

# STATISTIČKE ANALIZE

Statističke analize služe **procjeni (estimation)** parametara populacija te **testiranju hipoteza**.

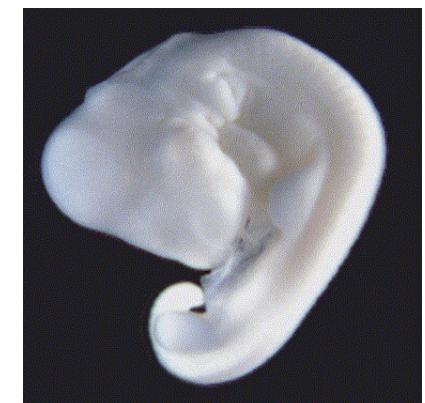
**Procjena** – utvrđivanje kvantitativne vrijednosti parametra (variable) populacije na temelju uzorka

- Prosječna veličina srdele u populacijama južnog i sjevernog Jadrana
- Bazalna ekspresija CyP1A2 gena u stanici jetre zdravog muškarca
- Oksidativna oštećenja u mozgu nakon 2 sata korištenja mobilnog telefona na frekvenciji 900 MHz



**Hipoteza** je tvrdnja o parametru (varijabli) populacije.

- Srdele u južnom Jadranu su manje nego one u sjevernom
- Srdele u jadranu pokazuju sezonalnost u veličini.
- Izloženost parama benzinskih motora u okolišno relevantnim koncentracijama tijekom 8 sati uzrokuje povišenu ekspresiju CyP1A2 gena u stanici jetre zdravog muškarca
- Inhibicija Tbx4 gena utječe na razvoj udova u embriju kokoške.



Statističke metode ukazuju i na **podudarnost hipoteze o parametru populacije i podacima saklupljenim o uzorku**. Hipoteza je neophodna za biološka istraživačka pitanja i omogućuje utvrđivanje uzročno-posljedičnih odnosa, a testiranje hipoteze je informativnije od procjene.

# TESTIRANJE HIPOTEZA

PITANJE – **HIPOTEZA/VARIJABLE** – DIZAJNIRANJE EKSPERIMENTA (UZORAK) – TESTIRANJE HIPOTEZE/ANALIZA PODATAKA



"I already wrote the paper.  
That's why it's so hard to  
get the right data."

# TESTIRANJE STATISTIČKIH HIPOTEZA

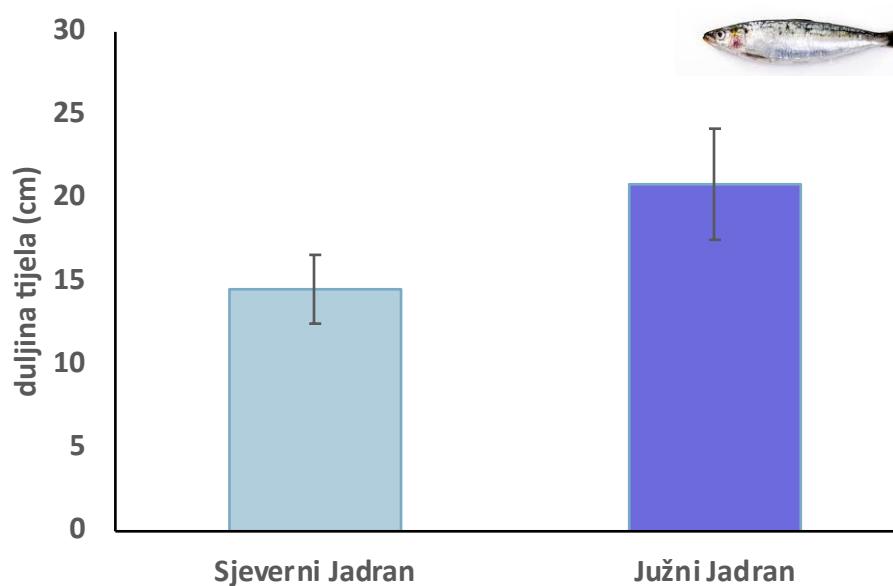
PITANJE – **HIPOTEZA/VARIJABLE** – DIZAJNIRANJE EKSPERIMENTA (UZORAK) – TESTIRANJE HIPOTEZE/ANALIZA PODATAKA

