

環境統計学ふらす

# 第4.2回 モデル選択

---

高木 俊

shun.takagi@sci.toho-u.ac.jp

2013/11/29

# 予定

- 第1回： Rの基礎と仮説検定
- 第2回： 分散分析と回帰
- 第3回： 一般線形モデル・交互作用
- 第4.1回：一般化線形モデル
- 第4.2回：モデル選択
- 第5回： 一般化線形混合モデル
- 第6回： 多変量解析(12/5予定)

# 今日やること

- 統計編
  - モデル選択
  - モデルアベレージング
  - モデル選択の応用
- 表現編
  - 一般化線形モデル・モデル選択における表現

# モデル 選択

# 仮説検定とモデル選択

- 注目するモデル(仮説)が複数ある(M1・M2・M3・・・)とき、

**仮説検定**: 帰無仮説のもとで注目するモデル(より極端な結果)が得られる確率(P値)を計算し、それが十分に小さければ( $<0.05$ )そのモデルを良しとする

- 非常に厳しい基準(帰無仮説は棄却されにくい)
- 有意かどうかの議論しかできない

**モデル選択**: それぞれのモデルの良さ(後述)をある基準で数値化し、度のモデルがよりふさわしいかを議論する

- 相対的により良いモデルを選ぶことができる
- (逆に有意かどうかの議論はできない)

# 検定とモデル選択の使い分け

- 仮説検定

実験など明確な仮説のもとに取得したデータを解析する場合

→「ある(想定している)要因が効いているか否かが知りたい」

- モデル選択

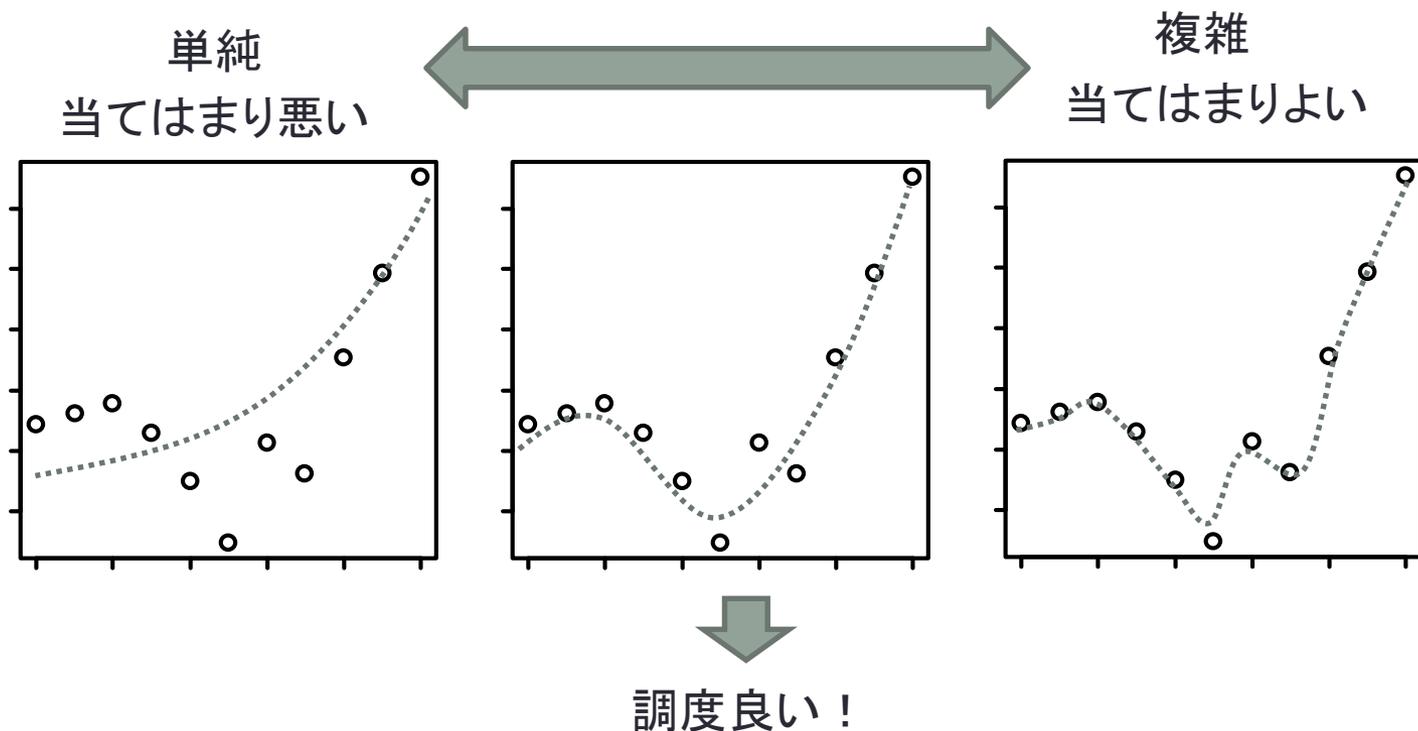
野外パターンの調査など、解析から考えられる仮説を絞り込む場合

→「どのような要因が効いているかを絞り込みたい」

(野外パターンデータでも想定する要因の影響を検討できる形で調査デザインが組まれている場合、検定を行うことが多い)

