Que faire avec 740 romans ?

Exploration einer Sammlung französischer Romane mit Topic Modeling

---

Christof Schöch
Nachwuchsgruppe
"Computergestützte literarische Gattungsstilistik" (CLiGS)
Lehrstuhl für Computerphilologie, Universität Würzburg

Digital Humanities Kolloquium
Trier, 28. Oktober 2015

Gefördert vom BMBF - FKZ 01UG1408/1508

1. Einleitung

Überblick

- Einleitung: Kontext und Fragestellungen
- Textsammlung: 740 französische Romane
- Methode: Topic Modeling Workflow
- Ergebnisse: Perspektiven auf die Daten
- Fazit

Kontext Digitale Geisteswissenschaften

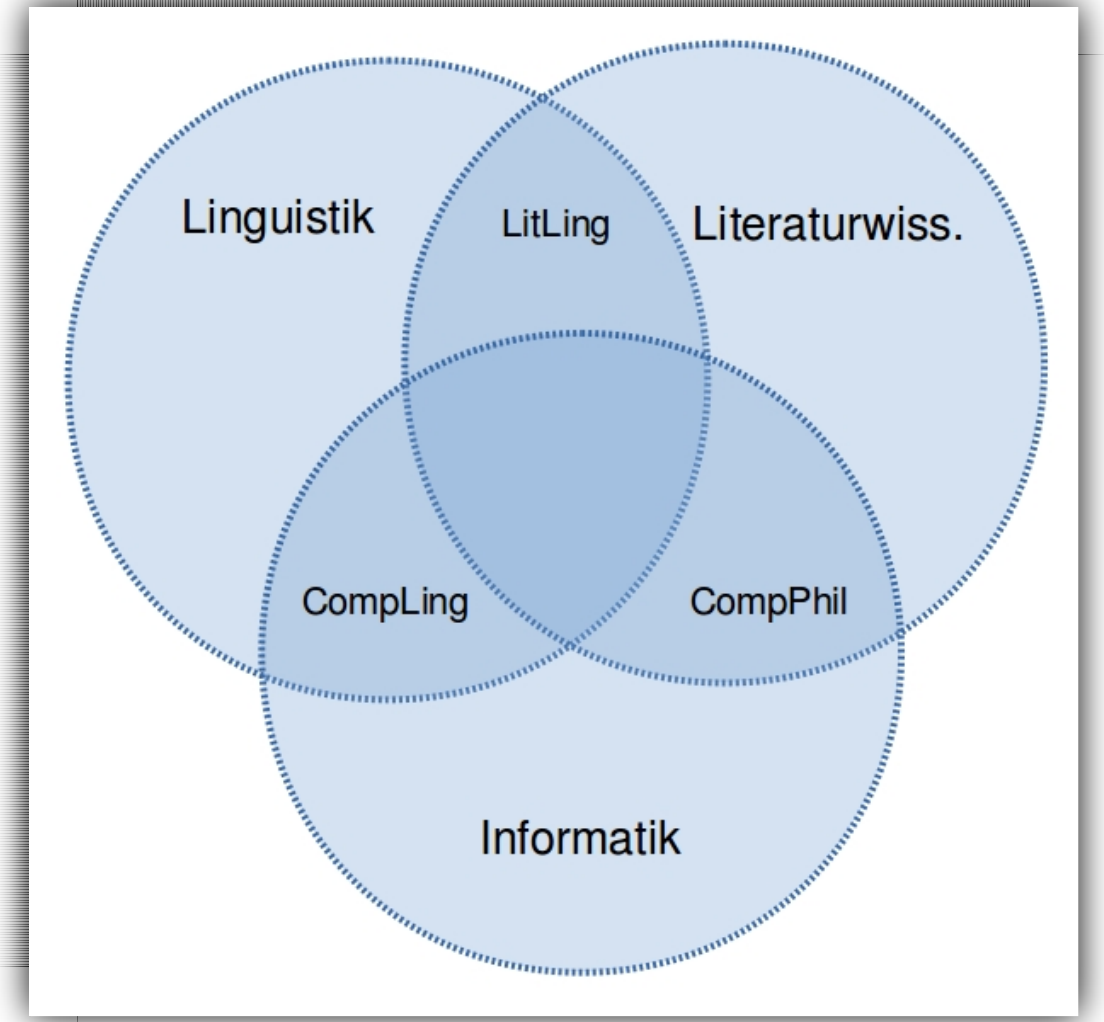

Kontext "CLiGS"

- CLiGS = Computergestützte literarische Gattungsstilistik, cligs.hypotheses.org
- BMBF-geförderte Nachwuchsgruppe (Romanistik und Informatik), 2014-2019
- Übergeordnete Ziele:
  - Beschreibung von Untergattungen des (französischen und spanischen) Romans und des Theaters auf Grundlage großer Textsammlungen
  - Adaptation von Methoden aus der Informatik für die Literaturwissenschaften
  - Reflexion über das Konzept der Gattungen