**Nul hipoteza ( $H_0$ )** – nema učinka među varijablama, nema razlike među populacijama

**Nul hipoteza se može samo odbiti, ne potvrditi**

**Odbijanjem nul hipoteze (statističkim testom)** zaključujemo da podaci podržavaju alternativnu hipotezu ( $H_A$ ) – populacije se razlikuju ili nezavisna varijabla ima učinak na zavisnu

- Inhibicija *Tbx4* gena utječe na razvoj udova u embriju kokoške.  
Nul hipoteza je Inhibicija *Tbx4* gena *ne utječe* na razvoj udova u embriju kokoške.
- Srdele u južnom Jadranu su veće nego one u sjevernom.  
Nul hipoteza je srdele u južnom i sjevernom Jadranu *ne razlikuju* se po veličini.



Procjena (*estimation*) nam daje uvid u magnitudu učinka.

## TESTIRANJE HIPOTEZA

PITANJE – **HIPOTEZA/VARIJABLE** – DIZAJNIRANJE EKSPERIMENTA (UZORAK) – TESTIRANJE HIPOTEZE/ANALIZA PODATAKA

Testiranjem statističke hipoteze uspoređujemo koliko podaci odstupaju od obrazaca koje očekujemo ako je nulta hipoteza točna!

Znanstvena hipoteza zapravo je pravo biološko pitanje, i znanstvenici postavljaju prepostavke koje onda testiraju kroz statističke hipoteze.

Npr. znanstvena hipoteza bi bila da se srdele u Jadranu razlikuju po veličini, s prepostavkom da su veće u južnom Jadranu zbog manje intenzivnog izlova

$H_0$  - *srdele u južnom i sjevernom Jadranu ne razlikuju se po veličini*

$H_{A1}$  - *srdele u južnom i sjevernom Jadranu razlikuju se po veličini*

$H_{A2}$  - *srdele u južnom Jadranu su veće od srdela u sjevernom Jadranu*

**Alternativna hipoteza može biti jednostrana ( $H_{A2}$ ) ili dvostrana ( $H_{A1}$ ) (one and two tailed)**

Dvostrana hipoteza uključuje vrijednosti na obje strane distribucije (srdele u južnom Jadranu su veće od srdela u sjevernom Jadranu i srdele u sjevernom Jadranu su veće od srdela u Sjevernom Jadranu). Ukoliko postoji mogućnost za obje vrijednosti uvijek se koriste dvostrane hipoteze!

## TESTIRANJE HIPOTEZA

- Parametri koje testiramo mogu biti srednje vrijednosti, varijance, korelacije, proporcije...
- Iznosimo najčešće vrijednost statističkog testa, veličine uzoraka, deskriptivnu statistiku (zbog procjene učinka) i  $P$ - vrijednost

*Primjer: imaju li krastače veću preferencu korištenju jednog prednjeg uda?*

*18 krastača donešeno u labos, zavezan im je balon za glavu i bilježeno je s kojom prednjom nogom miču balon s glave*



www.shutterstock.com - 1074389033

Bisazza et al. 1996. Right-pawedness in toads. *Nature* 379: 408.

$H_0$ : učestalost korištenja prednjih udova **je jednaka** u populaciji (i.e.,  $p = 0.5$ ).

