

# PŘÍMÁ ORDINAČNÍ ANALÝZA



# PŘEHLED METOD ORDINAČNÍ ANALÝZY

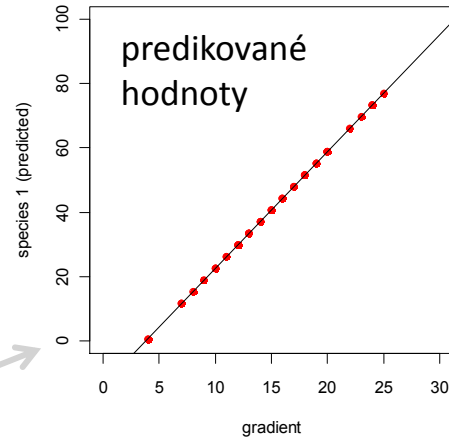

	raw-data-based (založené na primárních datech)		distance-based (založené na distanční matici)
	linear (lineární)	unimodal (unimodální)	
unconstrained (nepřímé)	PCA (analýza hlavních komponent)	CA, DCA (korespondenční a detrendovaná korespondenční analýza)	PCoA (analýza hlavních koordinát)  NMDS (nemetrické mnohorozměrné škálování)
constrained (přímé)	RDA (redundanční analýza)	CCA (kanonická korespondenční analýza)	db-RDA (redundanční analýza založená na distanční matici)



# PRINCIP PŘÍMÉ ORDINAČNÍ ANALÝZY (RDA)

	spe 1	spe 2	spe 3
sam 1			
sam 2			
sam 3			
sam 4			
sam 5			
sam 6			
sam 7			

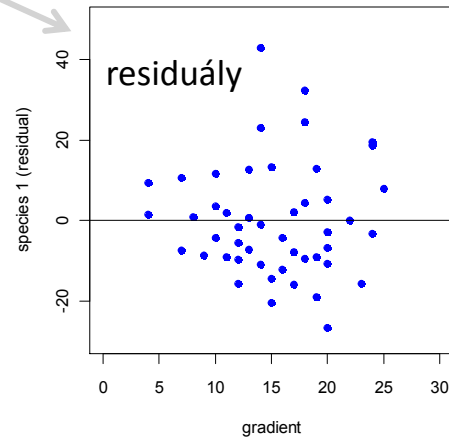
regrese abundance  
druhu na  
proměnné  
prostředí



	spe 1	spe 2	spe 3
sam 1			
sam 2			
sam 3			
sam 4			
sam 5			
sam 6			
sam 7			

	env 1	env 2
sam 1		
sam 2		
sam 3		
sam 4		
sam 5		
sam 6		
sam 7		

matice s vysvětlujícími  
proměnnými



	spe 1	spe 2	spe 3
sam 1			
sam 2			
sam 3			
sam 4			
sam 5			
sam 6			
sam 7			



## OMEZENÉ ORDINAČNÍ OSY

- Skóre založené na fitovaných hodnotách z mnohonásobné. regrese druhů (RDA), nebo vzorků (CCA) na průměrných prostředí
- Ordinační osy jsou lineárními kombinacemi prediktorů
- Reziduální variabilita je vyjádřena neomezenými osami, které jsou přítomné v každé přímé ordinaci.



# PŘÍMÁ ORDINACE

## INTERPRETACE VÝSLEDKŮ

RDA

	Inertia	Proportion	Rank
Total	0.3783	1.0000	
Constrained	0.1063	0.2808	2
Unconstrained	0.2721	0.7192	24

Inertia is variance

$R^2 = 28.08 \%$

Eigenvalues for constrained axes:

RDA1	RDA2
0.09240	0.01385

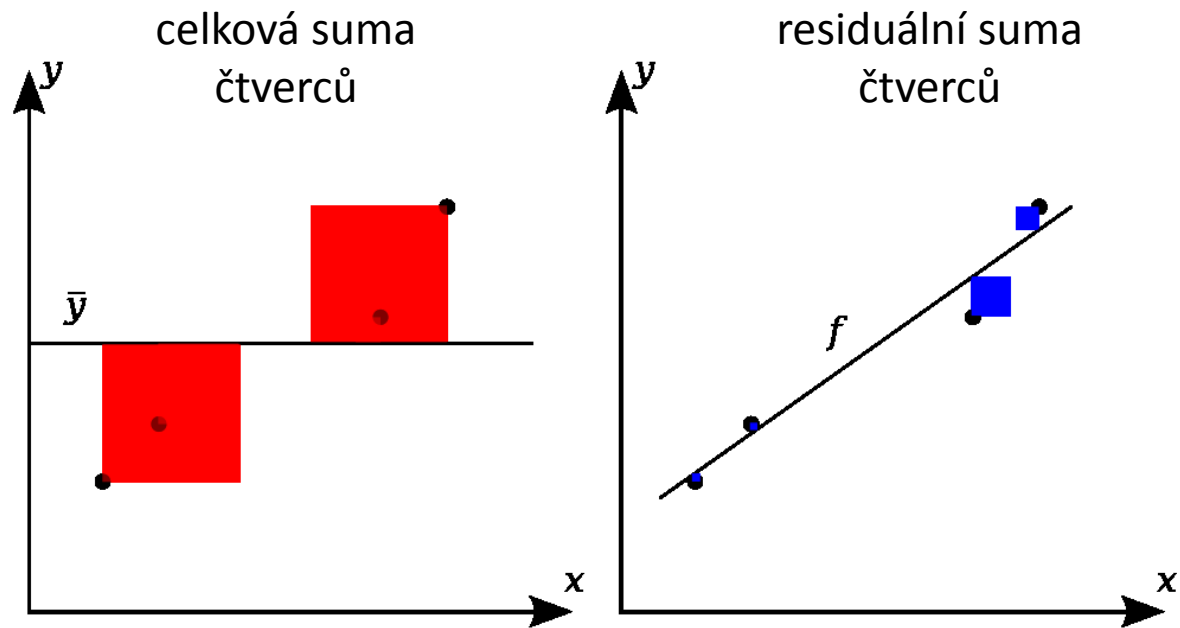
Eigenvalues for unconstrained axes:

PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8
0.09543	0.03586	0.02688	0.02280	0.01706	0.01550	0.00999	0.00880

(Shown only 8 of all 24 unconstrained eigenvalues)




# KOEFICIENT DETERMINACE V REGRESI



$$R^2 = 1 - \frac{SS_{\text{res}}}{SS_{\text{tot}}}$$



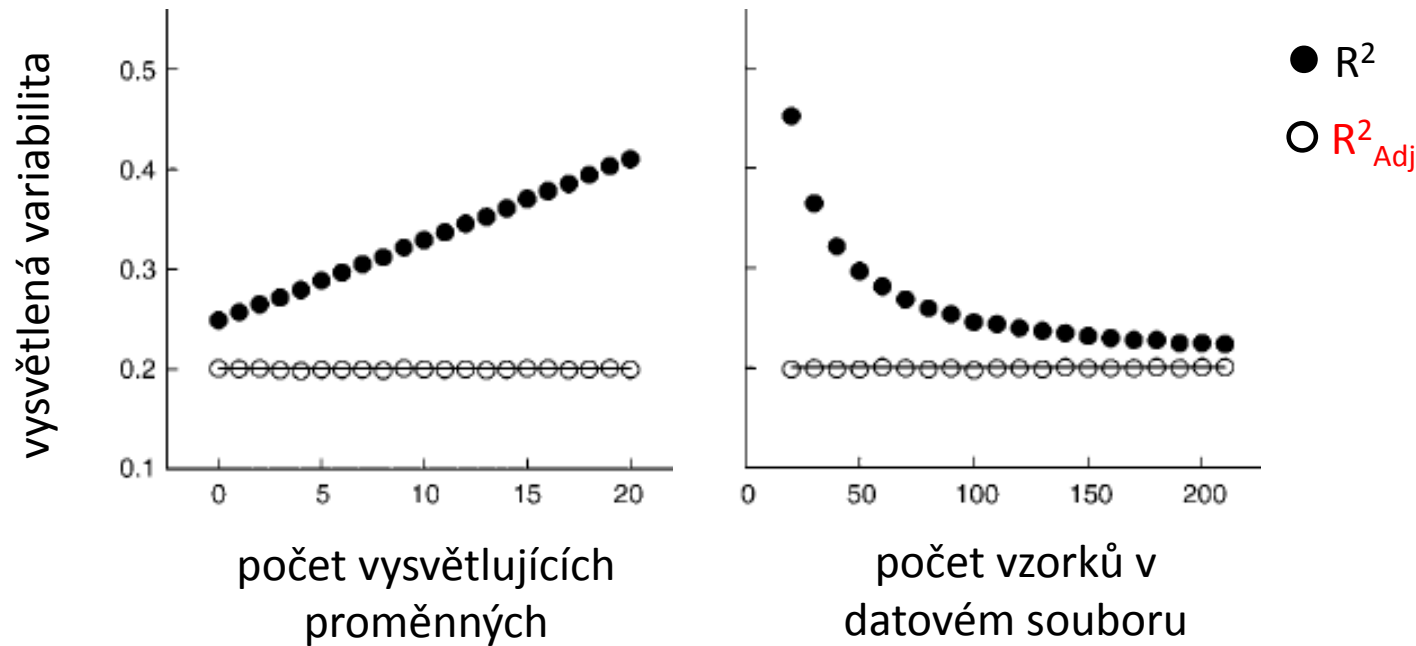
# VYSVĚTLENÁ VARIABILITA ( $R^2$ )