Beschreibungsebenen von Gattung

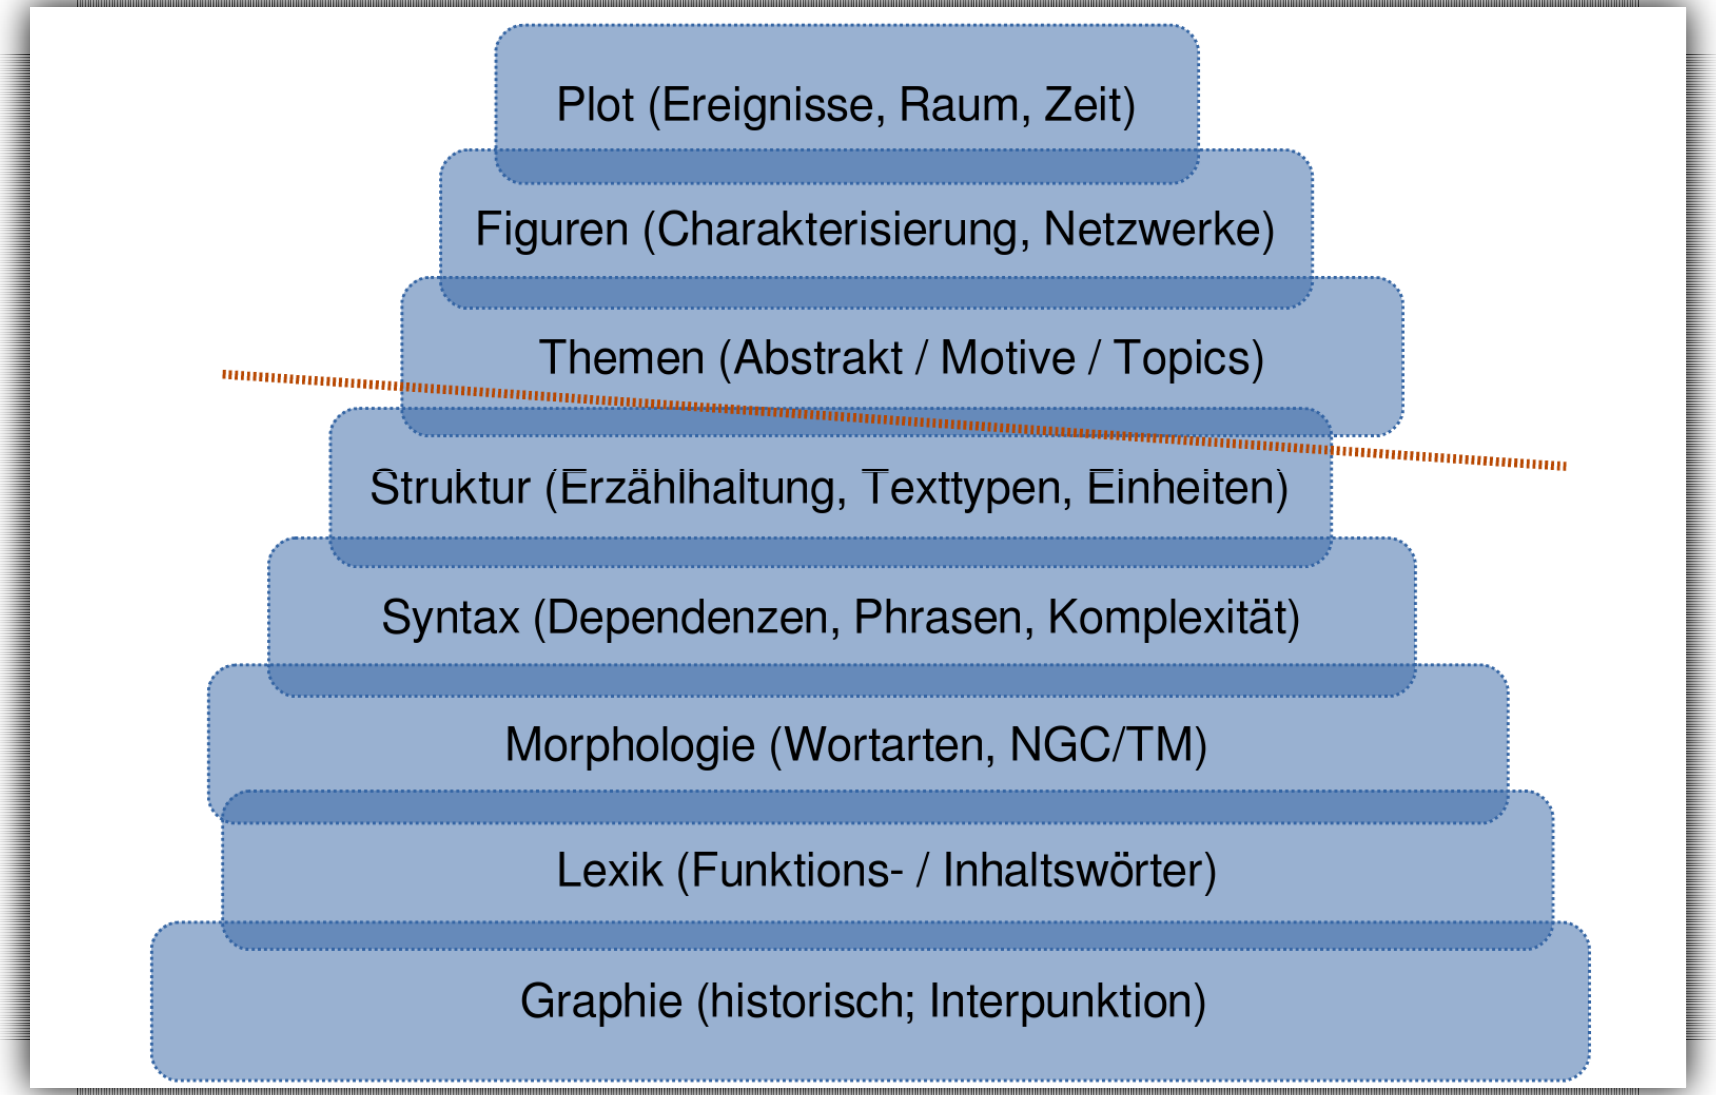

Fragestellungen

- Worum geht es im französischen Roman des 19. und 20. Jahrhunderts?
- Welche Typen von Topics gibt es überhaupt? (Was sind 'Topics'?)
- Welche Topics sind typisch für den Kriminalroman, welche für Nicht-Kriminalromane?
- Fokus auf den Kriminalroman: Wie gestaltet sich die Binnendifferenzierung der Gattung?
- Erlaubt Topic Modeling einen Zugang zu gattungsrelevanten Informationen?
- Welche Rolle spielen Visualisierungen der Daten für ihre Interpretation?

2. Die Textsammlung

Die Textsammlung

- 740 Romane, davon 271 Kriminalromane und 469 Nicht-Krimis;
  Textmenge: ca. 50 Mio. Tokens / 314 MB Text ; mehr in Vorbereitung
- Publiziert zwischen 1840 und 2009;
  durchschnittlich 41 Romane pro Jahrzehnt
- Liegen mit Metadaten und im TEI-Format vor (Text Encoding Initiative)

