

Using language-internal similarities to compare languages

Michael Cysouw

Research Unit “Quantitative Language Comparison”
Ludwig Maximilians University Munich

Assumptions

(apparently slightly radical)

- **Linguistic structures are language-specific**
 - ▶ there is no universal ‘nominative’
there are many different ‘Nominatives’
 - ▶ same holds also for phonemes!
- **Nature of a language-specific structure is determined by the set of all occurrences**
 - ▶ e.g. the meaning of the Albanian Nominative is defined by the collection of contexts in which it is used
 - ▶ a phoneme is defined by the set of all concrete occurrences in context

Case marking case-study

- Texts from watchtower.org
 - ▶ (Pamphlets of Jehovah's Witnesses)
- Translated into hundreds of languages
- Selection of 34 contexts in 15 languages that contain the word 'Bible'
- Only consider bound 'case' marking in orthographic representation of word 'Bible'

First 10 selected contexts

1. What important information is **contained in the Bible?**
2. Who is **the Bible's author?**
3. Why should **you study the Bible?**
4. **The Bible is** a precious gift from God.
5. **The Bible alone tells us** what we must do to please God.
6. **The Bible was written** by some 40 different men over a period of 1,600 years, beginning in 1513 B.C.E.
7. So God in heaven, not any human on earth, is **the Author of the Bible.**
8. God made sure that **the Bible was accurately copied** and preserved.
9. **More Bibles have been printed** than any other book.
10. Not everyone will be happy to see **you studying the Bible**, but do not let that stop you.

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblían	piibel	bibliax
5	bibla	bíobla	bíblían	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblían	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblían	piibel	bibliax
5	bibla	bíobla	bíblían	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblían	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblían	piibel	bibliax
5	bibla	bíobla	bíblían	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblían	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblían	piibel	bibliax
5	bibla	bíobla	bíblían	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblían	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblian	piibel	bibliax
5	bibla	bíobla	bíblian	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblian	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblian	piibel	bibliax
5	bibla	bíobla	bíblian	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblian	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblian	piibel	bibliax
5	bibla	bíobla	bíblian	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblian	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblian	piibel	bibliax
5	bibla	bíobla	bíblian	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblian	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

The dilemma of language comparison:

**There is no objective way to decide
which structure from language A
is to be compared with
which structure from language B**

(without any a-priori definition,

which would typically be a Eurocentric one)

Solution to the dilemma:

Language-specific metrics
(similarity measures)

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblían	piibel	bibliax
5	bibla	bíobla	bíblían	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblían	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

	Albanian
1	bibla
2	biblës
3	biblën
4	bibla
5	bibla
6	bibla
7	biblës
8	bibla
9	bibla
10	biblën
...	...

Language-specific metric on sampled contexts

- Many more intricate possibilities to define such a similarity measure
- Important: the similarity only uses structure of one single language
- There is no language comparison (yet)!

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblían	piibel	bibliax
5	bibla	bíobla	bíblían	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblían	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblían	piibel	bibliax
5	bibla	bíobla	bíblían	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblían	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