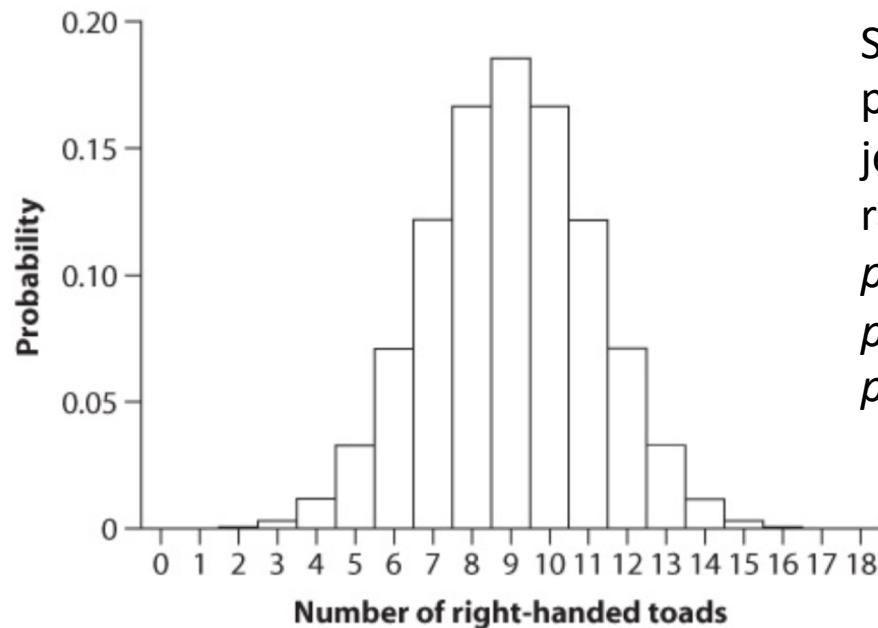
$H_A$ : učestalost korištenja prednjih udova **nije jednaka** u populaciji (i.e.,  $p \neq 0.5$ ).



**Dvostrani test – biološki je značajno i ako preferencijalno koriste lijevu i desnu nogu (frekvencija  $p$  za desnu nogu  $<0.5$ , frekvencija  $p$  za desnu nogu  $>0.5$ )**

$H_0$  – 9 krastača koristi desnu, devet lijevu nogu ( $p=0.5$ )

*Rezultat mjerenja – 14 krastača koristilo je desnu nogu! JE LI OVO SLUČAJAN ILI ZNAČAJAN REZULTAT Potrebno je utvrditi distribuciju mogućih uzoraka za  $H_0$  (nul distribucija)*



Slučajnim uzorkovanjem 18 jedinki iz populacije krastača s jednakim preferencijama korištenja udova moguće je u uzorku dobiti od 0 do 18 jedinki koje koriste desnu nogu, ali je vjerojatnost svakog od tih događaja različita !

$p(0) = 0.000004$  (4 slučajna uzorkovanja od 1.000.000 daje ovaj rezultat)

$p(9) = 0.1855$

$p(18) = 0.000004$

**Figure 6.2-1**

Whitlock et al., *The Analysis of Biological Data*, 2e, © 2015 W. H. Freeman and Company