Textsammlung im Überblick

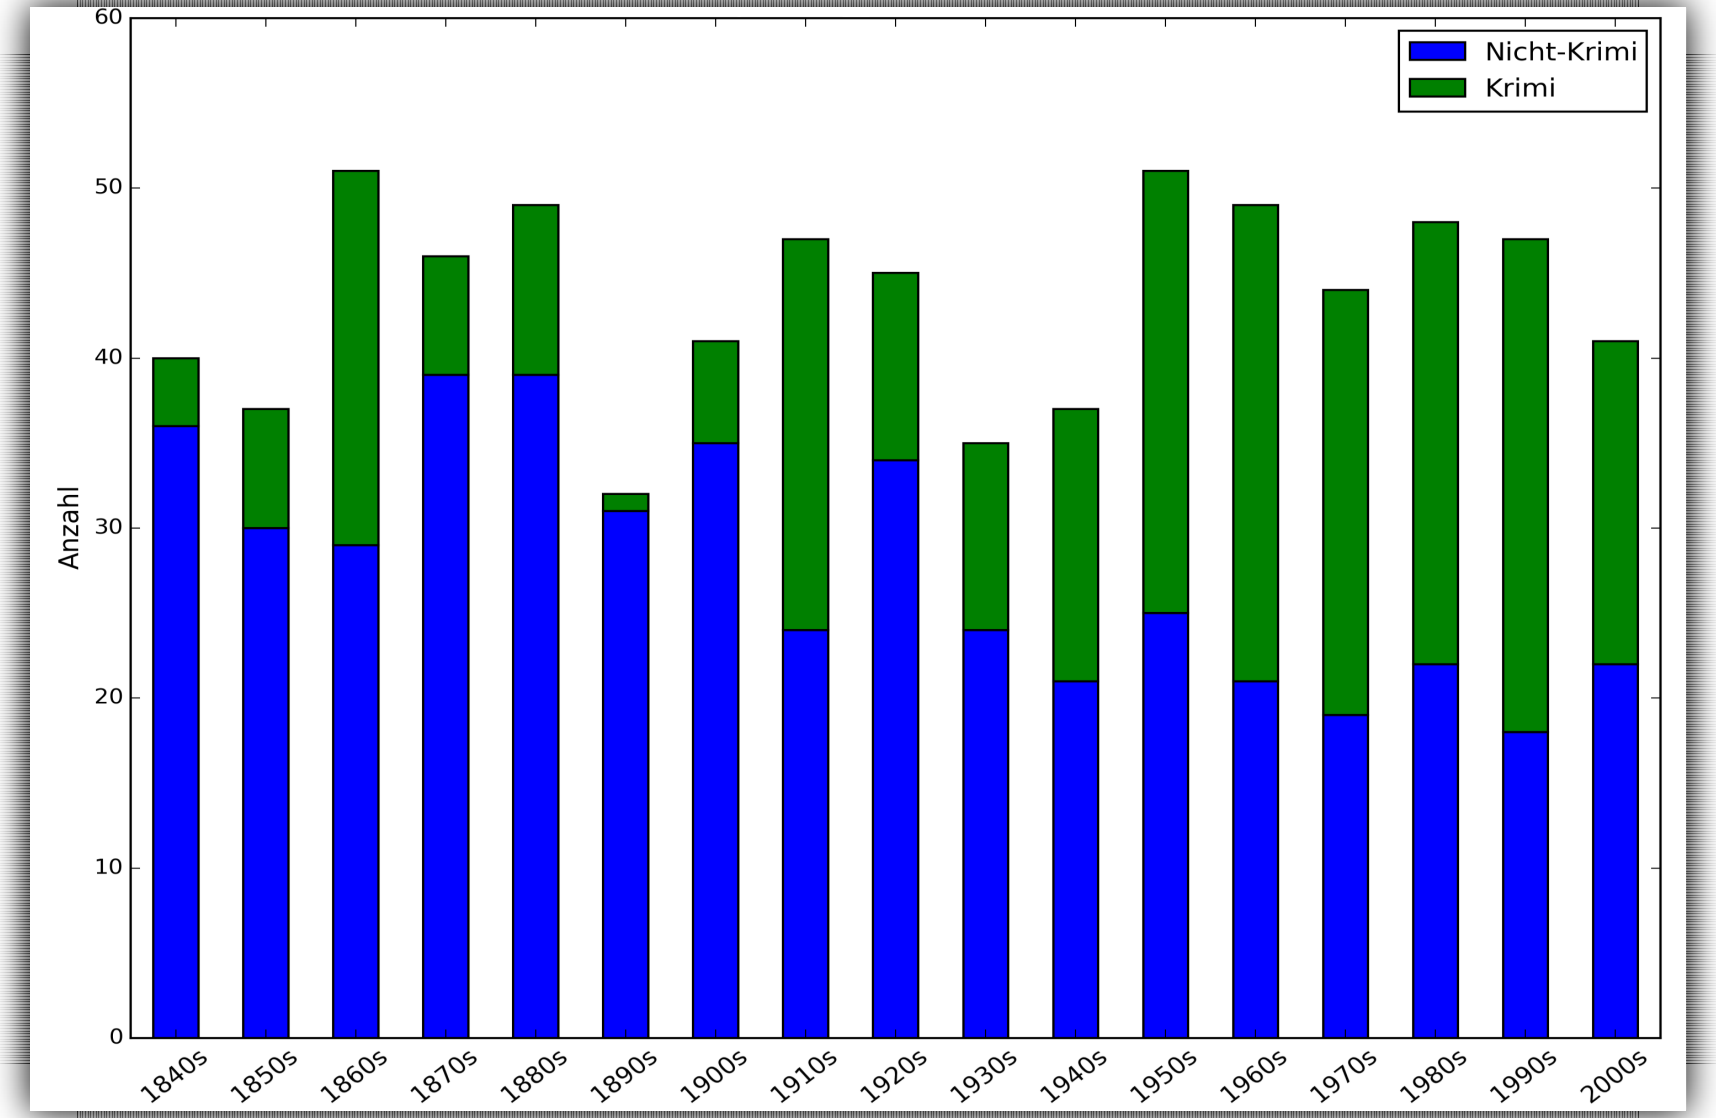

Metadaten

idno	author-name	gender	title	year	subgenre	subsubgenre	narration	protagonist	setting
rf0021	Daudet	male	PortTarascon	1890	blanche	adventure	heterodiegetic	n.av.	n.av.
rf0623	FevalPP	male	ReineEpees	1852	blanche	adventure	heterodiegetic	n.av.	n.av.
rf0622	FevalPP	male	Quittance2Galerie	1846	blanche	adventure	heterodiegetic	n.av.	n.av.
rf0621	FevalPP	male	Quittance1Heritiere	1846	blanche	adventure	n.av.	n.av.	n.av.
rf0636	FevalPP	male	Louve1	1855	blanche	adventure	heterodiegetic	n.av.	n.av.
rf0615	FevalPP	male	LoupBlanc	1843	blanche	adventure	n.av.	n.av.	rural
rf0610	FevalPP	male	FilsDiable1	1846	blanche	adventure	heterodiegetic	n.av.	n.av.
rf0633	FevalPP	male	Bossu	1857	blanche	adventure	n.av.	n.av.	n.av.
rf0487	Giono	male	HussardToit	1951	blanche	adventure	heterodiegetic	criminal	rural
rf0176	Verne	male	TestamentExcentrique	1899	blanche	adventure	heterodiegetic	n.av.	mixed
rf0731	Barbara	male	AssassinatPontRouge	1855	policier	archaique	n.av.	n.av.	n.av.
rf1263	BoilNarc	male	SermentLupin	1987	policier	archaique	heterodiegetic	criminal	n.av.
rf1262	BoilNarc	male	SecretEunerville	1986	policier	archaique	heterodiegetic	mixed	rural
rf1261	BoilNarc	male	SecondVisageLupin	1986	policier	archaique	heterodiegetic	criminal	n.av.
rf1260	BoilNarc	male	Poudriere	1987	policier	archaique	heterodiegetic	criminal	n.av.
rf1184	Boisgobey	male	RubisOngle	1886	policier	archaique	heterodiegetic	victime	urban
rf1003	Boisgobey	male	DoubleBlancB	1889	policier	archaique	heterodiegetic	criminal	urban
rf0628	FevalPP	male	MysteresLondres3	1843	policier	archaique	heterodiegetic	criminal	urban
rf0627	FevalPP	male	MysteresLondres2	1843	policier	archaique	heterodiegetic	criminal	n.av.
rf0614	FevalPP	male	HommeSansBras	1881	policier	archaique	heterodiegetic	victim	n.av.
rf0607	FevalPP	male	ErrantsNuit	1857	policier	archaique	heterodiegetic	victim	rural
rf1159	Gaboriau	male	MonsieurLecoq2	1869	policier	archaique	heterodiegetic	detective	urban
rf1158	Gaboriau	male	MonsieurLecoq1	1869	policier	archaique	heterodiegetic	detective	urban
rf1155	Gaboriau	male	CrimeOrcival	1866	policier	archaique	heterodiegetic	detective	rural
rf1152	Gaboriau	male	CordeCou2	1873	policier	archaique	heterodiegetic	suspect	rural
rf1151	Gaboriau	male	CordeCou1	1873	policier	archaique	heterodiegetic	suspect	rural
rf1150	Gaboriau	male	AmoursEmpoisonneuse	1881	policier	archaique	heterodiegetic	criminal	n.av.
rf0361	Galopin	male	MemoiresCambrioleur	1922	policier	archaique	homodiegetic	criminal	urban