# 良いモデルとは

- より少ない変数で全体のトレンドをうまく記述できているモデルは予測力が高い



# モデル選択の基準:AIC

- 赤池情報量基準(AIC)  
モデルが単純なほど・当てはまりが良いほど低い値を示す

$$AIC = -2\ln L + 2k$$

低いほど良い

対数尤度

パラメータ数

候補となるモデルの中でAICが最も小さくなるモデルが、少ない変数で当てはまりが良い(節約的に説明できる・予測力が高い)モデルとして選択される。

- 一般化線形モデルだけでなく、一般線形モデルでも使える
- AICに類似した指標としてBIC(変数増加時のペナルティーのかけ方が異なる)やAIC<sub>C</sub>(n数が少ない場合の補正)も用いられる

# AICの値

- AICは相対値(モデル間のAICの差)で議論し、絶対値はあまり意味を持たない
- AICの比較は説明変数の異なるモデル間で行う(目的変数や分布の異なるモデル間での比較はできない)

AICの差 ( $\Delta AIC$ )	支持の程度
0-2	信頼出来る
4-7	相当に怪しい
>10	全く信頼出来ない

(例)

	モデル	$\Delta AIC$
AIC最小	個体数～餌＋生息場所	0
	個体数～生息場所	0.3
	個体数～餌	2.4
	個体数～1	7.2
	個体数～餌×生息場所	7.3

生息場所は個体数に最も影響する要因

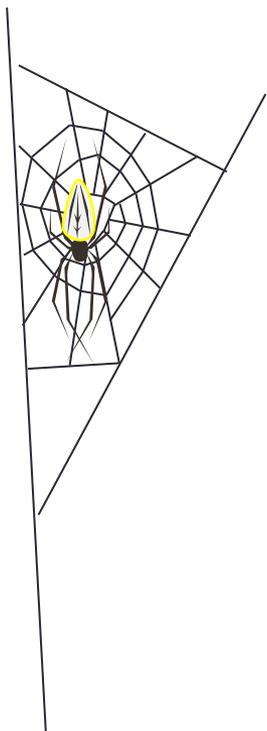


餌も若干影響するが単体での影響は強くない

交互作用の効果は無さそう

# 実例：重回帰とモデル選択

- クモの個体数はどのような要因で決まっているか



説明変数	内容
altitude	標高
PC1	植生の主成分1
PC2	植生の主成分2
g_height	草丈
f_200	周囲200m以内の森林率
e_200	周囲200m以内の林縁長
gr_200	周囲200m以内の草地率

data4.3.csv

目的変数: abundance 負の二項分布のGLMで解析

影響しそうな様々な要因の中から重要なものを絞り込みたい

```
model4.3 <- glm.nb(abundance ~ altitude + PC1 + PC2 + g_height + f_200 + e_200 + gr_200, data4.3)
```

# フルモデル(全説明変数入り)

```
> model4.3<- glm.nb(abundance~altitude+PC1+PC2+g_height+f_200+e_200+gr_200,data4.3)
> summary(model4.3)
```

```
Call:
glm.nb(formula = abundance ~ altitude + PC1 + PC2 + g_height +
  f_200 + e_200 + gr_200, data = data4.3, init.theta = 10.73447672,
  link = log)
```

```
Deviance Residuals:
    Min       1Q   Median       3Q      Max
-2.47297  -0.75209  -0.05157   0.51657   1.73451
```

```
Coefficients:
              Estimate Std. Error z value Pr(>|z|)
(Intercept)  2.5866296  0.4364805   5.926 3.1e-09 ***
altitude     -0.0009339  0.0007645  -1.222 0.22183
PC1           0.0137947  0.0166313   0.829 0.40685
PC2          -0.0062590  0.0421078  -0.149 0.88184
g_height     -0.0074983  0.0095195  -0.788 0.43089
f_200         0.5981511  0.3113102   1.921 0.05468 .
e_200         0.0003955  0.0001274   3.103 0.00191 **
gr_200       -0.9125296  1.1426795  -0.799 0.42453
---

```

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
(Dispersion parameter for Negative Binomial(10.7345) family taken to be 1)
```

```
Null deviance: 58.363 on 34 degrees of freedom
Residual deviance: 36.486 on 27 degrees of freedom
AIC: 238.69
```

```
Number of Fisher Scoring iterations: 1
```

```
Theta: 10.73
Std. Err.: 4.49
```

```
2 x log-likelihood: -220.692
```

#係数が有意でないものも多い  
→もっと説明変数を減らしてシンプルなモデルにできそう

#AICはここに出力  
#AIC(model4.3)でも見られる

# PC1を抜いてみる