# *p* VRIJEDNOST

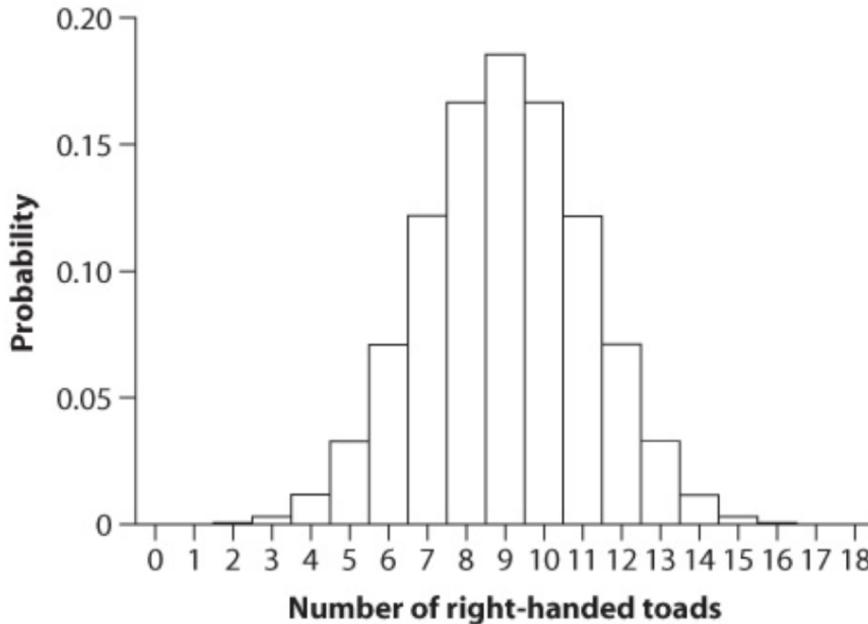