3. Methode: Topic Modeling

Topic Modeling

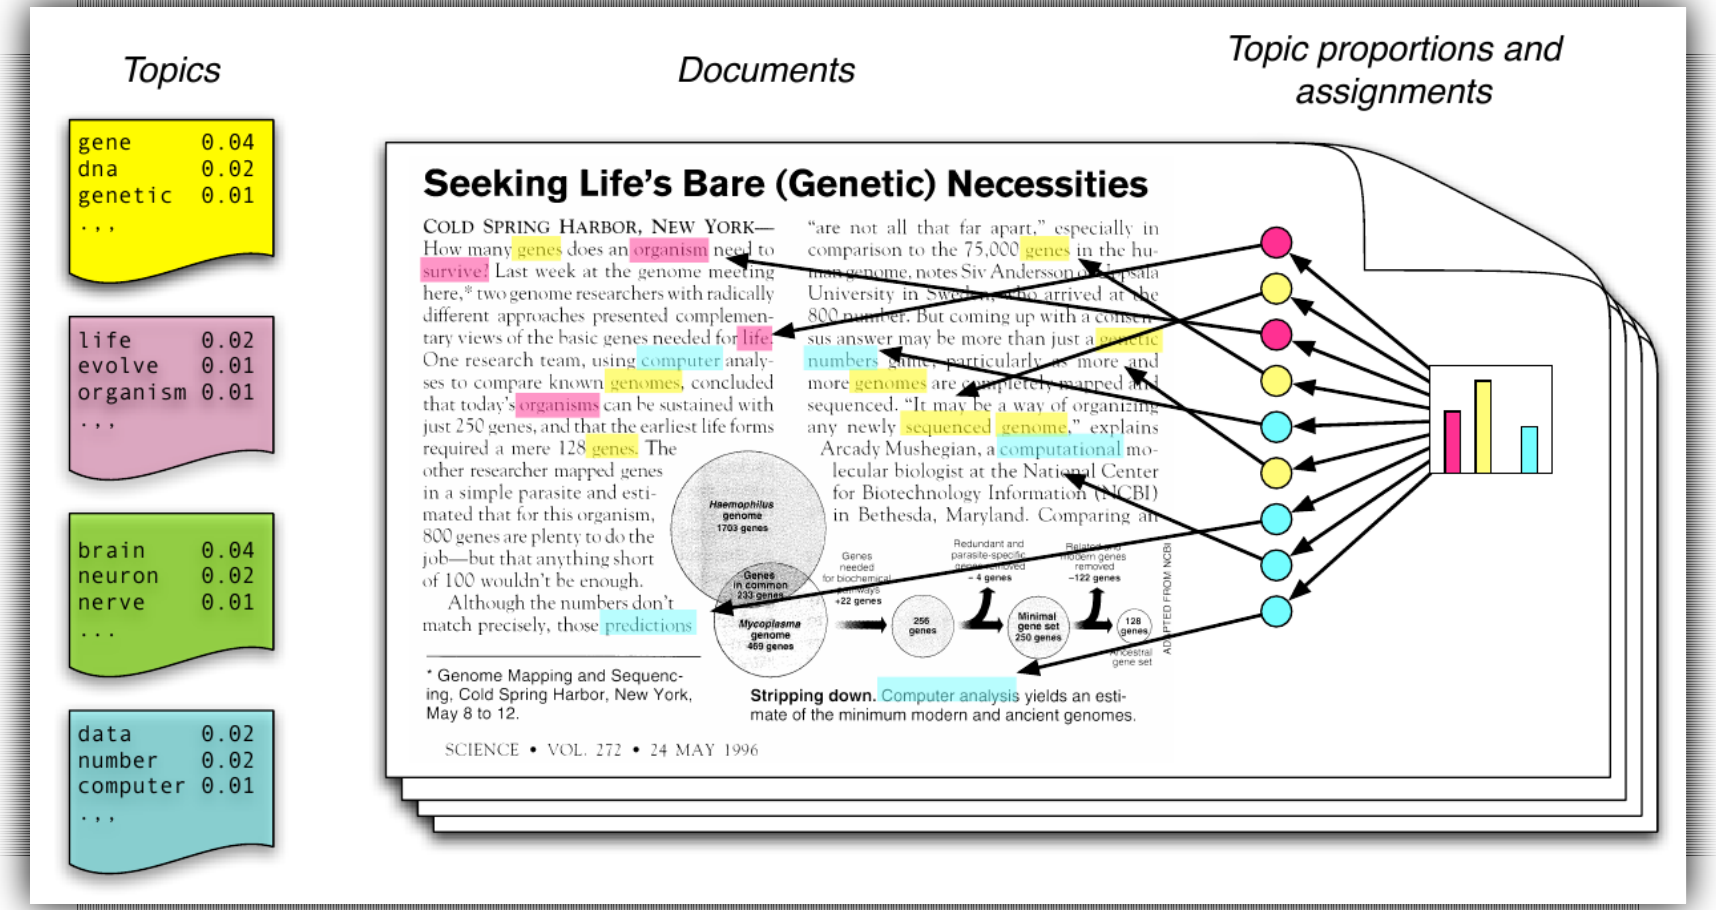

Topic Modeling