```
> AIC(model4.3)
[1] 238.6923
> model4.3pc1<- glm.nb(abundance~altitude+PC2+g_height+f_200+e_200+gr_200,data4.3)
> AIC(model4.3pc1)
[1] 237.3971
```

フルモデルのAIC(238.7)に比べ、PC1抜きのモデルのAIC(237.4)のほうが若干低くなった。

→PC1を抜いたほうが節約的なモデル

このような作業を繰り返すことで、最もAICが低くなる説明変数のセットを選択することができる

# 変数選択: ステップワイズ法

- 説明変数の選択を手作業で行うのは大変

説明変数7個:  $2^7=128$ 通りのモデルができる

**ステップワイズ法**: AICが低くなるように、変数をひとつずつ減らしていく(変数減少法)もしくは増やしていく方法(変数増加法)

step() で実行可能

```
step(model4.3)
```

```
⋮
```

選択されたモデル `glm.nb(abundance~e_200, data4.3)`  
AIC: 231.51

# 変数選択: 総当り法

- ステップワイズ法は計算は速いが、すべての組み合わせを考慮していないので、他の候補モデル( $\Delta AIC < 2$ )がわからない・本当に最小AICのモデルが選択できている確証はない  
→ 128通り総当りで計算してみる

- ① パッケージMuMInのdredge()を使う

```
library(MuMIn)
select<- dredge(model4.3,rank="AIC")
subset(select,delta<4)
```

- ② 自作関数のglm.nb.list()を使う

```
source("glm.nb.list.v2013.R")
glm.nb.list(model4.3,"model4.3.csv")
```

保存ファイル名指定

glm.nb用に作ってあるので、他の関数(glmやlmer)の場合、異なる関数を使います(主要なものは作ってあるので相談してくれれば差し上げます)。

# 結果 (dredge)

AICの低い順に選択されたモデルの一覧が表示される