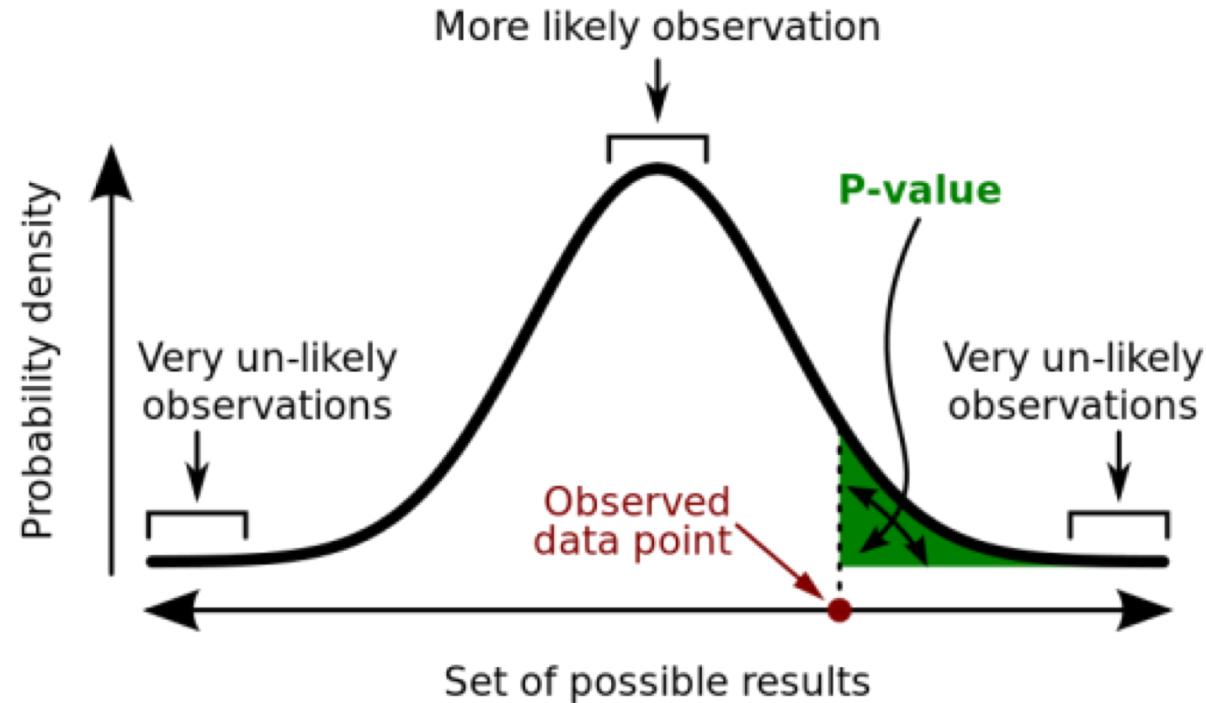
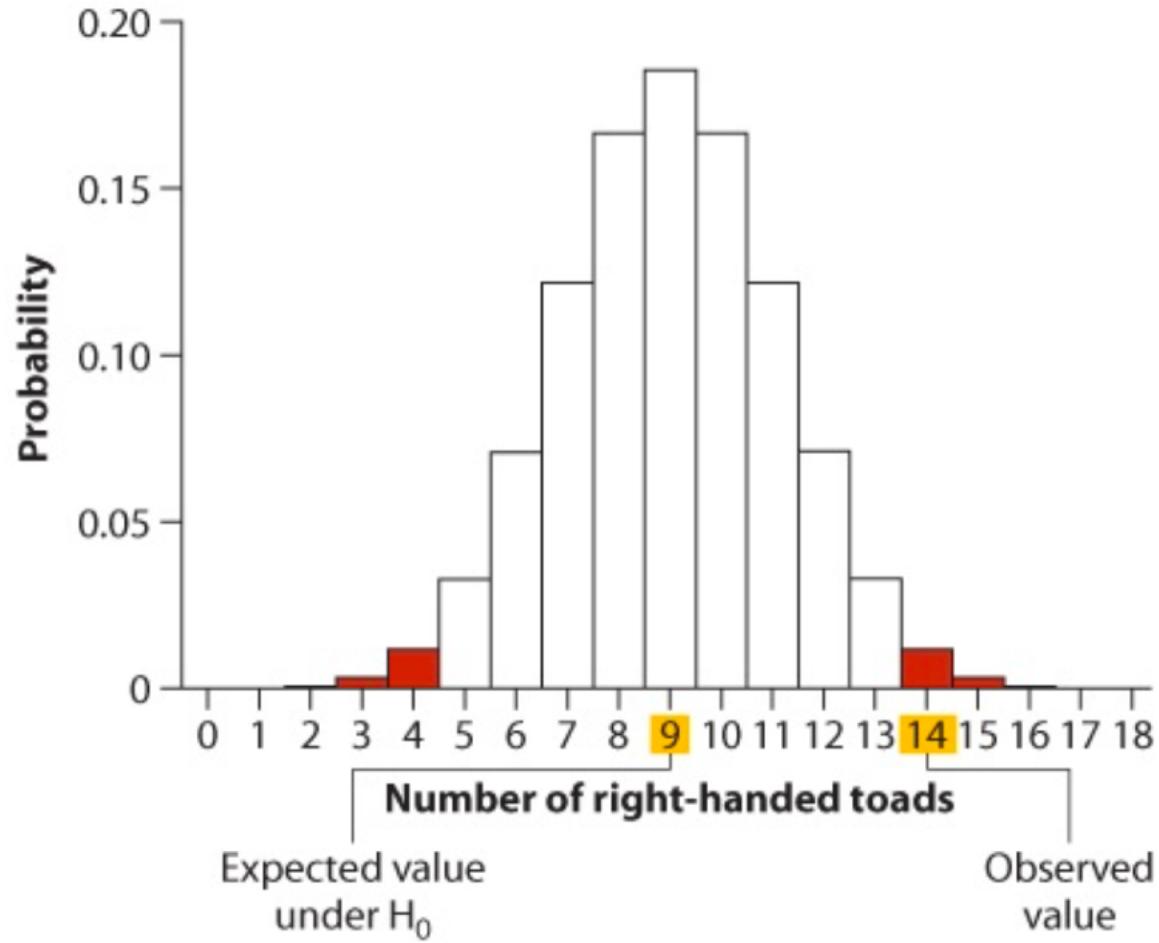