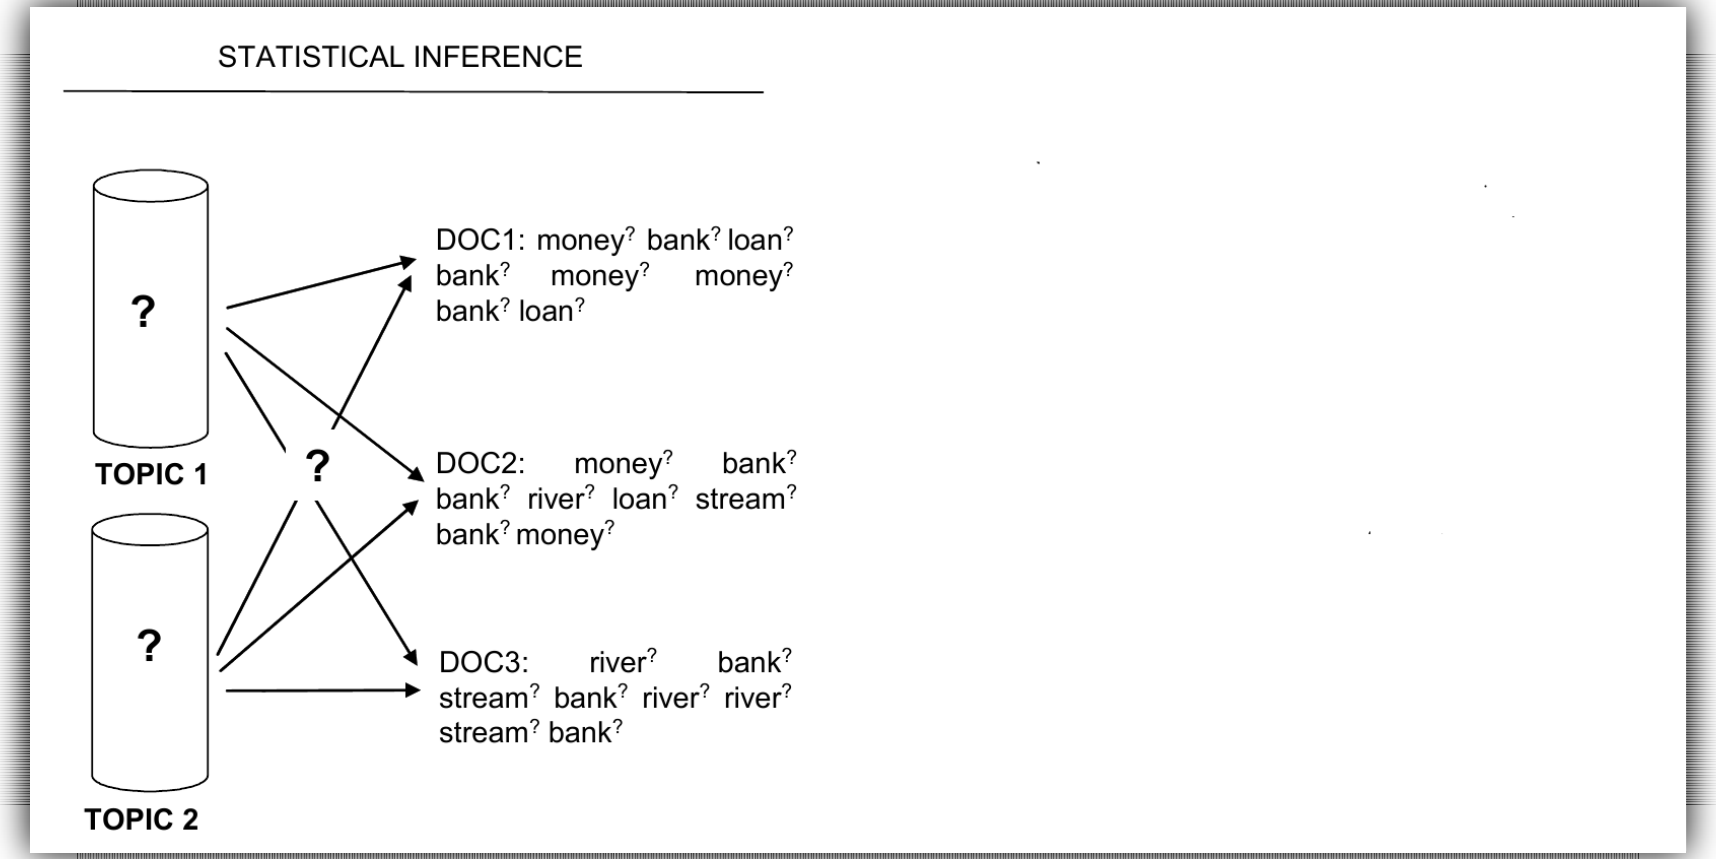

Topic Modeling

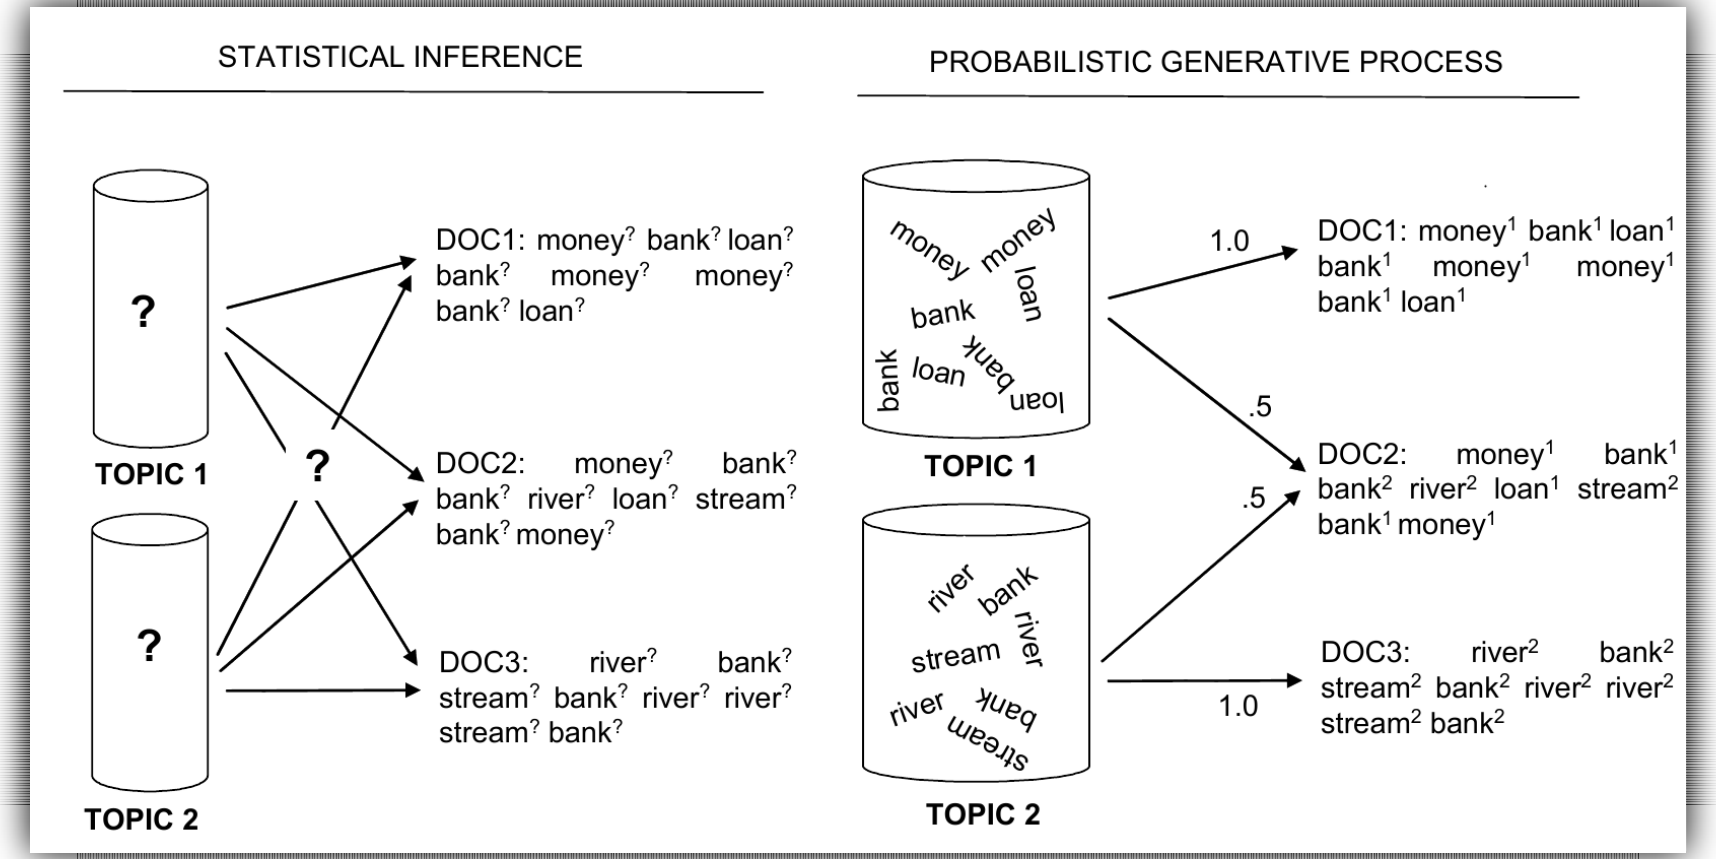

tmw (Python-Skripte)

