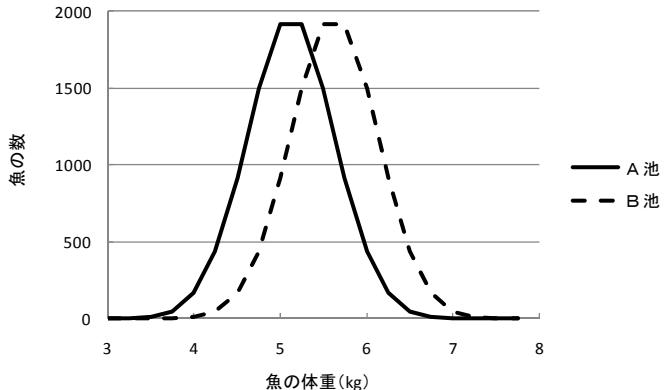
もし池の魚が10000匹だと分かっていれば、それぞれの池から () 匹調べればよい

もし池の魚の数が不明だとすれば、それぞれの池から () 匹調べればよい

1) は第6回の講義で学ぶ統計的推定、2) は第7回の講義で学ぶ統計的検定と関連がある。

ではためしに 10000 匹の魚の体重（正規分布するデータ、仮想のデータ）で実際にサンプリング実験をやってみよう（授業開始時に配布した生物統計学_授業用データ集 2010 のエクセルファイルを開く）。

A 池の魚の平均体重は 5.0kg, B 池の魚の平均体重は 5.5kg である。どちらの池の魚の平均体重のはらつきは同じで標準偏差 0.5kg である。標準偏差 0.5kg というとどのくらいばらつくだろうか？下のグラフのようになる。



2つの池から無作為にサンプリングした結果、A 池の魚の体重は（　　）kg, B 池の魚の体重は（　　）kg となった。教室全体では A 池の魚の方が重かった学生は（　　）名、B 池の魚の方が重かった学生は（　　）名いた。

さて 1 回だけの実験では今回の結果がたまたま偏った結果かも知れないので、100人の学生が 1 回ずつ 2 つの池からサンプリングした実験を 100 回行ったら、A 池の魚の方が重い学生は平均 23.85 人、B 池の魚が重い学生は平均 76.15 人となった（詳細はホームページに掲載）。

このようにたった 1 匹だけでどちらの池の魚の体重が重いかを判断しようとしたら 4 回のうち 1 回は間違った結論を出すことになる。しかし、このような判断をする人は世の中に多い。

質問：たった 1 つの数値だけで判断してしまった経験を下に書け。

しかし、学生がそれぞれ 5 匹ずつ、2 つの池からサンプリングして、その平均を比較したらどうなるだろうか？ A. やっぱり 3 回に 1 回は A 池の魚の平均が大きい、B. A 池の魚の平均が大きくなることが増える、C. A 池の魚の平均が大きくなることが減る

100人の学生が 5 匹ずつ 2 つの池からサンプリングした実験を 100 回行ったら、A 池の魚の方が重い学生は平均 5.85 人、B 池の魚が重い学生は平均 94.15 人となった。さらに 100人の学生が 10 匹ずつ 2 つの池からサンプリングした実験を 100 回行ったら、A 池の魚の方が重い学生は平均 1.32 人、B 池の魚が重い学生は平均 98.68 人となった（詳細はホームページに掲載）。

以上のことから、1回のサンプリングで採る魚の数が多くなるほど、B池の魚が重いという結果が（少なくなる・変わらない・多くなる）。つまり標本をたくさんとるほど（正しい結果を得る可能性が高くなる・正しい結果を得る可能性は変わらない・正しい結果を得る可能性が減る）。

ではこの魚の体重のデータは平均とばらつき（標準偏差という）が指定されていた。では2つの池の魚の平均体重の差が大きいほど、調べる魚の数（標本数という）を（すくなくしてもよい・変わらない・多くしなければいけない）。2つの池の魚の体重のばらつきが大きいほど、調べる魚の数を（すくなくしてもよい・変わらない・多くしなければいけない）。

池の中の魚をすべて調べれば正しい結論を得るはずだ。しかし、現実には魚をすべて調べるだけの時間、労力、お金を使えることはほとんどない。場合によっては破壊したり、殺したりする実験なら全部調べることが不可能である（例えば、魚の胃の中の内容物を調べるとしよう。全部、魚を調べたらその池には魚がいなくなってしまう・・・）。さらに原理的にすべて調べることが不可能な場合もある（仮説的無限母集団の概念、詳細は第3回で学ぶ）。