Figure 6.2-1

Whitlock et al., *The Analysis of Biological Data*, 2e, © 2015 W. H. Freeman and Company



- *P* vrijednost nije vjerojatnost da je nul hipoteza točna ili kriva, nego MJERA NEKOMPATIBILNOSTI PODATAKA S STATISTIČKIM MODELOM (u širokom smislu vjerojatnost dobivanja tog rezultata ukoliko je nul hipoteza točna)
- $\alpha$  je statistička značajnost testa, u biologiji je često 0.05
- *P* vrijednost govori o snazi dokaza da je nul hipoteza točna ili kriva, ali ne daje informaciju o snazi učinka!!



**p<0.05  
ODBACUJEMO NUL HIPOTEZU**

**Figure 6.2-2**

Whitlock et al., *The Analysis of Biological Data*, 2e, © 2015 W. H. Freeman and Company

V [14 ili više desnonogih]=V[14]+V[15]+V[16]+V[17]+V[18]=0.0155 pomnožiti s 2 zbog dvostrukog testa, V=0.031  
**TO JE P- VRIJEDNOST**

## RELEVANTNOST REZULTATA, ZNAČAJNOSTI I UČINKA

- provjeriti intervale pouzdanosti

$0.54 < p(\text{desnonoge}) < 0.91$  – treba povećati veličinu uzorka



- učinak (metoda procjene) – npr. relativno povećanje varijable, 1%, 25%, 200 %
- procjeniti biološku značajnost (npr. povećanje od 1 % bioraznolikosti u nekom području – kolika je ekološka značajnost!?)