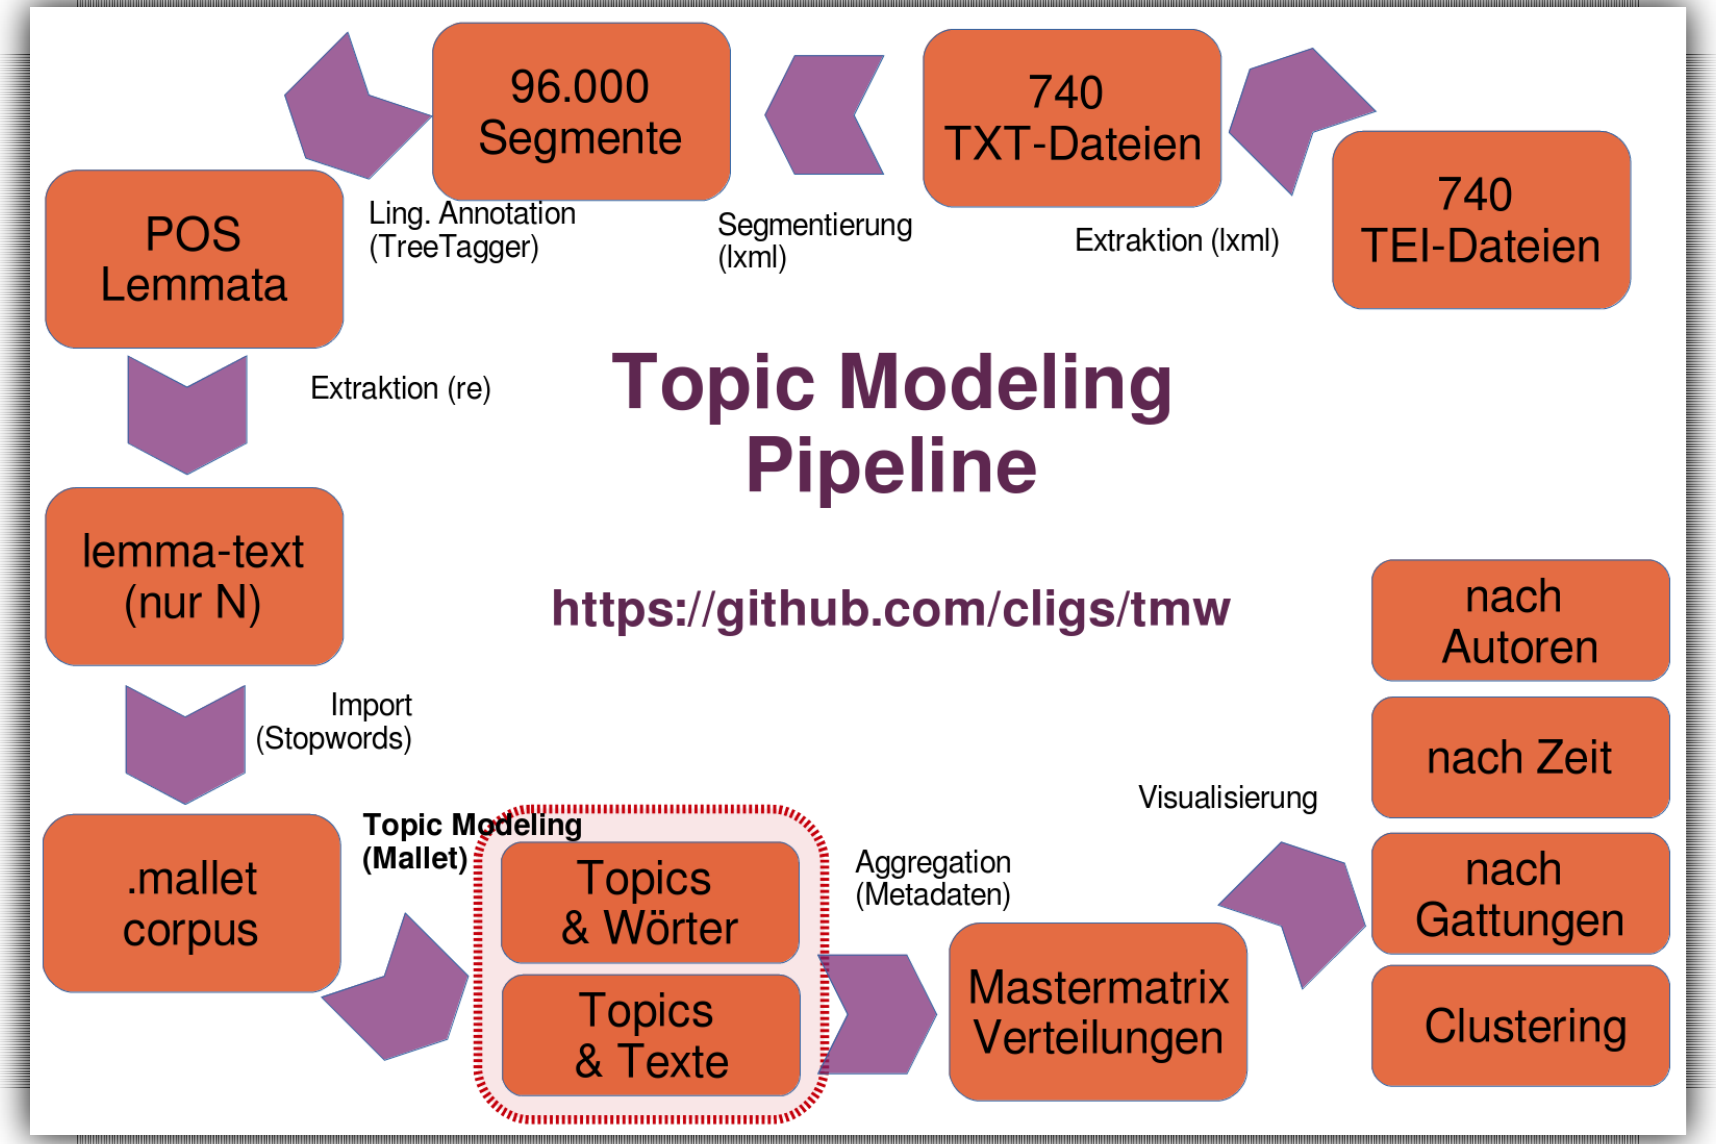

Topic Modeling: Anwendungen

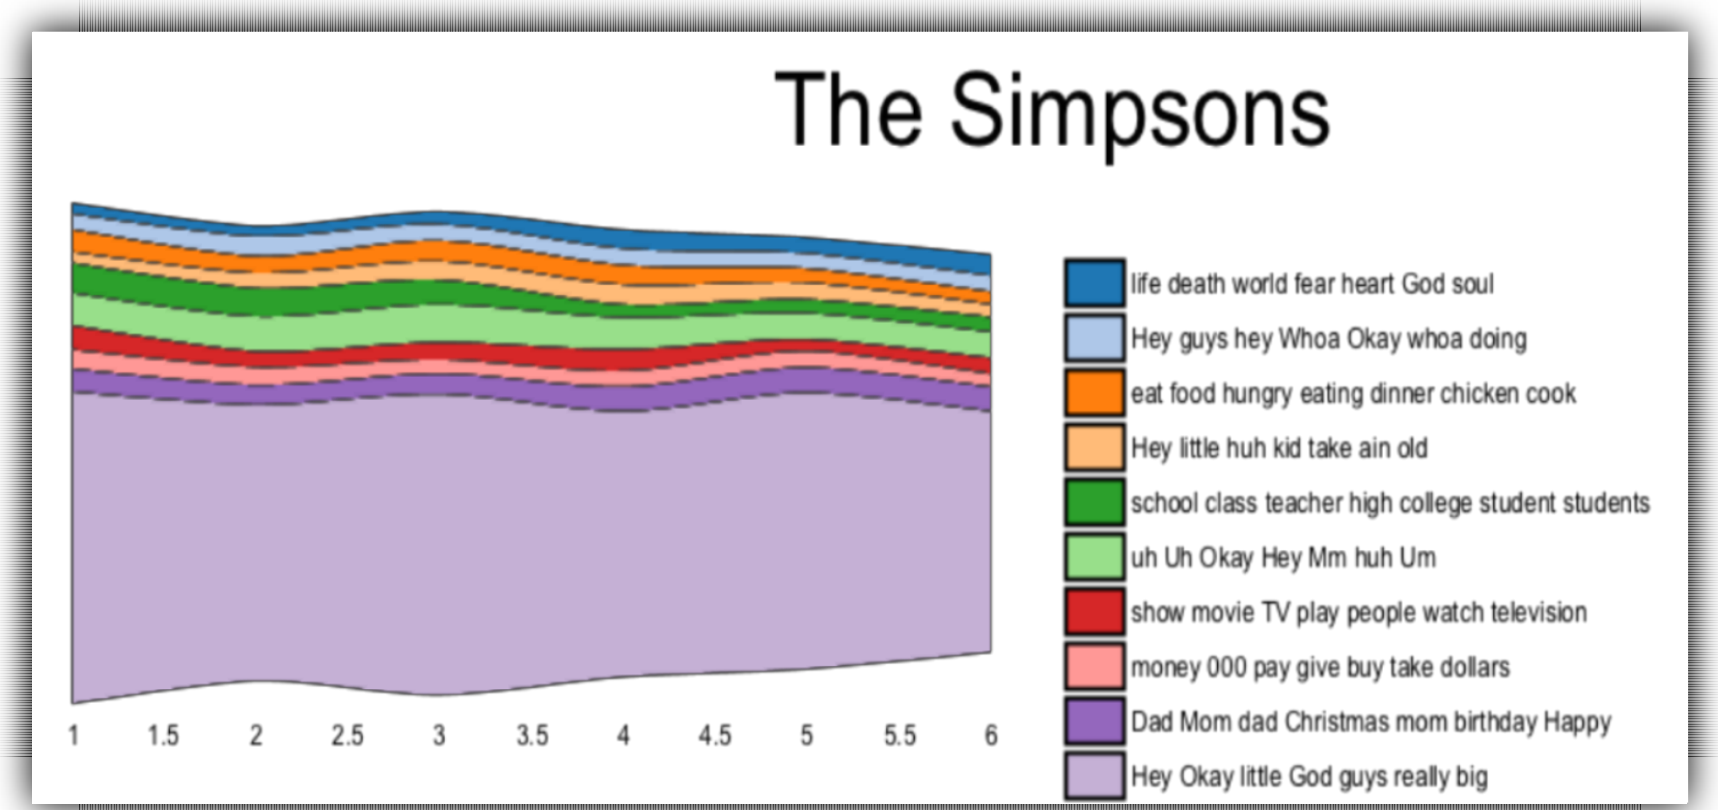

http://sappingattention.blogspot.com/ (Ben Schmidt)