```
Global model call: glm.nb(formula = abundance ~ altitude + PC1 + PC2 + g_height +
  f_200 + e_200 + gr_200, data = data4.3, init.theta = 10.73447672,
  link = log)
```

←元のモデル

---

Model selection table

	(Int)	alt	e_200	f_200	g_hgh	gr_200	PC1	PC2	df	logLik	AIC	delta	weight
3	2.290		0.0004603						3	-112.756	231.5	0.00	0.097
7	2.183		0.0004255	0.2971					4	-111.964	231.9	0.42	0.079
8	2.208	-9.184e-04	0.0004186	0.5347					5	-111.227	232.5	0.94	0.061
67	2.265		0.0004559				-0.02698		4	-112.469	232.9	1.43	0.048
19	2.380		0.0004671		-0.7984				4	-112.512	233.0	1.51	0.046
71	2.157		0.0004208	0.2982			-0.02718		5	-111.661	233.3	1.81	0.039
23	2.277		0.0004320	0.3048	-0.8592				5	-111.670	233.3	1.83	0.039
35	2.276		0.0004436			0.005403			4	-112.677	233.4	1.84	0.039
39	2.142		0.0003905	0.3378		0.009889			5	-111.702	233.4	1.89	0.038
11	2.387		0.0004664		-0.002141				4	-112.727	233.5	1.94	0.037
4	2.297	-5.437e-05	0.0004616						4	-112.752	233.5	1.99	0.036
24	2.312	-9.581e-04	0.0004254	0.5528	-0.9377				6	-110.866	233.7	2.22	0.032

///(略)

- ↑  
それぞれの変数に関して選択された場合、その係数の推定値が入る
- カテゴリー変数の場合、選択されると“+”

↑  
各モデルのAIC、 $\Delta$ AICなど

# 結果 ( glm.nb.list )

- 指定したcsvにモデル選択の結果が格納される
- Estimate・SE両方表示

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	
1		formulas	AIC	deltaAIC	logLiks	(Intercept)	(Intercept)	altitude_Est	altitude_SE	PC1_Estimate	PC1_SE	PC2_Estimate	PC2_SE	g_height_Est	g_height_SE	f_200_Estimate	f_200_SE	e
2	3	abundance ~ e_200()	231.51127	0	-112.7556	2.2903217	0.1292294	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	0
3	7	abundance ~ f_200 + e_200()	231.92723	0.4159514	-111.9636	2.1828926	0.1516459	NA	NA	NA	NA	NA	NA	NA	NA	0.2970656	0.2365284	0
4	71	abundance ~ altitude + f_200 + e_200()	232.45346	0.9421816	-111.2267	2.2082452	0.1504346	-0.000918	0.0007469	NA	NA	NA	NA	NA	NA	0.5346642	0.3051216	0
5	19	abundance ~ PC2 + e_200()	232.93739	1.4261212	-112.4687	2.2653335	0.1318413	NA	NA	NA	NA	-0.026979	0.0354336	NA	NA	NA	NA	0
6	4	abundance ~ e_200 + gr_200()	233.02317	1.5118949	-112.5116	2.3800953	0.1843039	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	0
7	23	abundance ~ PC2 + f_200 + e_200()	233.32202	1.810747	-111.661	2.1572704	0.1541688	NA	NA	NA	NA	-0.027179	0.0350609	NA	NA	0.2982142	0.235081	0
8	8	abundance ~ f_200 + e_200 + gr_200()	233.34049	1.8292164	-111.6702	2.2766696	0.1984215	NA	NA	NA	NA	NA	NA	NA	NA	0.3048187	0.236146	0
9	35	abundance ~ PC1 + e_200()	233.3542	1.8429247	-112.6771	2.2763666	0.1337436	NA	NA	0.0054027	0.0139364	NA	NA	NA	NA	NA	NA	0
10	39	abundance ~ PC1 + f_200 + e_200()	233.40305	1.8917761	-111.7015	2.142327	0.1604299	NA	NA	0.0098894	0.0140183	NA	NA	NA	NA	0.3377821	0.2411046	0
11	11	abundance ~ g_height + e_200()	233.45443	1.9431551	-112.7272	2.3866822	0.4073592	NA	NA	NA	NA	NA	NA	-0.002141	0.0084882	NA	NA	0
12	67	abundance ~ altitude + e_200()	233.50303	1.991754	-112.7515	2.2969104	0.145527	-5.44E-05	0.0005828	NA	NA	NA	NA	NA	NA	NA	NA	0
13	72	abundance ~ altitude + f_200 + e_200 + gr_200()	233.73125	2.2199736	-110.8656	2.3119794	0.1952783	-0.000958	0.0007437	NA	NA	NA	NA	NA	NA	0.5528276	0.3051841	0
14	15	abundance ~ g_height + f_200 + e_200()	233.88862	2.3773471	-111.9443	2.2612534	0.4115597	NA	NA	NA	NA	NA	NA	-0.001728	0.0084097	0.2955856	0.2365512	0
15	103	abundance ~ altitude + PC1 + f_200 + e_200()	234.10255	2.5912751	-111.0513	2.1743581	0.1611389	-0.000863	0.0007575	0.0080185	0.0139894	NA	NA	NA	NA	0.5535656	0.3042532	0
16	87	abundance ~ altitude + PC2 + f_200 + e_200()	234.16416	2.6528883	-111.0821	2.1880338	0.1546192	-0.000828	0.0007674	NA	NA	-0.018928	0.0356023	NA	NA	0.5121267	0.3076826	0
17	79	abundance ~ altitude + g_height + f_200 + e_200()	234.29652	2.7852472	-111.1493	2.366533	0.4118984	-0.000967	0.000758	NA	NA	NA	NA	-0.003465	0.0083483	0.5444382	0.3067787	0
18	27	abundance ~ PC2 + g_height + e_200()	234.62433	3.1130545	-112.3122	2.4993873	0.4200786	NA	NA	NA	NA	-0.034943	0.0375429	-0.005358	0.0090129	NA	NA	0
19	40	abundance ~ PC1 + f_200 + e_200 + gr_200()	234.65473	3.1434522	-111.3274	2.2424171	0.2024881	NA	NA	0.0113472	0.013997	NA	NA	NA	NA	0.3527271	0.2406991	0
20	20	abundance ~ PC2 + e_200 + gr_200()	234.66033	3.1490555	-112.3302	2.3397292	0.1938512	NA	NA	NA	NA	-0.022145	0.0364413	NA	NA	NA	NA	0
21	36	abundance ~ PC1 + e_200 + gr_200()	234.79673	3.2854607	-112.3984	2.3699331	0.1858412	NA	NA	0.0064907	0.0138971	NA	NA	NA	NA	NA	NA	0
22	51	abundance ~ PC1 + PC2 + e_200()	234.93122	3.4199469	-112.4656	2.2635111	0.1341785	NA	NA	0.0011777	0.0156378	-0.02564	0.0399057	NA	NA	NA	NA	0
23	83	abundance ~ altitude + PC2 + e_200()	234.93633	3.4250593	-112.4682	2.262775	0.1514409	1.96E-05	0.0005919	NA	NA	-0.027172	0.0362044	NA	NA	NA	NA	0
24	24	abundance ~ PC2 + f_200 + e_200 + gr_200()	234.97251	3.4612385	-111.14863	2.2369734	0.2073592	NA	NA	NA	NA	-0.021877	0.0360243	NA	NA	0.3040831	0.2349789	0
25	12	abundance ~ g_height + e_200 + gr_200()	234.99469	3.4834133	-112.4973	2.4460242	0.4170381	NA	NA	NA	NA	NA	NA	-0.001516	0.008518	NA	NA	0
26	47	abundance ~ PC1 + g_height + f_200 + e_200()	235.00162	3.4903437	-111.5008	2.4088461	0.4301132	NA	NA	0.014759	0.0156602	NA	NA	-0.006311	0.0094289	0.3525129	0.2421344	0
27	68	abundance ~ altitude + e_200 + gr_200()	235.01249	3.501219	-112.5062	2.3877958	0.1959745	-6.17E-05	0.0005791	NA	NA	NA	NA	NA	NA	NA	NA	0
28	31	abundance ~ PC2 + g_height + f_200 + e_200()	235.04744	3.5361672	-111.5237	2.3734826	0.4228824	NA	NA	NA	NA	-0.034507	0.0371546	-0.004917	0.0089265	0.2945073	0.2347561	0
29	43	abundance ~ PC1 + g_height + e_200()	235.11348	3.6022103	-112.5567	2.4919396	0.4328638	NA	NA	0.0090978	0.0154533	NA	NA	-0.004999	0.0094445	NA	NA	0
30	55	abundance ~ PC1 + PC2 + f_200 + e_200()	235.14138	3.6301056	-111.5707	2.1376845	0.160419	NA	NA	0.006435	0.0157786	-0.01984	0.0395714	NA	NA	0.3244379	0.2415824	0
31	104	abundance ~ altitude + PC1 + f_200 + e_200 + gr_200()	235.25268	3.7414054	-110.6263	2.2811567	0.2009005	-0.000894	0.0007523	0.0093893	0.0139499	NA	NA	NA	NA	0.5759362	0.3042684	0

# モデル選択の結果

- ベストモデル(AIC最小)で選択された変数  
e\_200: 半径200m以内の林縁長
- 他の上位モデル( $\Delta AIC < 2$ )で選択された変数とその回数  
e\_200(11)  
f\_200(5): 半径200m以内の森林率  
altitude(2): 標高  
PC2(2): 植生の第2主成分(シダ植物少ないほど高い値)  
gr\_200(2): 半径200m以内の草地面積  
PC1(2): 植生の第1主成分(grass多いほど高い値)  
g\_height(1): 草丈

# 解釈

- 林縁長単独のモデルが**ベストモデル**
- **上位モデル**ではすべて林縁長を含むモデルが選ばれている  
→ 林縁長が最も強く効いている要因
- 森林率は比較的上位のモデルで選ばれている割合が高い
- 林延長を含まない森林率のみのモデルは上位に選ばれない  
→ 森林率も林縁長を考慮すれば影響力のある変数(ただし単独での説明力は高くない)
- その他の要因は単独で強く効いているものはない  
→ 多少は個体数に影響するがそれほど影響力強くない

# モデル選択の結果

モデル選択では

- どのモデルが選択されたか
- 選択されたモデルにおける係数の推定値はどの程度かの二つが主な結果となる

モデル選択と検定を同時に行っているものもあるが、全く別の考えなのでモデル選択を行った場合は本来検定を行わなくて良い

# 結果の表現例

表1. 選択されたモデル( $\Delta AIC < 2$ )の各変数の係数の推定値と標準誤差

$\Delta AIC$	森林面積		林縁長		植生PC1		植生PC2	
	Estimate	SE	Estimate	SE	Estimate	SE	Estimate	SE
0	2.13	0.03	1.22	0.01	—	—	—	—
0.2	—	—	1.24	0.02	—	—	—	—
0.8	2.14	0.04	1.24	0.02	—	—	0.03	0.01
1.4	2.11	0.04	1.22	0.02	0.04	0.02	—	—
1.6	2.15	0.04	1.23	0.03	0.04	0.02	0.03	0.01
1.9	—	—	1.24	0.03	0.04	0.04	0.04	0.03

(数値は適当)

# 候補モデルの要約: モデルアベレージング

- 複数ある候補モデル(上位モデル)の結果をすべて示すのではなく、それらの平均的な効果を要約するためにモデルアベレージング(モデル平均化)を行う場合がある

## モデルアベレージングの手順

1. モデル選択を行い、候補となるモデルを絞り込む( $\Delta AIC > 4$ など)
2.  $\Delta AIC$ を基準に候補モデルの重み付けを行う(Akaike weight)
3. 各変数の推定値の重み付け平均を計算する

$$\text{Akaike Weight } w_i = \frac{\exp\left(-\frac{1}{2}\Delta_i\right)}{\sum_{r=1}^R \exp\left(-\frac{1}{2}\Delta_r\right)}$$

# model.avgによる実行