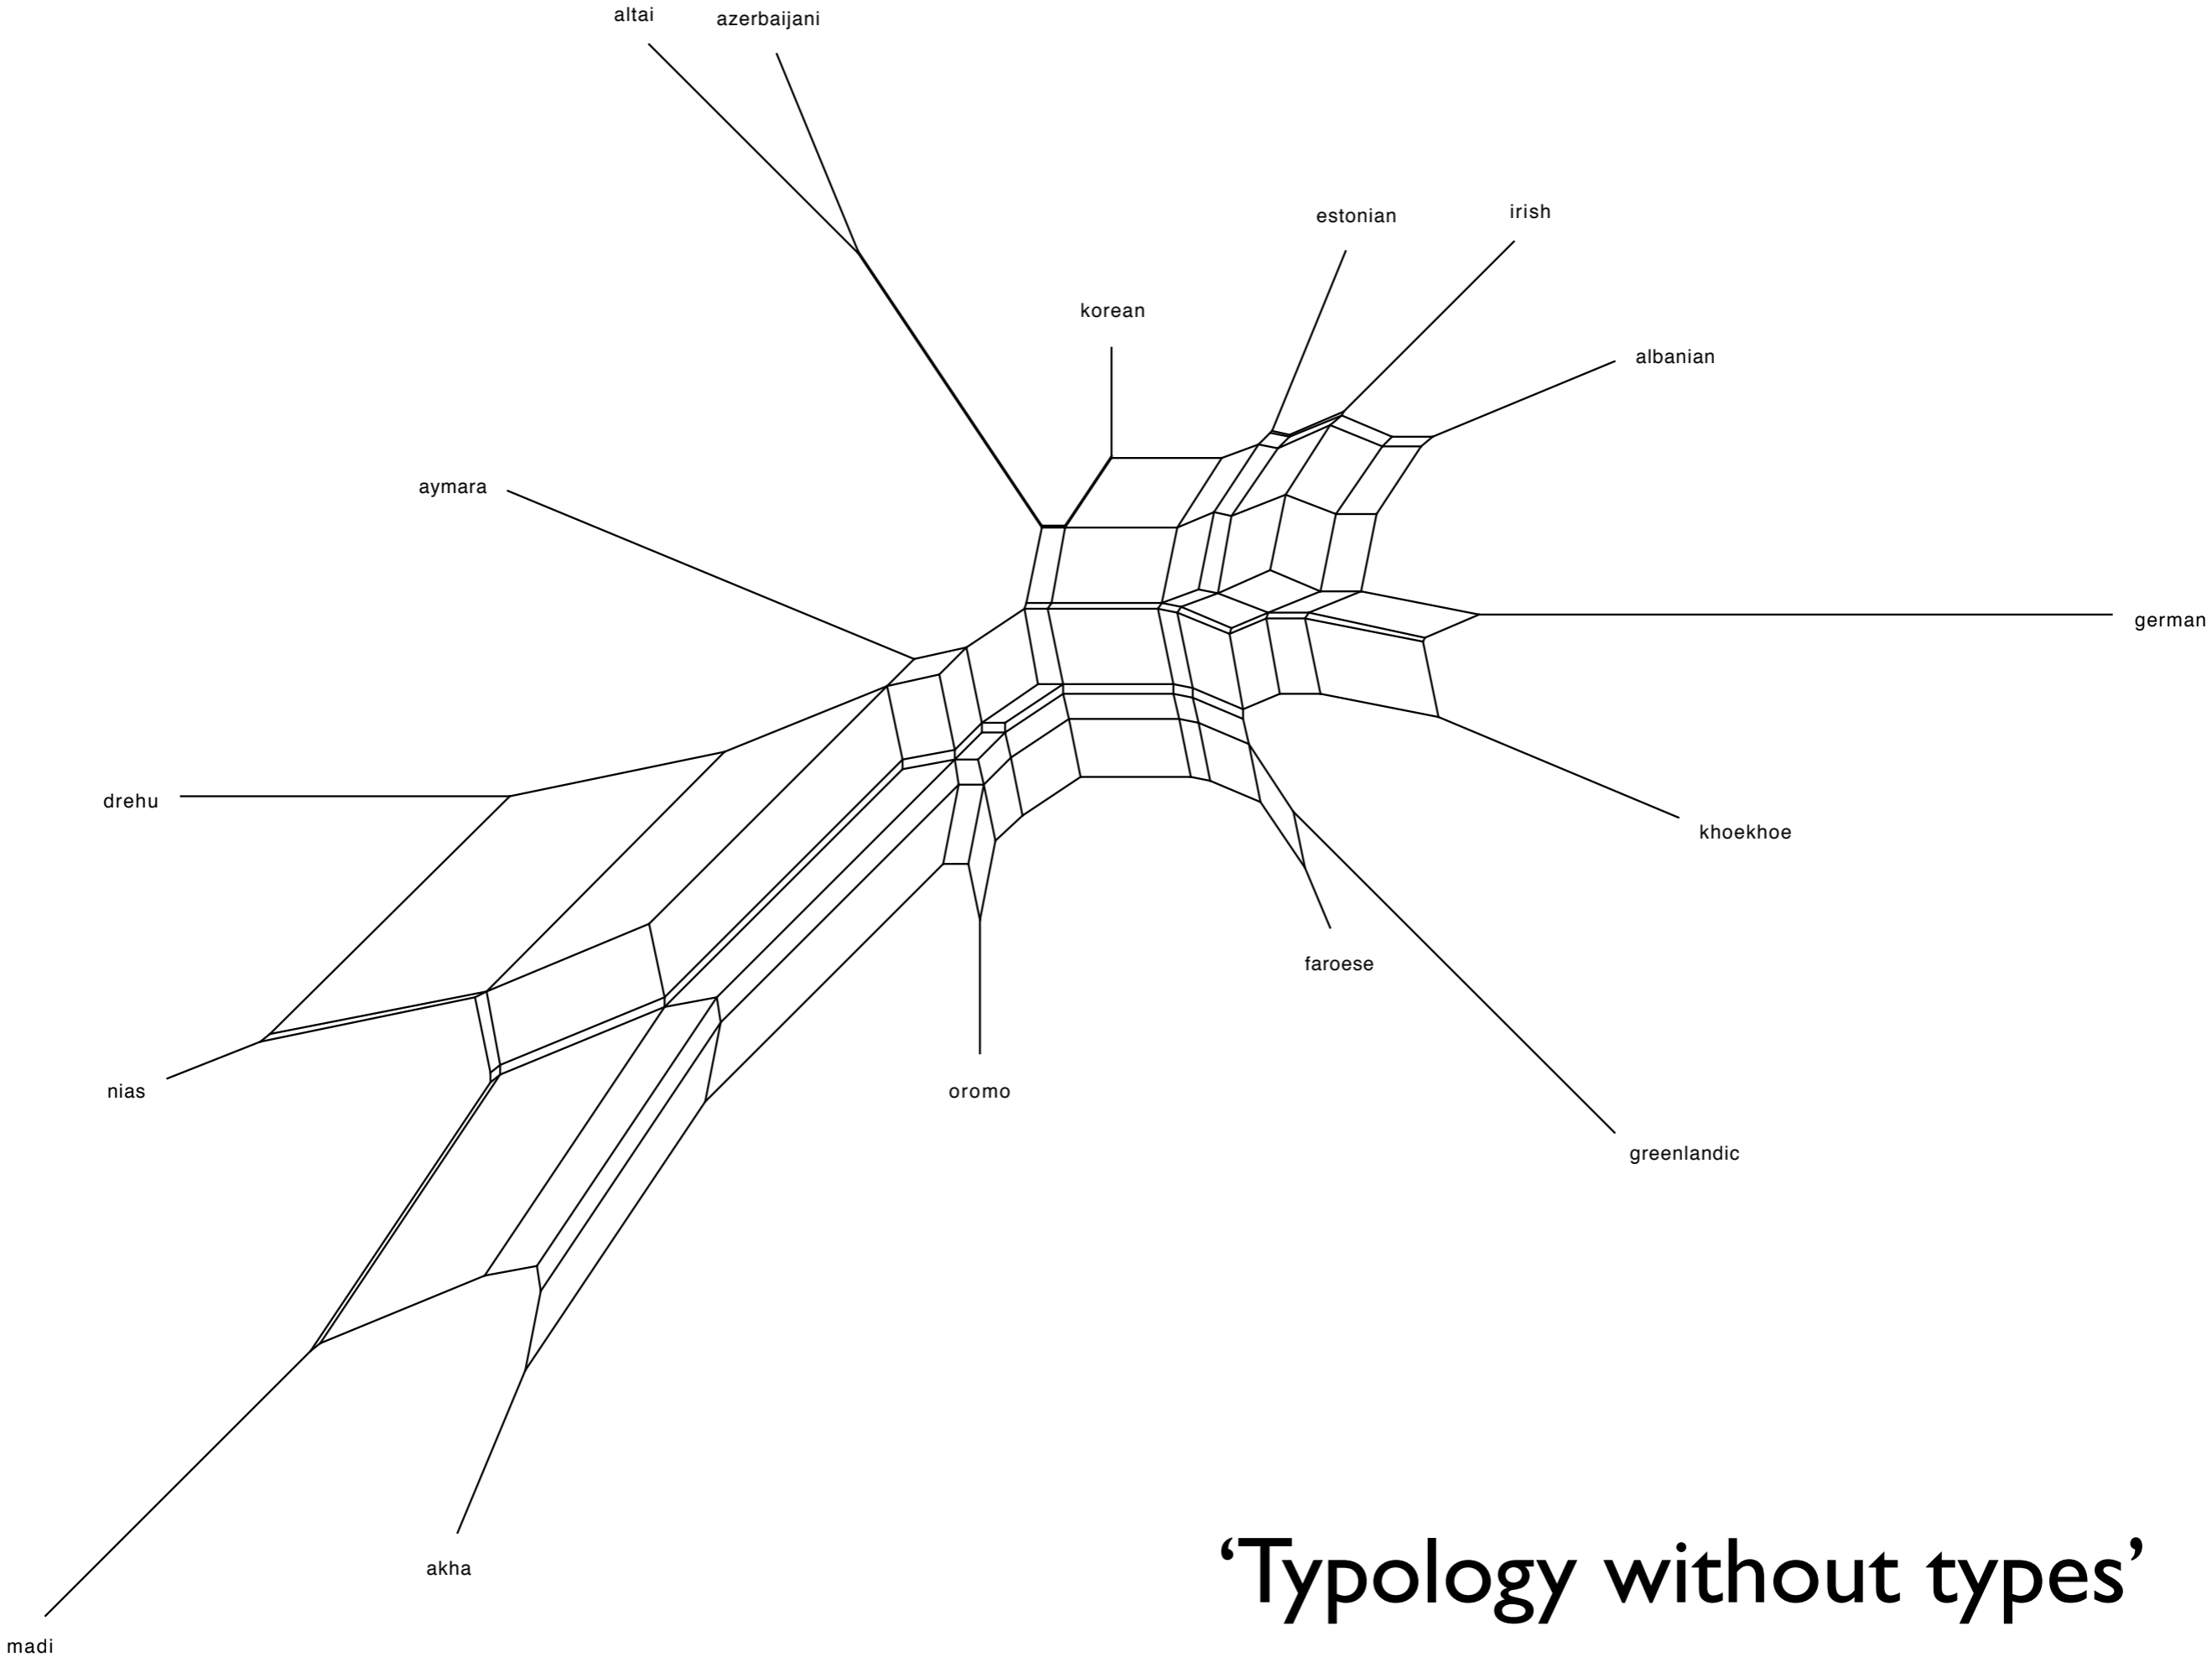
Similarity between languages ...