2. () の法則

昔のヨーロッパ人は彗星は前触れもなくやってきたので不吉なことの前兆ととらえた。

★ 科学の始まり ケプラーの法則 ブラーエの集めた膨大な天文学データから
ケプラーの法則から万有引力の法則へ
ニュートンはケプラーの法則から万有引力の法則を導いた
万有引力の法則ですべての天体の運動を説明できる

多数のデータから少数の法則を導くことができた→少数の法則から予測・発見ができた
海王星の存在の予言、ハレー彗星が周期的に地球の近くに来ることを予言など

たくさんデータを集めれば集めるほど確実である。

保険のデータ 人間の死や事故はわからないことだらけ

統計を集めて、確率的に掛け金を決める（生命表 車の事故）

★ 統計をみて考えよう。

- ① 日本の出生率と出生性比（女子新生児100人に対する男子新生児数）の右の表を見て気づいたことを書け。

	西暦	出生率	出生性比
明治38年	1905	31.2	102.7
明治39年	1906	29.6	108.7
明治40年	1907	34.0	102.7
明治41年	1908	34.7	104.6
明治42年	1909	34.9	104.1
昭和39年	1964	17.7	105.9
昭和40年	1965	18.6	105.3
昭和41年	1966	13.7	107.6
昭和42年	1967	19.4	105.3
昭和43年	1968	18.6	107.1
昭和44年	1969	18.5	107.2
昭和45年	1970	18.8	107.1

② 人の寿命はそれぞれ異なる。しかし、たくさんのデータを集めると傾向がわかる。日本人の平均余命が年々伸びていることを示す右の表を見て気づいたこと、さらにこのようなデータはどういうことに利用されているかを書け。

暦年	男			女		
	40歳	65歳	80歳	40歳	65歳	80歳
昭和22	68.0	39.8	9.5	70.9	49.1	17.3
25-27	81.8	55.1	16.6	83.2	62.8	26.1
30	87.0	61.8	20.0	89.0	70.6	31.9
35	89.7	64.8	20.1	92.2	75.2	33.8
40	92.6	69.1	22.6	95.0	80.0	38.4
45	93.7	72.1	26.1	96.1	82.6	43.0
50	95.1	76.8	33.2	96.9	86.1	50.7
55	96.1	79.4	37.8	97.6	88.5	57.0
60	96.7	81.1	42.8	98.0	90.1	63.0
平成2	97.1	82.6	46.9	98.3	91.3	67.8
7	97.2	83.3	48.2	98.4	91.6	70.2
12	97.5	84.7	52.5	98.6	92.6	74.5
13	97.6	85.1	53.5	98.6	92.8	75.3
14	97.7	85.4	54.2	98.6	92.9	75.9
15	97.6	85.3	54.5	98.6	93.0	76.3
16	97.7	85.7	55.2	98.7	93.0	76.8

注1) 平成12年までは、完全生命表による。

2) 昭和45年以前は、沖縄県を除く値である。

3) 生命表作成時点における死亡状況を一定不変とした場合の状況を表しており、現実の生存者の割合とは異なっている。

2. 少数例で何かいえないと？ 近代的な統計学の登場

大数の法則とはいうけれど、たくさんのデータを集めるのは大変である

できるだけ少ない・多くのデータでできるだけ少ない・多くの法則（結果）を得たい・・・

大数の法則にかなうぐらいのデータを集めることは困難なことも多い

自動車の耐久性テスト 少ない・多くの台数を破壊試験して、しかも正確なデータがほしい

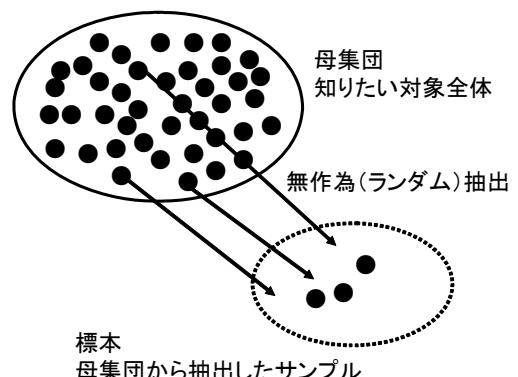
オオサンショウウオの食性を知りたい 数自体が少ない・いくらでもいる

猫のエイズの治療薬 効かないかもしれない副作用の強い薬は動物虐待かも？

それゆえできるだけ少数の・多数のデータでできるだけ少数の・多数の法則（結果）を得たい

標本（サンプル）から母集団を推定する 近代的な統計学の手法

母集団（調査対象すべて）からランダム（無作為）に取ったサンプル（母集団からの代表）であれば、統計学からどの程度の精度・誤差で判断できるかがわかる。



正しく抽出した標本から母集団を推定する実例と誤差

視聴率 標本サイズと誤差 関東地区で 1455 万世帯から 600 世帯
山陰地方で 45 万世帯 200 世帯をサンプリングする
視聴率が 20% と出たら、その誤差はどのくらい？どっちの精度が高い？