```
summary(model.avg(select, subset=delta<4))
```

#delta<4のモデルで平均化

(略)

```
Model-averaged coefficients:
      Estimate Std. Error Adjusted SE z value Pr(>|z|)
(Intercept)  2.2844432   0.2590055   0.2682936  8.515 < 2e-16 ***
e_200        0.0004365   0.0001243   0.0001291  3.381 0.000722 ***
f_200        0.3992940   0.2891835   0.2992486  1.334 0.182098
altitude     -0.0006203   0.0008152   0.0008404  0.738 0.460428
PC2          -0.0260130   0.0368250   0.0383024  0.679 0.497045
gr_200       -0.8351350   1.1212113   1.1667511  0.716 0.474128
PC1          0.0082295   0.0149242   0.0155081  0.531 0.595657
g_height     -0.0034938   0.0089628   0.0093135  0.375 0.707561
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

平均化モデル  
の係数表

```
Full model-averaged coefficients (with shrinkage):
(Intercept)      e_200      f_200      altitude      PC2      gr_200      PC1      g_height
 2.28444316  0.00043646  0.20945214 -0.00018385 -0.00621017 -0.21456714  0.00206968 -0.00076694
```

```
Relative variable importance:
 e_200  f_200 altitude  gr_200  PC1  PC2 g_height
 1.00  0.52   0.30   0.26   0.25 0.24 0.22
```