	Albanian	1	2	3	4	5	6	7	8	9	10
1	bibla	0	1	1	0	0	0	1	0	0	1
2	biblës	1	0	1	1	1	1	0	1	1	1
3	biblën	1	1	0	1	1	1	1	1	1	0
4	bibla	0	1	1	0	0	0	1	0	0	1
5	bibla	0	1	1	0	0	0	1	0	0	1
6	bibla	0	1	1	0	0	0	1	0	0	1
7	biblës	1	0	1	1	1	1	0	1	1	1
8	bibla	0	1	1	0	0	0	1	0	0	1
9	bibla	0	1	1	0	0	0	1	0	0	1
10	biblën	1	1	0	1	1	1	1	1	1	0
...	...										

	Irish	1	2	3	4	5	6	7	8	9	10
1	bhíobla	0	0	1	1	1	0	0	1	0	0
2	bhíobla	0	0	1	1	1	0	0	1	0	0
3	mbíobla	1	1	0	1	1	1	1	1	1	1
4	bíobla	1	1	1	0	0	1	1	0	1	1
5	bíobla	1	1	1	0	0	1	1	0	1	1
6	bhíobla	0	0	1	1	1	0	0	1	0	0
7	bhíobla	0	0	1	1	1	0	0	1	0	0
8	bíobla	1	1	1	0	0	1	1	0	1	1
9	bhíobla	0	0	1	1	1	0	0	1	0	0
10	bhíobla	0	0	1	1	1	0	0	1	0	0
...	...										

... by establishing a similarity between language-specific similarities

	Language	1	2	3	4	5
1	Albanian	0.00	0.28	0.21	0.30	0.76
2	Irish	0.28	0.00	0.35	0.27	0.74
3	Faroese	0.21	0.35	0.00	0.33	0.42
4	Estonian	0.30	0.27	0.33	0.00	0.59
5	Aymara	0.76	0.74	0.42	0.59	0.00
...	...					



‘Typology without types’

	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblían	piibel	bibliax
5	bibla	bíobla	bíblían	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblían	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...


	Albanian	Irish	Faroese	Estonian	Aymara
1	bibla	bhíobla	bíbliuni	piibel	bibliaxa
2	biblës	bhíobla	bíbliunnar	piibli	bibliax
3	biblën	mbíobla	bíbliuna	piiblit	bibliat
4	bibla	bíobla	bíblían	piibel	bibliax
5	bibla	bíobla	bíblían	piibel	bibliakiw
6	bibla	bhíobla	bíbliuna	piibli	bibliax
7	biblës	bhíobla	bíbliunnar	piibli	bibliaxa
8	bibla	bíobla	bíblían	piiblit	bibliaxa
9	bibla	bhíobla	(n.a.)	piiblit	bibliawa
10	biblën	bhíobla	bíbliuna	piiblit	bibliat
...