Topic Modeling: Anwendungen

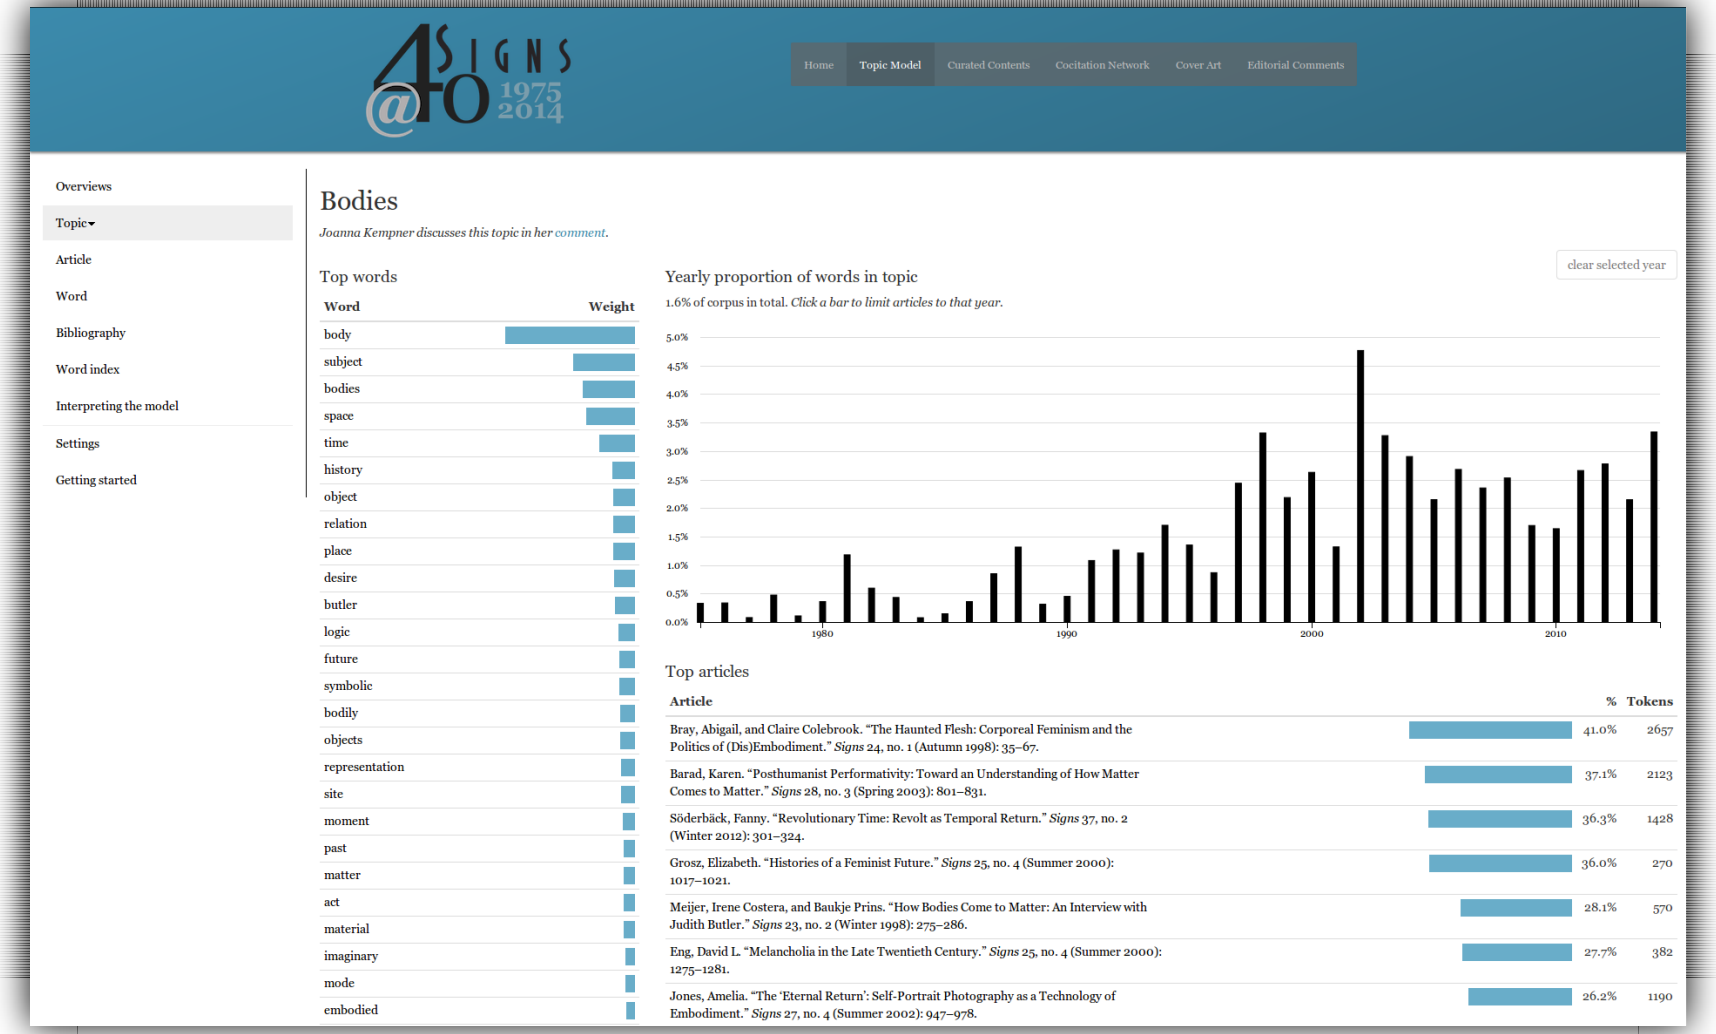

http://signsat40.signsjournal.org/topic-model/ (Andrew Goldstone)