変数の相対重要性(それぞれの変数に対して、Akaike weightを合計したもの)

# モデル選択の応用: 多重バッファ解析

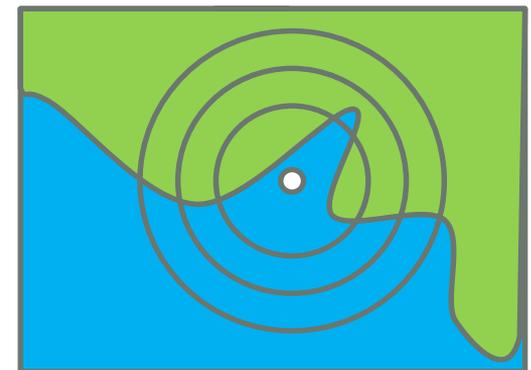
- 生物の分布や個体数のモデリングにおいて、局所スケール要因(その場の環境)と景観スケール要因(周囲の環境)の両方を考慮する事がある

例) 局所: その場所の草丈

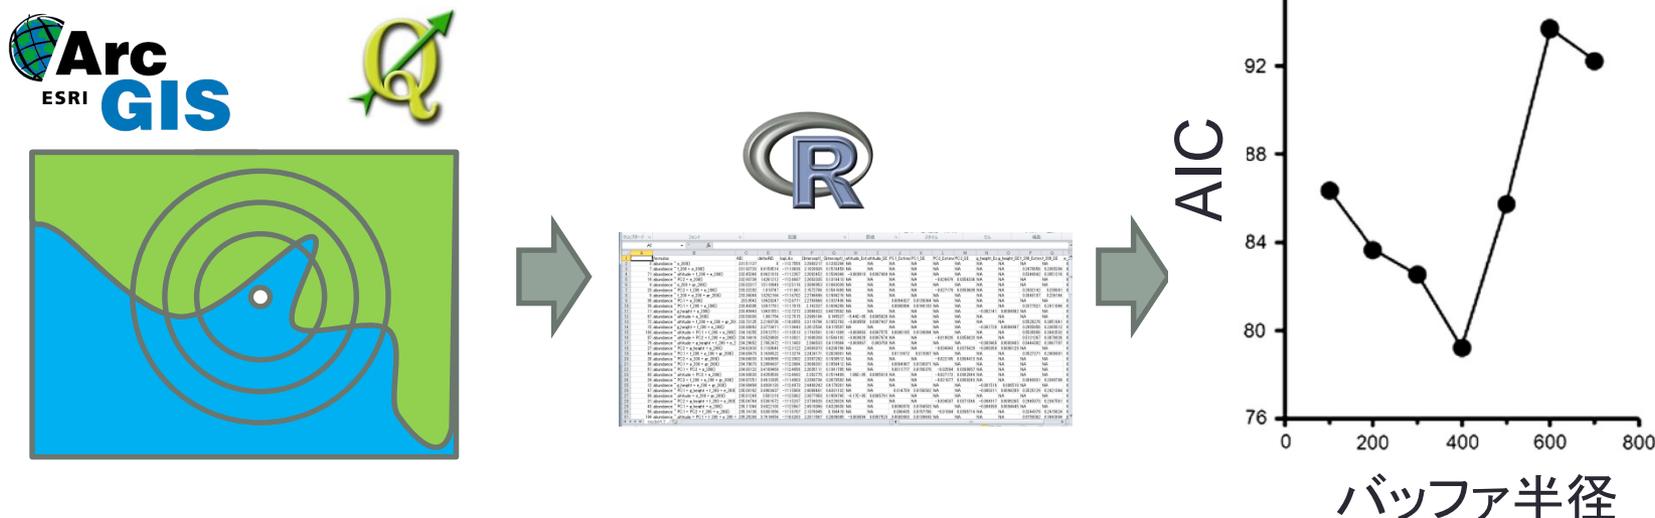
景観: 周囲**200m**以内の森林率

- この時どの程度のスケールでの環境要因が効いてくるかを、モデル選択により探索することができる

周囲100mと200mと300mの森林率のどれが最も分布をよく説明できるか？



# 多重バッファ解析の手順



1. GISを用いて調査地点から複数のスケールでバッファを発生させる  
(例: 半径100m~1500mまで100m刻みで15個のバッファ)
2. それぞれのスケールで抽出した環境要因を説明変数としたモデルを作り、それぞれのスケールにおいて、モデル選択を行う
3. 各スケールのベストモデルのAICを比較し、最もAICが低くなるスケールを特定する

# モデル選択:まとめ

- 仮説検証ではなく仮説探索型のデータにおいて、予測力の高い説明変数の絞込みを行う上で有効
  - 異なる種類の説明変数だけでなく、異なる指標で計算した同じ種類の説明変数(異なるスケールで抽出した環境変数など)を用いたモデル比較にも使える
1. 見たい説明変数をすべて含んだモデルを作成
  2. 説明変数総当りでモデル選択
  3. 必要に応じてモデルアベレージング