## GREŠKE TIPA 1 I 2

**Greška tipa 1 – odbijanje točne nul hipoteze (definirana s  $\alpha$ , smanjuje se smanjivanjem  $\alpha$ )**

- “lažno pozitivni rezultat” (npr. nalazimo razliku koja ne postoji)

npr. ako je  $\alpha=0.05$  jednom u 20 puta činimo grešku tipa 1

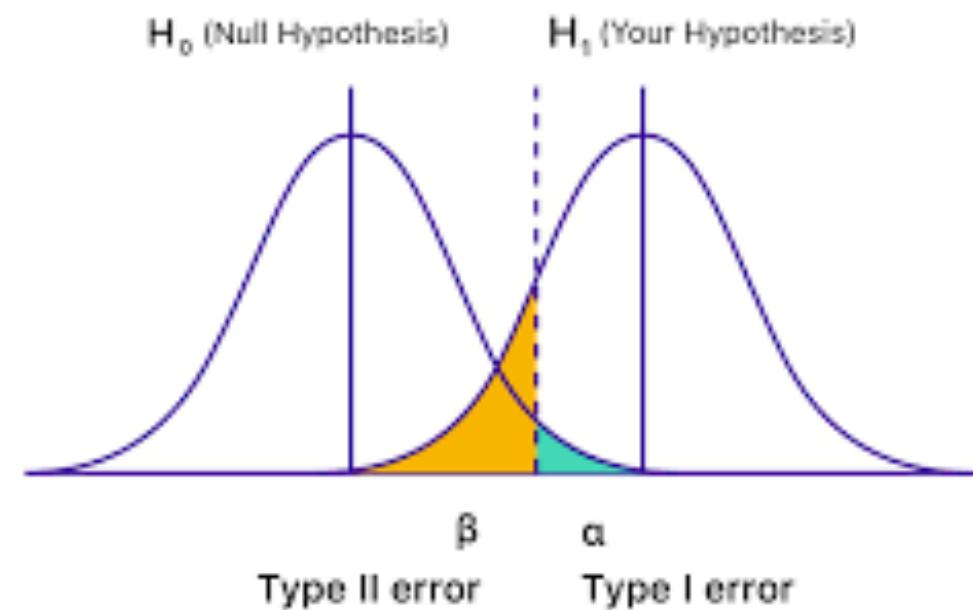
**Greška tipa 2 – ne odbijanje netočne nul hipoteze (krivo prihvatanje  $H_0$ )**

- “lažno negativni rezultat” (npr. ne nalazimo razliku koja postoji)

**Snaga testa – vjerojatnost da slučajan uzorak dovede do greške tipa 2**

**Povećana veličina uzorka smanjuje grešku tipa 2 i povećava snagu testa**

		$H_0$ True	$H_0$ False
Accept $H_0$ /Reject $H_1$	True	True	False: Type II error
	False: Type I error	False: Type I error	True



## Four principles for improved statistical ecology

Gordana Popovic<sup>1</sup>  | Tanya Jane Mason<sup>2,3</sup>  | Szymon Marian Drobniak<sup>4,5</sup> 

### Najčešće greške

- 1) POSTAVLJANJE HIPOTEZE NA OSNOVU REZULTATA
- 2) NE IZNOŠENJE NE-ZNAČAJNIH REZULTATA
- 3) TESTIRANJE NULTE HIPOTEZE ZA KOJU ZNATE DA JE KRIVA
- 4) KRIVA INTERPRETACIJA NE-ZNAČAJNIH REZULTATA KAO NE POSTOJANJE UČINKA ILI POVEZANOSTI

