

# **Statistische Probleme der korpusbasierten Typologie**

Balthasar Bickel

[www.uni-leipzig.de/~bickel](http://www.uni-leipzig.de/~bickel)

## Rückblick (April 2005)

Korpusbasierte Variablen in der Typologie:

1. Typologische Verteilungen zum Teil von Diskurspräferenzen voraussagbar  
... aber lokale/areale Geschichte bildet weitere Variablen
2. Typologische Varianz im Diskurs  
... aber soziologische/ethnologische Varianz bildet weitere Variablen

## Heute (September 2005)


1. Natur typologischer Variablen und Folgen davon für korpusbasierte Typologie
2. Geltungsbereiche in der Typologie

# Typologische Varianz, speziell im Diskurs

- Voraussetzung aller Typologie: die Varianz ist **strukturell** und **nicht individuell**
- Oft gemachte, aber auf einem Fehlschluss basierende Zusatzannahme: die Varianz ist notwendigerweise durch "**Sprachen**" (eine genealogische oder soziologische Einheit) bedingt = eine empirische, nicht apriorische Frage
- Beispiele zu strukturellen Variablen:
  - Grösse phonologischer Domänen
    - zwischensprachliche Varianz > innersprachliche Varianz
    - intergenealogische Varianz > intragenealogische Varianz
  - Affixkohärenz
    - Varianz nicht durch Sprache, sondern Kategorie bedingt (z.B. Tempus vs. Negation)
- Beispiel zu korpusbasierter Variable:
  - Referenzdichte

## Beispiel: Referenzdichte (RD)

- Discourse variable:  $RD = N(\text{overt arg}) / N(\text{poss. arg})$  (defined only for radical pro-drop languages)



Language vs. Individual:  $F(1,61) = 15.55, p < .001$

## Testdesign für RD-Typologie

- Aber: was an den Sprachen bedingt die Varianz?  
Welche Faktoren?
  - genealogische
  - areale
  - strukturelle
  - soziologische
  - NICHT: “Sprache”!
- Testdesign kann und soll “Sprachen” ignorieren!

# Testdesign für RD-Typologie

- GLM design; interest in interactions
- DV = RD
- Structural factor: SYN (postulated in earlier work\*)
  - agreement with NP (SYN = “case-based”)
  - agreement with argument (SYN = “none”)
- Sociological factors:
  - Social network (NET): loose, close
  - Literacy (LIT): literate, illiterate
- Unlikely: areal factors
- Not (yet) testable: genealogical factors

\* Bickel, B. 2003. Referential density in discourse and syntactic typology. *Language* 79, 708-29.

# Sample

	GEN	AREA	SYN	NET	RD predicted
Belhare	ST	Himalayas	–	close, rural	low
Kyirong			–	close, urban	low
Xiang		China	–	loose, urban	high
Nepali	IE	Himalayas	+	close, urban	high
Maithili			+	close, urban	high
Chechen	ND	Caucasus	+	loose, urban	high


Cross-community variable:

- Literacy (LIT)

# Factorial analysis

3-way ANOVA (SYN \* NET \* LIT):


- main effect of SYN ( $F(55,1) = 10.75, p = .002$ )
- main effect of LIT ( $F(55,1) = 33.89, p < .001$ )
- interaction effect of SYN \* NET ( $F(61,1) = 11.22, p = .001$ )



## Factorial analysis (cont'd)

2-way ANOVA (SYN\*LIT ) under the **NET = close** condition


- main effect of SYN ( $F(1,36) = 25.50, p < .001$ , contrast = .08\*\*)
- main effect of LIT ( $F (1,40) = 12.14, p = .001$ , contrast = .09\*)
- no significant interaction



## Factorial analysis (cont'd)

1-way ANOVA (NET) under the **SYN = none** condition (loose NET strictly implies LIT; hence LIT is excluded here)

- main effect of NET ( $F(1,30) = 38.68, p < .001$ , contrast = .16\*\*)



## Methodologische Konklusion

- “Sprachen” als genealogische und/oder soziologische Einheiten spielen in der korpusbasierten Typologie keine Rolle
- Alles GLM-Designs, v.a. ANOVA

## Geltungsbereich

Wichtiger Störfaktor in der Typologie ist Genealogie (Verwandtschaft aufgrund eines gemeinsamen Vorfahren), aber wir können nicht genealogisch stratifizieren

- anstatt Zufallsproben, genealogisch balancierte Proben
- Probe = Population
- klassische Statistik nicht anwendbar
- exakte und Randomisierungsmethoden (Monte-Carlo)
- Randomisierungsbasierte ANOVA \*

\* Janssen, D., B. Bickel & F. Zúñiga 2005. Randomization tests in language typology. Ms.