視聴率の誤差はサンプルの大きさに依存し、
母集団の大きさとサンプルの大きさの比はほとんど関与しない。誤差を大まかに見積もると右の表のようになる。真の視聴率と測定された視聴率との誤差は 95% の確率で以下の範囲内に収まることを右表は示す。

視聴率	標本数600	標本数200
5%・95%	±1.8%	±3.1%
10%・90%	±2.4%	±4.2%
20%・80%	±3.3%	±5.7%
30%・70%	±3.7%	±6.5%
40%・60%	±4.0%	±6.9%
50%	±4.1%	±7.1%

3. 正確なデータを取るために：標本の選び方は難しい

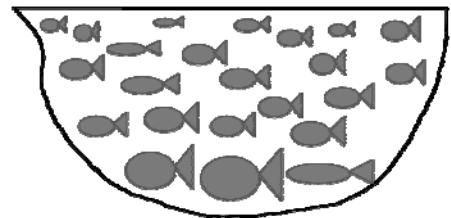
標本に要求されること

- 母集団を代表しているか（統計的な手法を適用するための条件）
- 精度が必要な程度あるか（サンプルの数が多ければ精度は高くなる）

★ 母集団を代表しているか インターネットを使って、世論調査したら・・・？

- 元気そうなウシばかりサンプリングしたら？
- 愛煙家の夫の副流煙を受けた妻の例

★ 池の魚を調査する例をもう一度考える。この池の魚で、大きな魚は底に住む性質がある。もし調査のときに、面倒だからと水面近くの魚ばかり調査したらどうなるだろうか？



無作為（ランダム）なサンプリングであることが要請される

無作為標本（ランダムサンプル）ならば

標本数が少數であっても母集団について代表値、精度などを統計的に推定できる。

D. 生物統計学・実験計画学とは

大数の法則に従って、データをたくさん取ればより正確なことがわかるとはいえるが、実験を何度も繰り返すことはたいへん手間かかる。したがって、なるべく少ないサンプルで結論を得たい。しかし、サンプルが少ないと誤差が大きくなる・・・

1. どのようにデータを取れば、精度よく、しかも少ない実験ですむのか？

不均一なところ（圃場、牛の集団）からどのように実験し、データを得るのか？

- ① 圃場によって地力が違うので、同じ品種でも収量が異なる。

- ② ヒトに栄養剤を与えた効果を知りたいが、体の大きさによって効果が違うそうだ。

- 不均一さの克服のためには
1. 精度を知る どの程度ばらついているのか?
 2. 傾向のある不均一さを偶然誤差に転化する
 3. 可能ならば不均一さによる誤差を除去して、精度を高める

2. 生物統計学・実験計画学の3つの柱

- ① 誤差の定量と制御（精度がよくなる・精度がわかる）
- ② 実験回数を少なくできる
- ③ 実験のデータの変動のうち、処理による意味のある部分と偶然誤差を分けることができる。
さらに処理の主効果と交互作用を検出できる。

E. 宿題

宿題はホームページ <http://www.ipc.shimane-u.ac.jp/food/kobayashi/biometrysukudai.html> を見てください。

宿題は所定のタブをプリントアウトして生物資源科学部2号館204室に提出してください。
締め切りは原則として**次回の授業の前日**（通常は、授業の翌週の月曜日）**午後1時まで**とします。

授業の前に前回の宿題を返却する。間違えた問題を訂正して、再提出することができる。再提出するときは、再提出となった元のレポートといっしょに再提出のレポートを提出すること。宿題の計算がおかしいときはデータを持ってくればチェックします。再提出の締め切りは1月31日とする。宿題の解答もホームページで公開します。再提出の時はこの解答を参考にしてもかまいません。ただし丸写し（そのままプリントアウト）はしないこと。

生物統計学予定表

1. 10月 5日 生物統計学とは？
2. 10月 12日 平均と分散・データの要約
3. 10月 19日 母集団と標本、確率分布
4. 10月 26日 二項分布、ポアソン分布、正規分布
5. 11月 2日 正規分布の特徴
6. 11月 9日 統計的推定
7. 11月 16日 統計的検定
8. 11月 30日 t分布とt検定
9. 12月 7日 カイ二乗分布・F分布
10. 12月 14日 分散分析その1 一元配置
11. 12月 21日 分散分析その2 二元配置
12. 1月 11日 相関分析
13. 1月 18日 回帰分析
14. 1月 25日 頻度の分析とデータのとり方
15. 2月 8日 期末試験