identically coded in 2 out of 5 languages

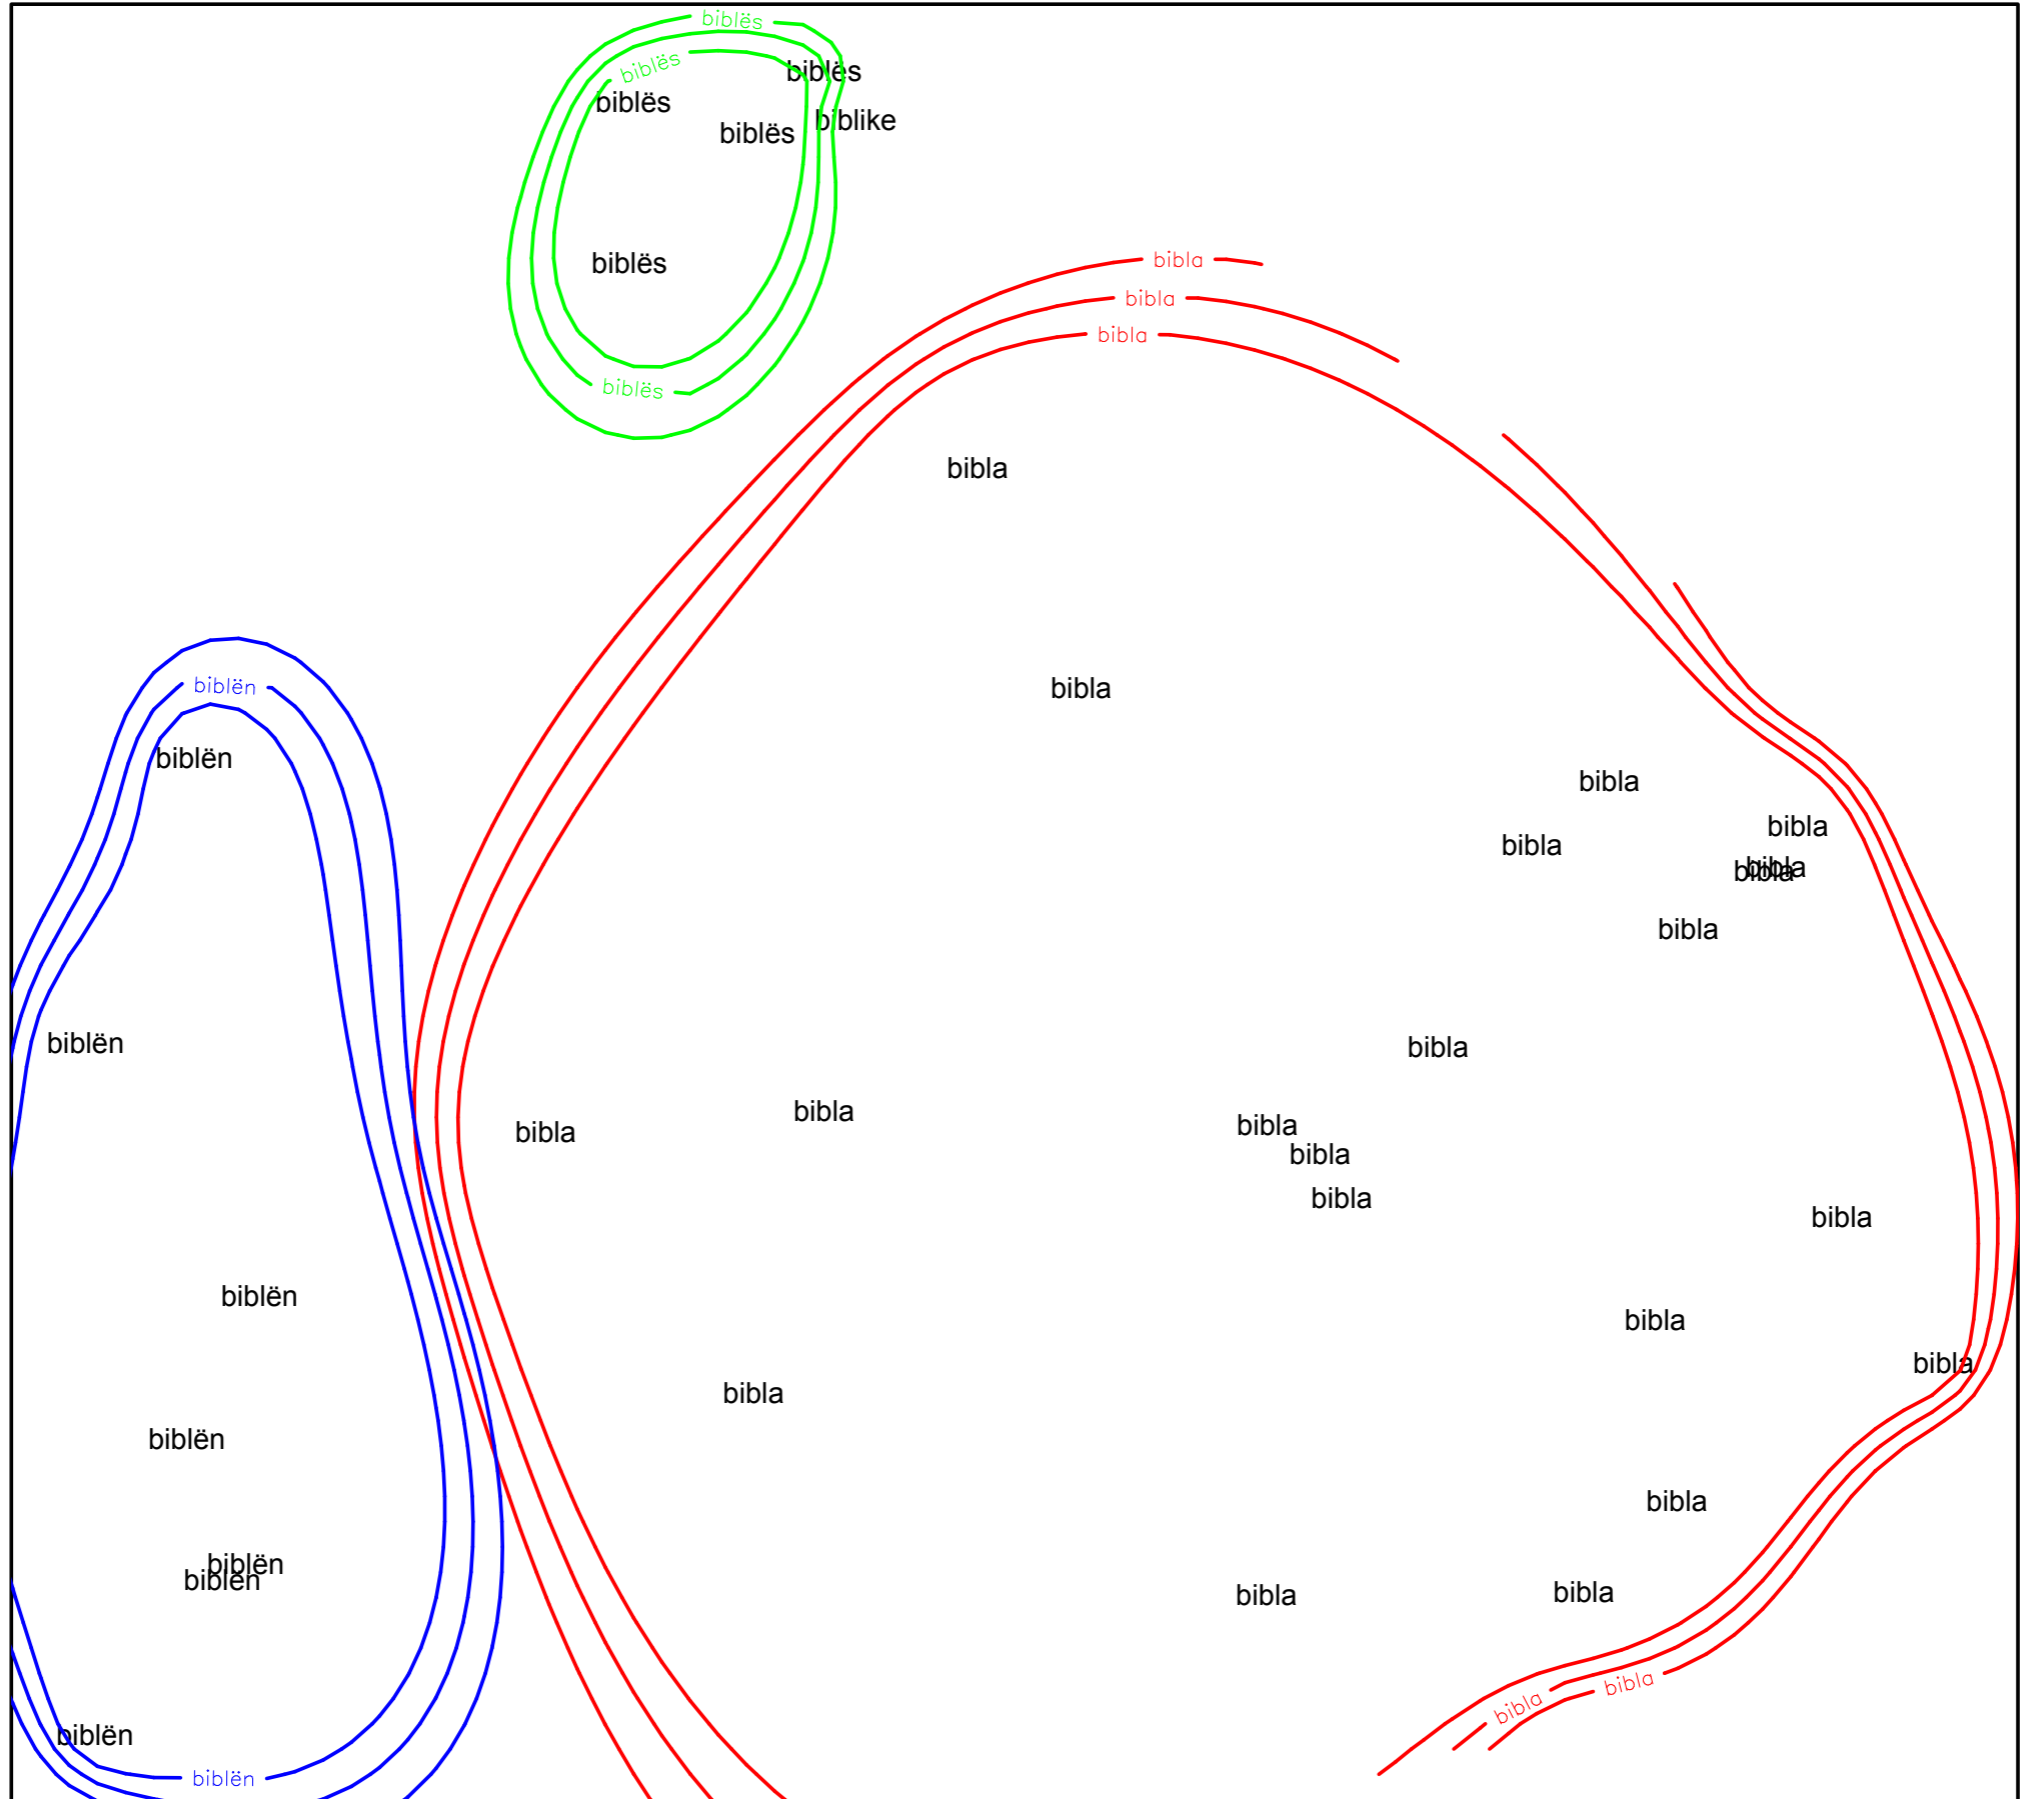
Cross-linguistic metric on sampled contexts