# 一般化線形モデル モデル選択の 方法・結果表現

# 一般線形モデルと共通の部分

- 説明変数がカテゴリカル型の場合（いわゆる分散分析）

→ (LM) 分散分析表

(GLM) 尤度比検定（逸脱度分析）の表

カテゴリー（処理）の効果は有意であるか

- 説明変数に連続変数が含まれる場合（いわゆる回帰）

→ (LM) 係数表 + 分散分析表

(GLM) 係数表 + 尤度比検定の表

↑  
推定結果

どういった関係にあるか  
（+、-、一山など）

↑  
検定結果

関係は有意であるか

\*モデル選択の場合は普通検定しない

# 例： 係数表 + 尤度比検定 (GLM)

各説明変数に対する係数の推定値および尤度比検定の結果

説明変数	推定値	標準誤差	$\chi^2$	P値
切片	-2.532	5.660		
低木	0.07926	0.1283	4.116	0.04
餌昆虫	1.5105	3.158	0.322	0.57
低木 × 餌昆虫	-0.02799	0.07208	0.147	0.70

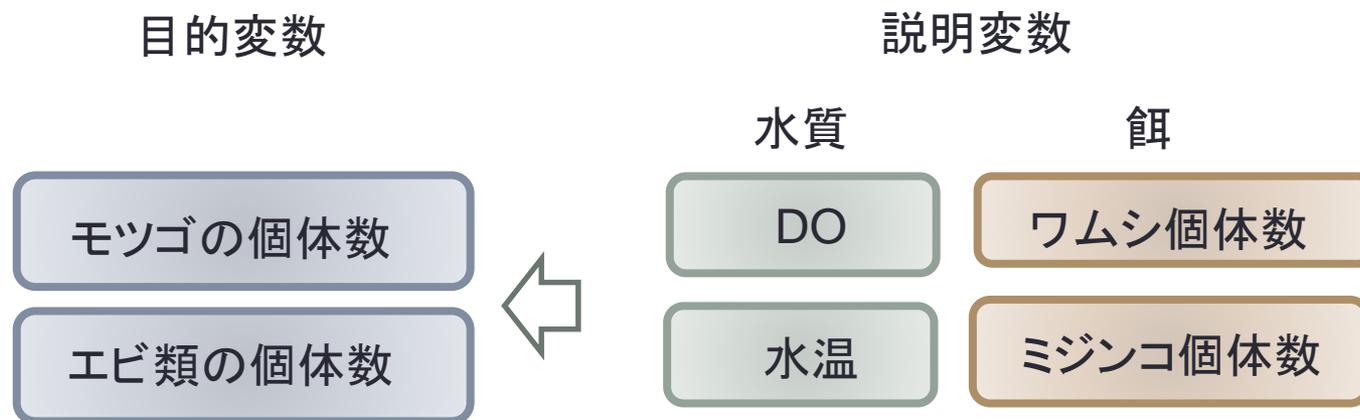
(切片に関しては、特に興味が無い場合書かなくてもよい)

# 方法の表現・GLM

- GLMを用いる際には、**誤差構造(分布)**と**リンク関数**を明記すること。
- Yを目的変数、X1・X2を説明変数とする一般化線形モデルによる解析を行った。目的変数はポアソン分布に従うと仮定し、リンク関数はlogとした。
- 個体の生存または死亡を目的変数とした。リンク関数をlogitとし、誤差構造に二項分布を仮定した一般化線形モデルにより解析を行った。
- 要旨等でスペースがない場合は「一般化線形モデル(誤差構造:ポアソン、リンク関数:log)で解析した。」

# 方法の表現(プレゼン)

一般化線形モデル(誤差構造:負の二項分布、リンク関数:log)



