

SPECIÁLNÍ POUŽITÍ ORDINACÍ



NEPARAMETRICKÉ TESTOVÁNÍ LINEÁRNÍHO MODELU POMOCÍ RDA

- Lineární modely (regrese, ANOVA) předpokládají normalitu reziduálů
 - To bývá u biologických dat často problém
 - Spousta typů dat je problematických a nelze rozumně normálně aproximovat, např. poměry (kvazibinomiální data)
- Signifikaci lineárního modelu lze otestovat pomocí „jednorozměrné“ RDA a permutačního testu.
 - Model a regresní koeficienty získám nejsnáze fitováním `lm`
 - Pro test signifikance ale spočtu RDA s jednorozměrnou odpovědí a použiju příslušný permutační test – ten již normalitu reziduálů nevyžaduje



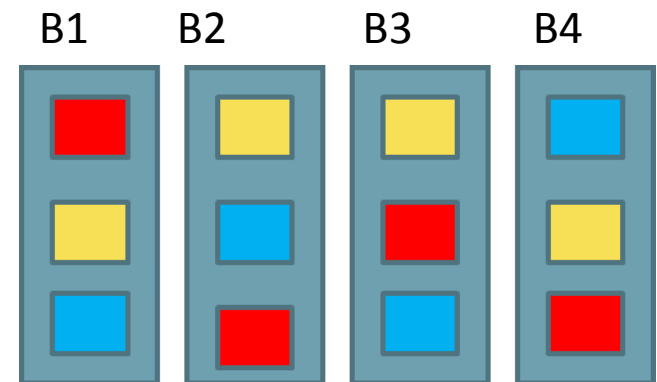
ORDINAČNÍ ANALÝZY SE STRUKTUROVANÝMI DATY

- Všechny metody mají předpoklad nezávislosti pozorování
 - Nezávislost = hodnota proměnné v jednom vzorku nemá vliv na hodnotu proměnné v druhém vzorku
 - Dosud: jeden řádek = jedno nezávislé pozorování
- Řada experimentů i pozorování ale produkuje strukturovaná data, kde nezávislost neplatí
 - To je nezbytné ošetřit v analýze
 - V ordinačních metodách se řeší pomocí kovariát a úprav ordinačního testu
- Pokud testujeme experimenty se strukturovanými daty, nemá příliš smysl řešit vysvětlenou variabilitu (ta bývá nízká), zásadní je test signifikance
- Hierarchický rozklad variability
 - Např. rozdíly v morfometrických parametrech na úrovních: mezi druhy – mezi populacemi uvnitř druhů – mezi jedinci uvnitř populací
 - Tady je zásadní rozložení variability; vyšší úrovně lze případně otestovat (i když zrovna tu mezidruhovou docela těžko)



BLOKY

- Uspořádání experimentu v designu úplných znáhodněných bloků
- Identitu bloku zadáváme do analýzy jako kategoriální kovariátu
- Permutujeme pozorování jen uvnitř bloků, ne mezi nimi
- Zacílení analýzy na rozdíly mezi experimentálními zásahy a odfiltrování rozdílů mezi bloky




gradient prostředí





SPLIT-PLOT DESIGN

- Experimentální uspořádání o dvou úrovních
 - Whole-plot
 - Split-plot
- Při testování whole-plot prediktoru nelze použít kovariátu (protože by se tím zcela odfiltroval jeho vliv)
- Lze kombinovat bloky a split-plot design
- Místo toho split-plot permutace
 - Nastavení permutací pro split-ploty
 - Nebo whole-ploty
- Vhodné i pro testování BACI designů
 - Zásah = whole plot, opakování v čase = split plot; permutují se whole-ploty; test interakce zásah x čas
- Hierarchické uspořádání
 - Chybí split-ploty, permutace whole-plotů
- Design musí být balancovaný a data **KOMPLETNÍ**



PŘÍKLAD BACI DESIGNU REPLIKOVANÉHO V BLOCÍCH

- Těšitel et al. 2017
- Vliv poloparazitických rostlin (*Rhinanthus*) na složení společenstva
- BACI design – baseline + 3 roky po zásahu, 6 bloků
- Testování pomocí parciální RDA
 - Bloky kovariáty
 - Plocha v bloku – whole-plot
 - Časové opakování plochy – split-plot
 - Permutace whole-plotů v blocích
 - Test interakce *Rhinanthus* x čas (a Koseno 2x x čas – ale to nebylo průkazné)



Uspořádání bloku



REVERZNÍ ANALÝZA





- Záměna rolí vysvětlujících a vysvětlovaných proměnných
- Pragmatický nástroj v některých případech
- Ve studii Bonari et al. 2019 byl studován vliv oplocení příbřežních borů ve Středomoří na složení společenstva rostlin a roztočů pancířníků (*oribatid mites*)
- Vliv oplocení vyšel průkazně na oba typy společenstev, ale zároveň víme, že ta se navzájem ovlivňují (pancířníci žerou zbytky organického opadu z rostlin)
- Variation partitioning
 - Čistý efekt oplocení na oribatidy
 - Čistý efekt oplocení na rostliny
 - Společný efekt oplocení na pancířníky i rostliny
 - TO ALE NELZE