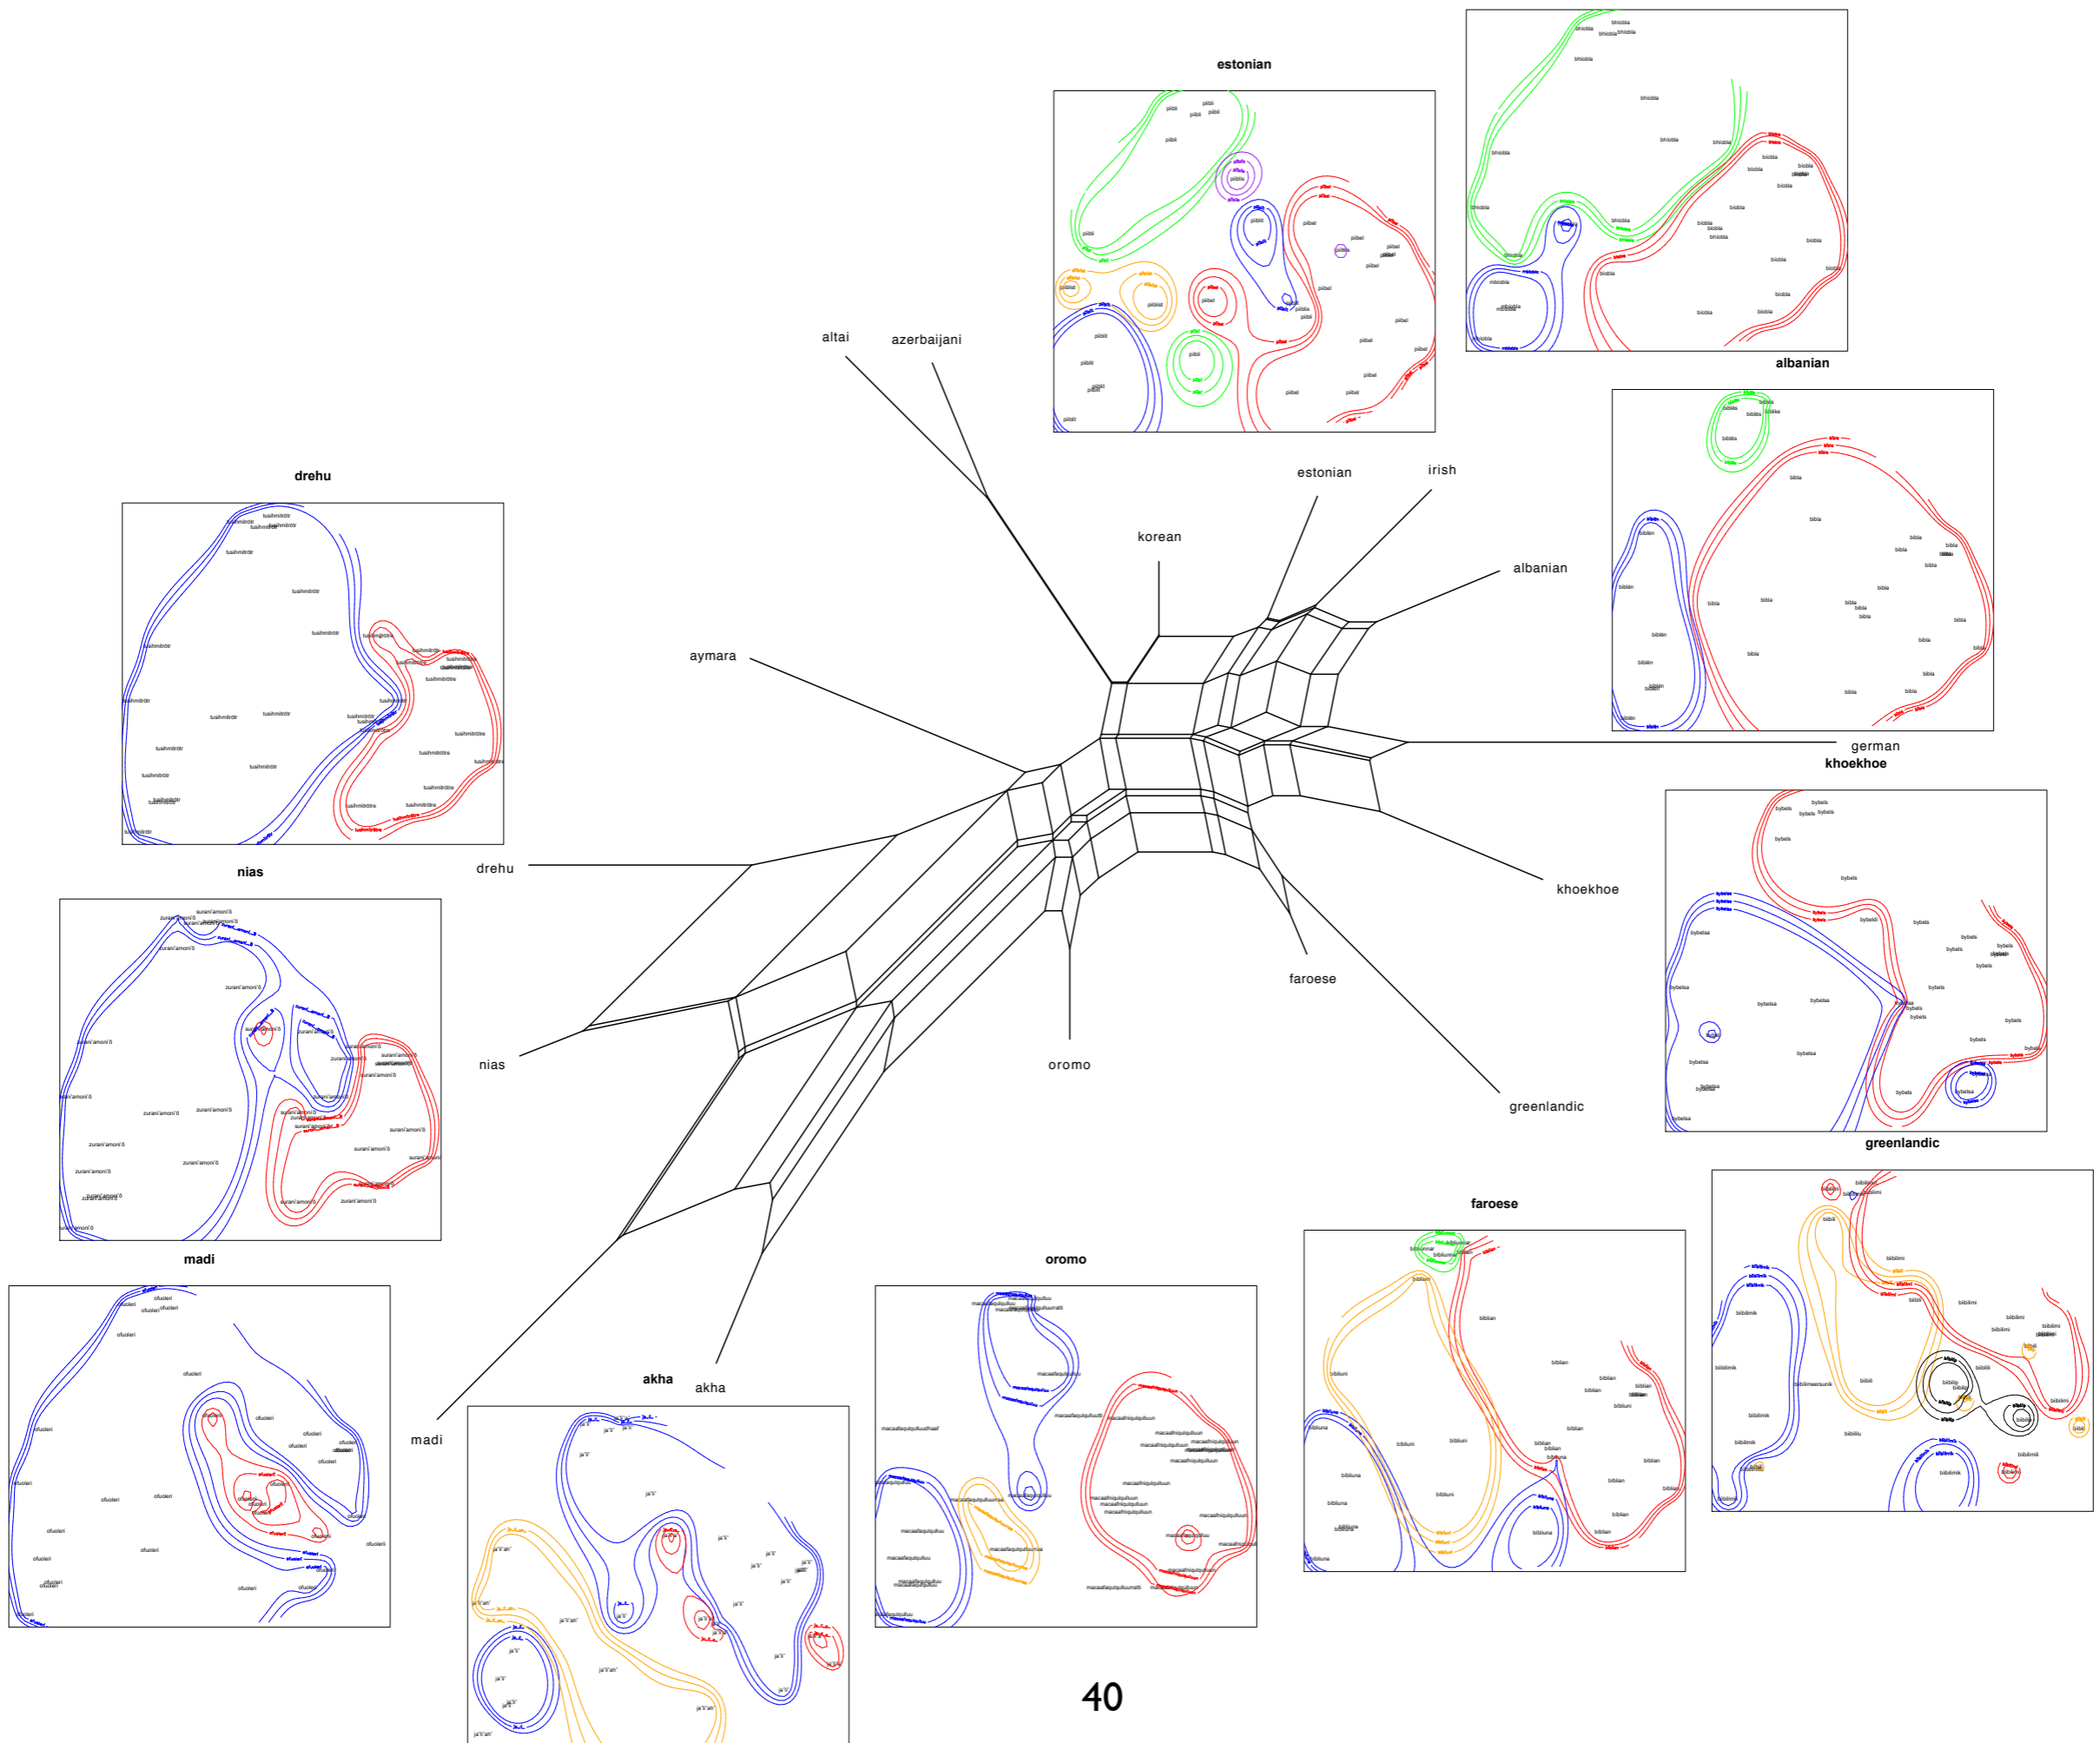
	1	2	3	4	5
1	0	0.28	0.21	0.30	0.76
2	0.28	0	0.35	0.27	0.74
3	0.21	0.35	0	0.33	0.42
4	0.30	0.27	0.33	0	0.59
5	0.76	0.74	0.42	0.59	0

(average of language-specific metrics)



albanian





Summary

- Language comparison has to be based on a suitable set of exemplars in context
 - ▶ Language-specific metrics on contexts
 - ▶ Only uses knowledge about the structure of one language
- Language comparison is reduced to a metric on language-specific metrics
 - ▶ ‘typology without types’
- Compare language-specific metric to an ‘average’ metric
 - ▶ Cross-linguistic metric on contexts
 - ▶ Visualize structure of individual languages on this basis