説明変数総当り、AIC基準でモデル選択を行った

# 結果の表現(プレゼン)

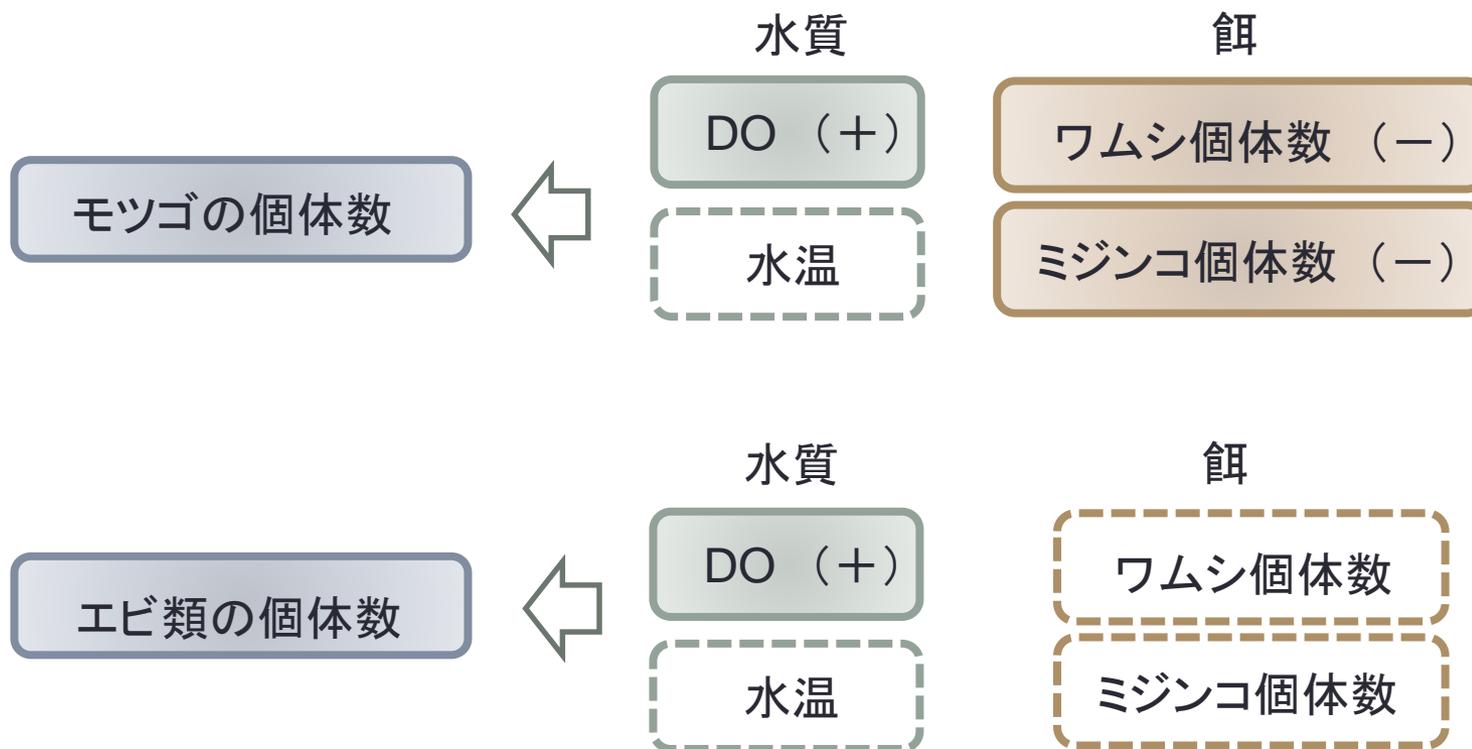
- 細かい推定値を一覧表にするのは、論文においては良い表現だが、プレゼン(ポスター)においてはわかりにくいことも

(表現の例)

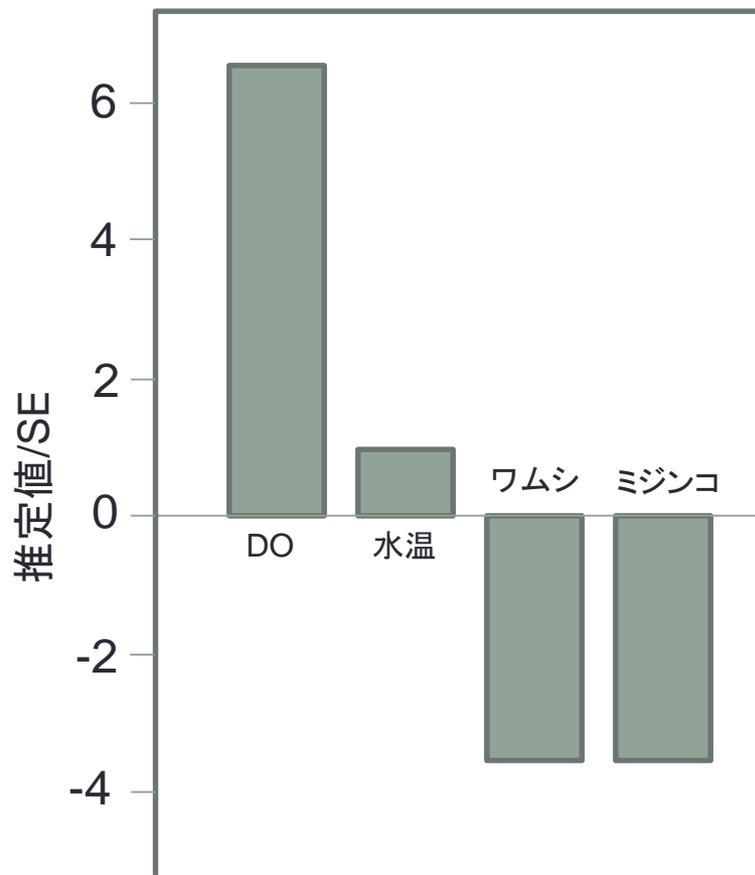
1. 係数は符号のみを示す
2. 二次項を含む(一山型)など、特に回帰曲線の形が重要となる係数に関しては、ベストモデルもしくは平均モデルの推定値を用いて予測線を示す
3. ベストモデルもしくは平均モデルの「推定値/SE」やモデルアベレージングを行い、相対重要度( $\sum wi$ )を図示する

# 結果の表現(プレゼン・例)

ベストモデルで選択された変数



## 結果の表現(プレゼン・例)



$\Delta AIC < 4$  の平均化モデルにおける各説明変数に対する係数の推定値/SE