BONARI ET. AL. 2019 – VLIV OPLOCENÍ NA ROSTLINY A PANCÍŘNÍKY

G. Bonari, et al.

Forest Ecology and Management 443 (2019) 28–35



REVERZNÍ VARIATION PARTITIONING

- Oplocení – jednorozměrná binární odpověď
- Složení společenstev – 2 skupiny prediktorů
 - Pak už Variation partitioning pomocí parciálního Mantel testu založeného na maticích nepodobnosti společenstev a matici nepodobností dané oplocením




Fig. 4. Variation partitioning of the effect of fencing on species composition of plant and mite communities. Partial effects on the two community types as well as the shared effect between them are displayed. Percentages are derived from R^2 based on partial Mantel tests (127 permutations). Note that the effect of fencing on the shared component of community composition was not tested.



TESTOVÁNÍ ROZDÍLŮ MEZI SKUPINAMI POZOROVÁNÍ

- Definice problému: Máme objekty definované kategoriální proměnnou a popsané řadou dalších proměnných. Zajímá nás, jestli se průkazně liší v těch dalších proměnných
 - Např., druhy popsané morfometrickými parametry
 - Lze otestovat pomocí RDA, případě dalších metod přímé ordinace
- Pokud se liší tak ale vyvstává přirozená otázka: ČÍM se liší?
 - Na to RDA nedovede odpovědět
- Je třeba použít Diskriminační analýzu (obvykle lineární - LDA)
 - Kanonická DA (Canonical discriminant analysis, Canonical variate analysis)
 - Hledá rozdíly mezi vzorky
 - Klasifikační DA
 - Snaží se najít takovou funkci, která bude na základě dostupných parametrů, co nejsprávněji klasifikovat vzorky.



KANONICKÁ DISKRIMINAČNÍ ANALÝZA

- Cílem je odhalit ČÍM se liší a-priori dané skupiny pozorování
 - Např jakými znaky se liší jednotlivé druhy v rámci rodu
- Analýza se snaží najít takové ordinační osy, které maximalizují rozdíly mezi skupinami a minimalizují variabilitu uvnitř
 - Odpověď je příslušnost vzorku ke skupině
 - Prediktory jsou jednotlivé charakteristiky vzorků
 - Morfometrické parametry,
 - Charakteristiky prostředí
 - Jednotlivé druhy u community dat
 - Algoritmus odpovídá reverzní CCA
- Můžeme použít postupný výběr prediktorů (pak je ale zásadní provést napřed globální test např. pomocí klasicky uspořádané RDA, že se skupiny liší, tj, RDA: parametry \sim skupiny)
 - Z takto vybraných proměnných lze sestavit diskriminační funkci



KLASIFIKAČNÍ DISKRIMINAČNÍ ANALÝZA

- Cílem je klasifikovat soubor neznámých vzorků na základě jeho parametrů a diskriminační funkce
- Diskriminační funkce
 - Typicky založená na parametrech vybraných postupným výběrem
 - Na základě training datasetu – pro který je známá klasifikace i parametry
- Pomocí klasifikační DA
 - Můžeme klasifikovat neznámý soubor pozorování
 - Např. určovat rostliny do druhů na základě morfologických znaků
 - Ověřovat účinnost diskriminační funkce
 - Cross-validation: ze známého datasetu vyřadíme 1 vzorek a zbylé použijeme jako training dataset k sestavení diskř. funkce. Pomocí funkce klasifikujeme vynechaný vzorek a porovnáme vypočtenou klasifikaci s reálnou. Toto opakujeme pro každý vzorek v datasetu.
 - Výsledkem je tabulka správně a nesprávně klasifikovaných případů.



LDA V EKOLOGII

- Těšitelová et al. - Složení stromového patra lokalit kruštíků (*Epipactis* spp.)




Fig. 2. Ordination plot of canonical discriminant analysis (CDA) showing differences in tree layer composition of phytosociological relevés containing *Epipactis albensis* ($N = 13$), *E. atrorubens* ($N = 73$), *E. helleborine* ($N = 45$) and *E. purpurata* ($N = 50$) from the Czech Phytosociological Database (Chytrý and Rafajlová, 2003). All herbs and mosses were excluded, since *Epipactis* plants depend on ECM fungi associated with trees and shrubs. Mean Ellenberg indicator values for each relevé (with exclusion of bryophytes, species not categorized by Ellenberg et al., 1992, and *Epipactis* spp. to prevent circular reasoning) were passively projected in the CDA ordination space. The arrows denote an increase either in species abundance or in environmental factor value. All axes explained 88.0% of total variability. Plant species: CarpBet, *Carpinus betulus*; CratLae, *Crataegus laevis*; CratSpe, *Crataegus* sp.; EuonEur, *Euonymus europaeus*;