- vysvětlená variabilita stoupá s počtem vysvětlujících proměnných (i když jsou náhodné) a klesá s počtem vzorků v datovém souboru
- platí pro přímou (kanonickou) ordinační analýzu i mnohonásobnou regresi



# VYSVĚTLENÁ VARIABILITA ( $R^2$ ) A UPRAVENÝ (ADJUSTED) $R^2$



- upravený  $R^2$  se nemění s počtem vysvětlujících proměnných a počtem vzorků v souboru





# VÝPOČET UPRAVENÉHO $R^2$ POMOCÍ EZEKIELOVY FORMULE (RDA)


$$R^2_{(Y|X)adj} = 1 - \frac{n-1}{n-p-1} (1 - R^2_{Y|X})$$

$n$  ... počet vzorků

$p$  ... počet vysvětlujících proměnných


$R^2_{Y|X}$  ... vysvětlená variabilita bez adjustace

## Výpočet adjustovaného $R^2$ permutačním modelem (RDA, CCA)



# UPRAVENÉ $R^2$ PRO KOMBINACE N A P

$$R^2_{(Y|X)\text{adj}} = 1 - \frac{n-1}{n-p-1} (1 - R^2_{Y|X})$$




# PŘÍMÁ ORDINAČNÍ ANALÝZA

## MONTE-CARLO PERMUTAČNÍ TEST

- testuje nulovou hypotézu, že druhové složení je nezávislé na jedné nebo více vysvětlujících proměnných pomocí randomizace

ošetřeno	plocha	pokr.
1	1	8
1	2	7
1	3	7
1	7	6
1	8	5
1	9	6
0	4	5
0	5	5
0	6	6
0	10	1
0	11	2
0	12	2
	F =	0.413

RANDOMIZACE: Každé ploše se přiřadí náhodně jeden vegetační zápis (v našem případě jedna hodnota pokravnosti). Tím se zruší jakákoliv závislost mezi proměnnou prostředí (tj. ošetřením) a hodnotami pokravnosti.



Z hodnot pokravnosti spočtu množství variability vysvětlené proměnnými prostředí (F-statistika). Pro hodnoty:

výchozí                      randomizované

ran.1	ran.2	ran.3	ran.4
7	2	5	7
6	5	8	2
5	6	1	5
1	8	6	7
6	1	7	6
6	5	6	2
8	5	6	5
5	6	7	1
5	7	2	6
2	6	2	5
7	2	5	6
2	7	5	8
0.175	0.005	0.005	0.076


A tak dále.  
Až po dosažení kýženého počtu randomizací.



# PŘÍMÁ ORDINAČNÍ ANALÝZA

## MONTE-CARLO PERMUTAČNÍ TEST

- Randomizace produkuje rozdělení hodnot, které by mělo testové kritérium za platnosti nulové hypotézy
- testuje nulovou hypotézu, že druhové složení je nezávislé na jedné nebo více vysvětlujících proměnných
- test první kanonické osy – vliv jen jedné kvantitativní proměnné
- test všech kanonických os – vliv všech proměnných, nebo vliv jedné kategoriální proměnné s více kategoriemi (počet os = počet kategorií – 1)
- testová statistika –  $F_{\text{data}}$  (**pseudo-F**)



$$P = \frac{n_x + 1}{N + 1}$$

P – hladina signifikance

$n_x$  – počet permutací, kde  $F_{\text{perm}} \geq F_{\text{data}}$

N – celkový počet permutací



# POSTUPNÝ VÝBĚR VYSVĚTLUJÍCÍCH PROMĚNNÝCH

## *FORWARD SELECTION*

- ze souboru vysvětlujících proměnných umožňuje vybrat jen ty, které mají průkazný vliv
- v každém kroku testuje zvlášť vliv jednotlivých proměnných (Monte-Carlo permutační test)
- vybere tu proměnnou, která vysvětlí nejvíce variability a zároveň je signifikantní; tuto proměnnou pak do modelu zahrne jako kovariátu
- v dalším kroku znovu testuje vliv jednotlivých proměnných na druhová data (s odstraněním vlivu kovariát) a opakuje předchozí kroky
- testy signifikance jsou zatíženy mnohonásobným porovnáním, a jsou proto poměrně liberální (počet signifikantních proměnných je často nerealisticky vysoký a vyžaduje např. Bonferroniho korekci)




# PROBLÉM MNOHONÁSOBNÉHO POROVNÁNÍ

## FORWARD SELECTION PŘÍLIŠ LIBERÁLNÍ

Simulace:

- 25 náhodně vygenerovaných proměnných
- otestování průkaznosti korelace každé proměnné s každou (čtvercová matice)
- průkazné korelace ( $p < 0.05$ ) jsou označeny červeně
- dohromady 300 analýz, z nich je 16 průkazných



# ŘEŠENÍ PŘÍLIŠ LIBERÁLNÍ FORWARD SELECTION

- globální test
- pokud významný, pak forward selection
- končí, pokud:
  - $R^2_{Adj}$  má překročit globální  $R^2_{Adj}$
  - by přidávaná proměnná nebyla významná

Blanchet et al. 2008



# PARCIÁLNÍ ORDINACE

## *PARTIAL ORDINATION*

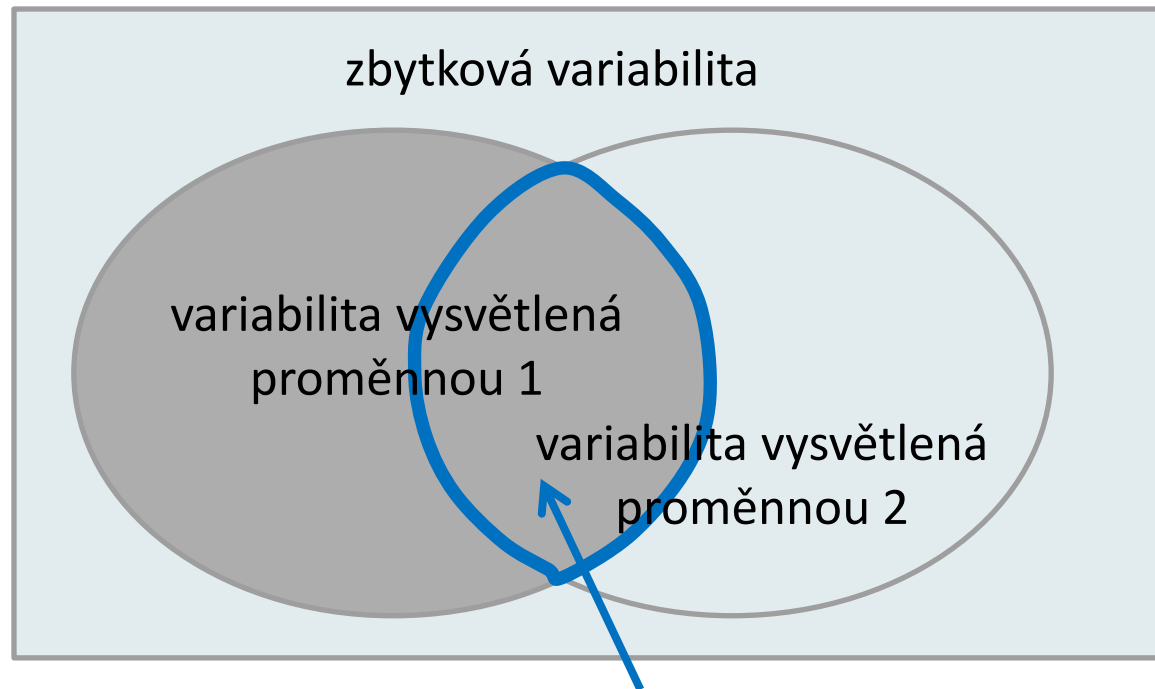
- odstraňuje část variability vysvětlené proměnnými, jejichž vliv chceme odečíst, ale ne přímo kvantifikovat (například vliv umístění ploch do bloků)
- následně se přímou nebo nepřímou ordinací analyzuje zbytková variabilita
- „odečítané“ proměnné se definují jako **kovariáty**
- pokud následuje přímá ordinace – ordinační osy představují čistý vliv ostatních vysvětlujících proměnných bez vlivu kovariát
- pokud následuje nepřímá ordinace – ordinační osy zachycují zbytkovou variabilitu v druhových datech po odstranění vlivu kovariát
- Pomocí kovariát můžeme dále testovat i čisté efekty více prediktorů, pokud jsou tyto navzájem korelované





# ROZKLAD VARIANCE

## VARIANCE PARTITIONING



**vysvětlená variabilita sdílená proměnnou 1 a proměnnou 2 kvůli jejich vzájemné korelaci**




# ROZKLAD VARIANCE

## VARIANCE PARTITIONING

Tři analýzy:

vysvětlující proměnná	kovariáta	vysvětlená variabilita
1 a 2	není	[a]+[b]+[c]
1	2	[a]
2	1	[c]



sdílená variabilita  $[b] = ([a]+[b]+[c]) - [a] - [c]$

nevysvětlená variabilita  $[d] = Total\ inertia - ([a]+[b]+[c])$

$[a]+[b]$  – celkový (*marginal*) vliv proměnné 1

$[a]$  – čistý (*partial, conditional*) vliv proměnné 1 (bez vlivu prom. 2)