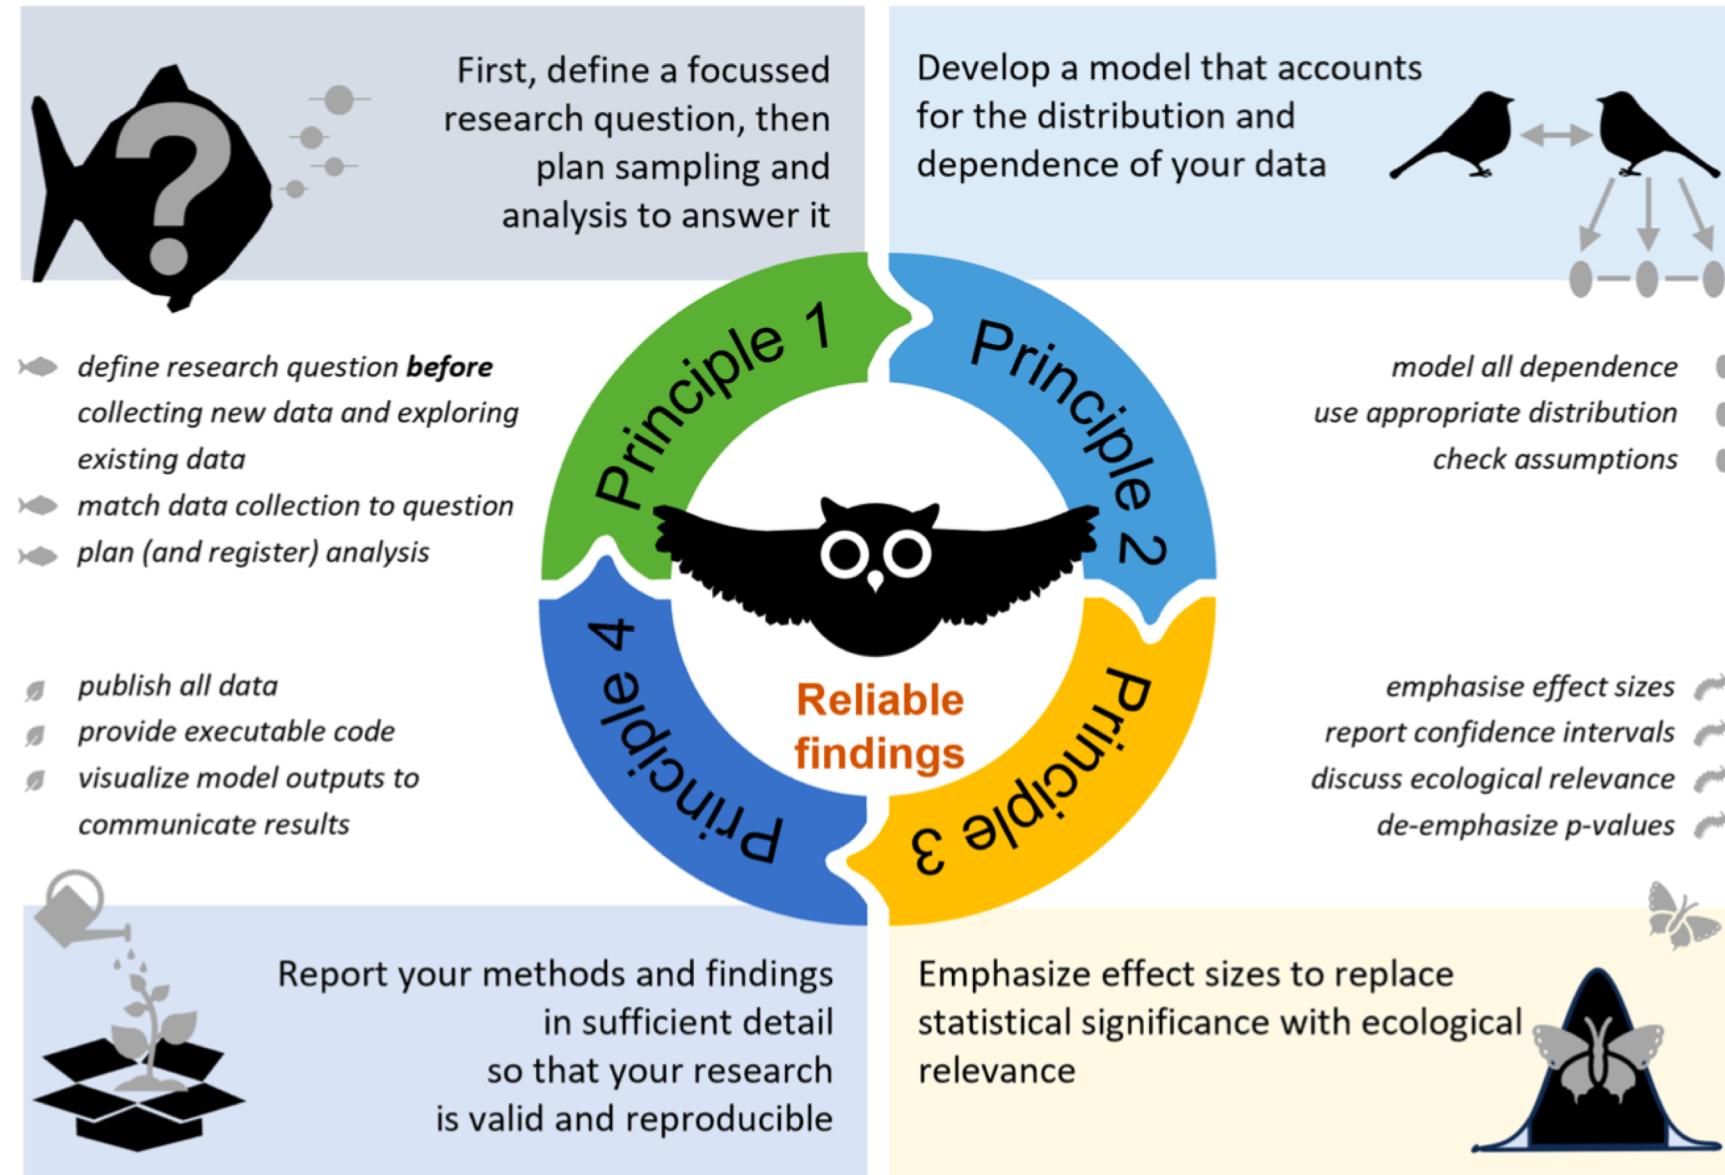
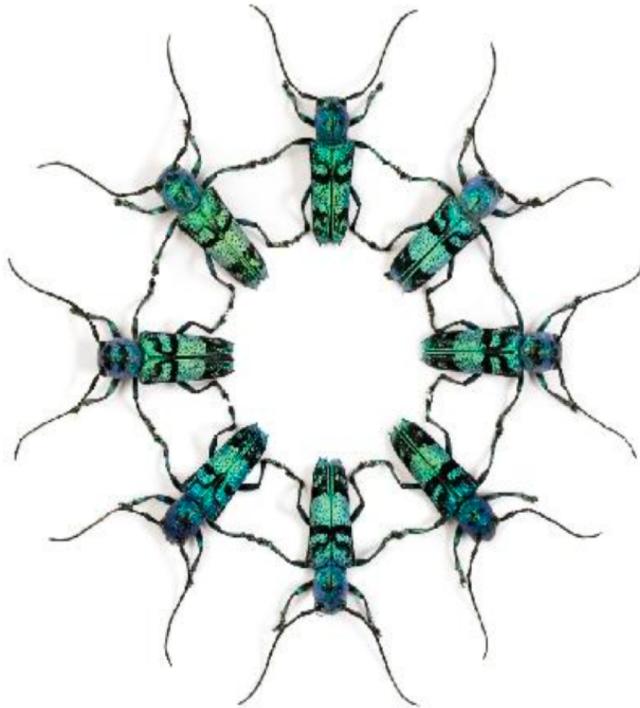


FIGURE 1 Four principles for improved statistical ecology.



The Analysis of Biological Data

WHITLOCK • SCHLUTER

SECOND EDITION