Topic Modeling: Anwendungen

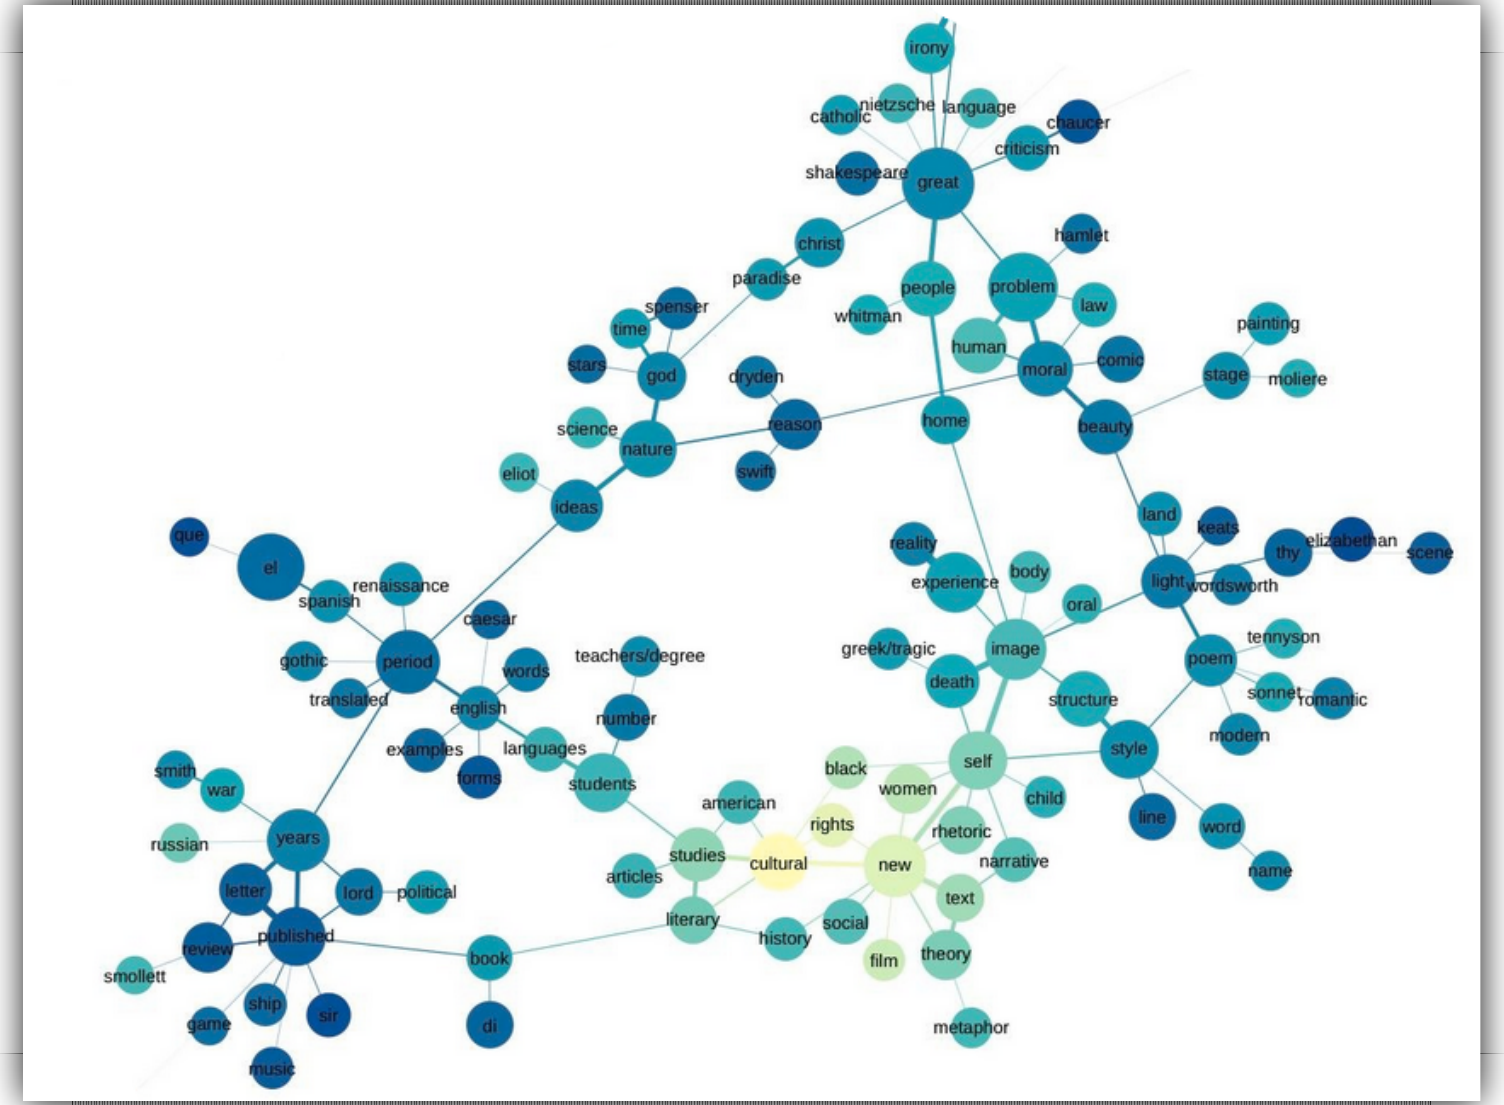

http://pmla.site44.com/ (Ted Underwood)

4. Perspektiven auf die Gesamtsammlung

Überblick

- Typen von Topics
  - nach Semantik
  - nach Struktur
  - nach Verteilung
- Ähnlichkeit von Topics
- Topics über die Zeit
- Romane nach Topics

Typen von Topics

Personal

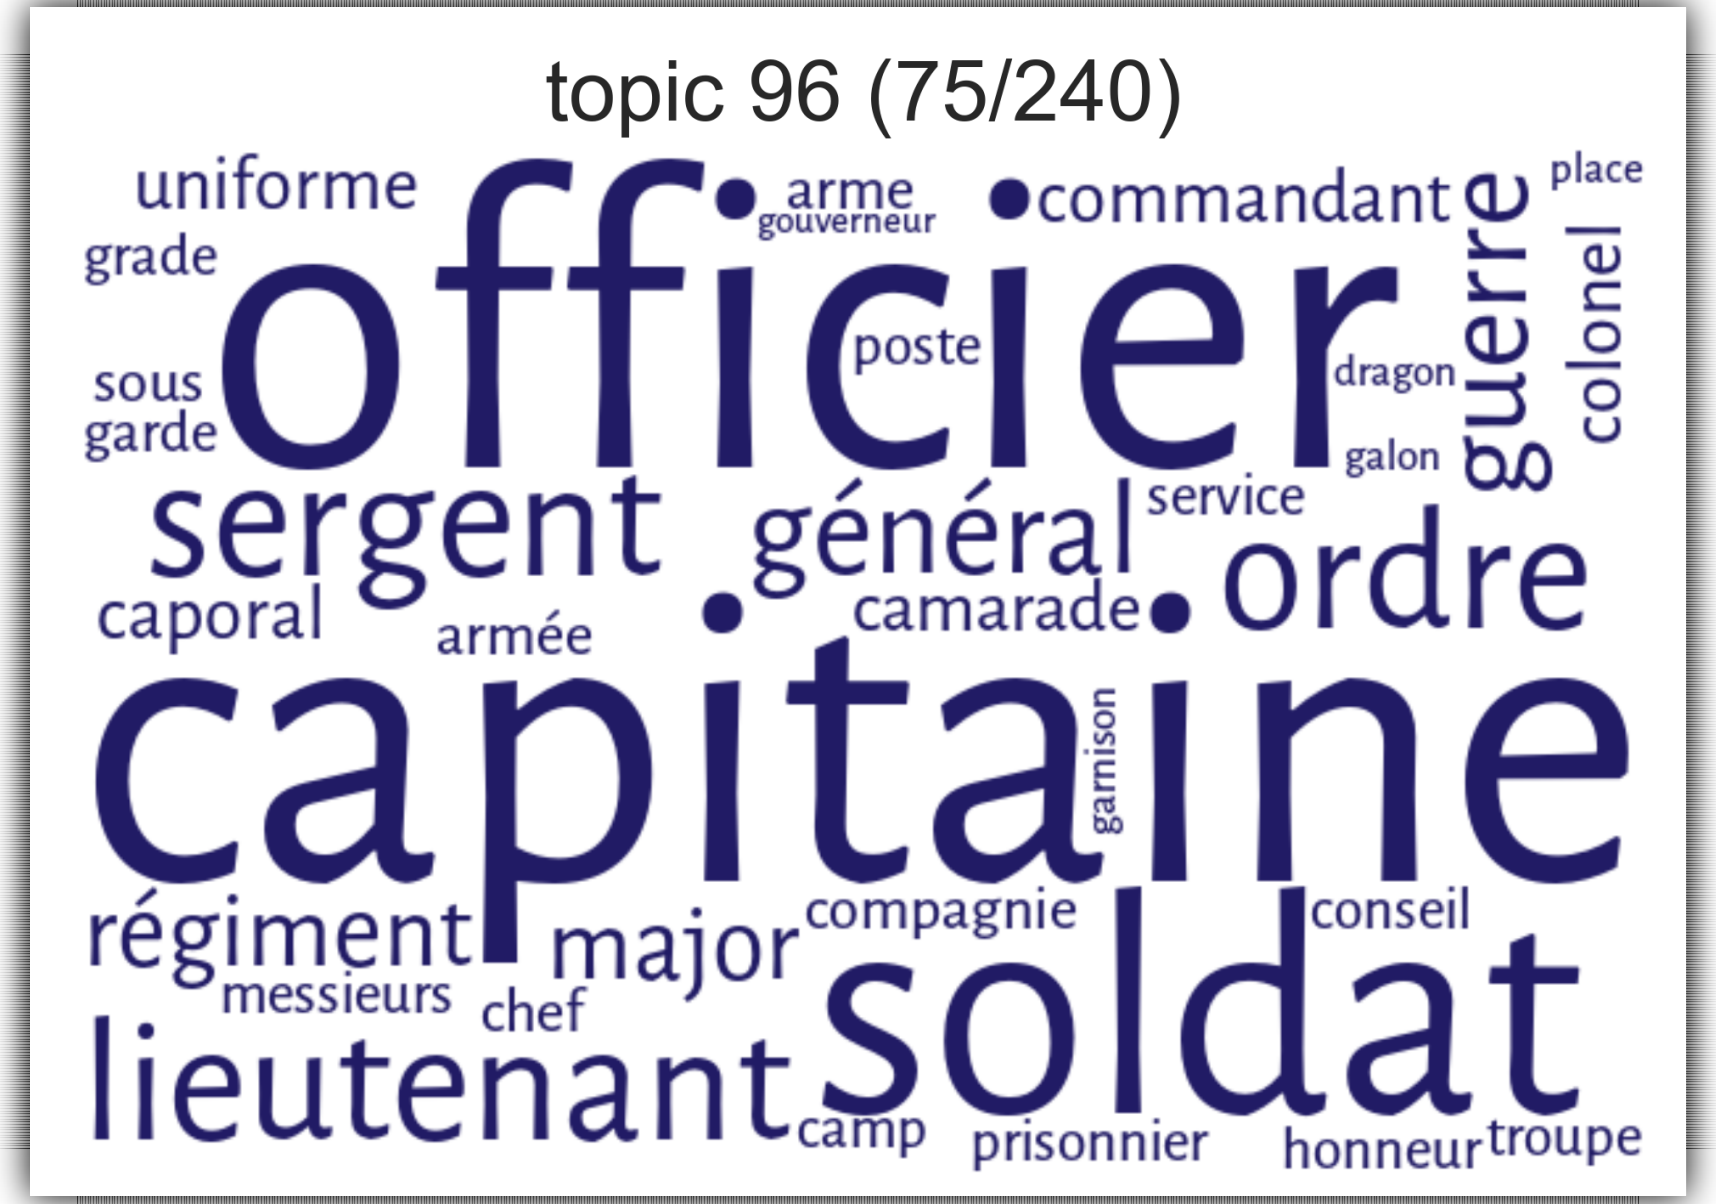

Offizier, Hauptmann, Soldat

Personal

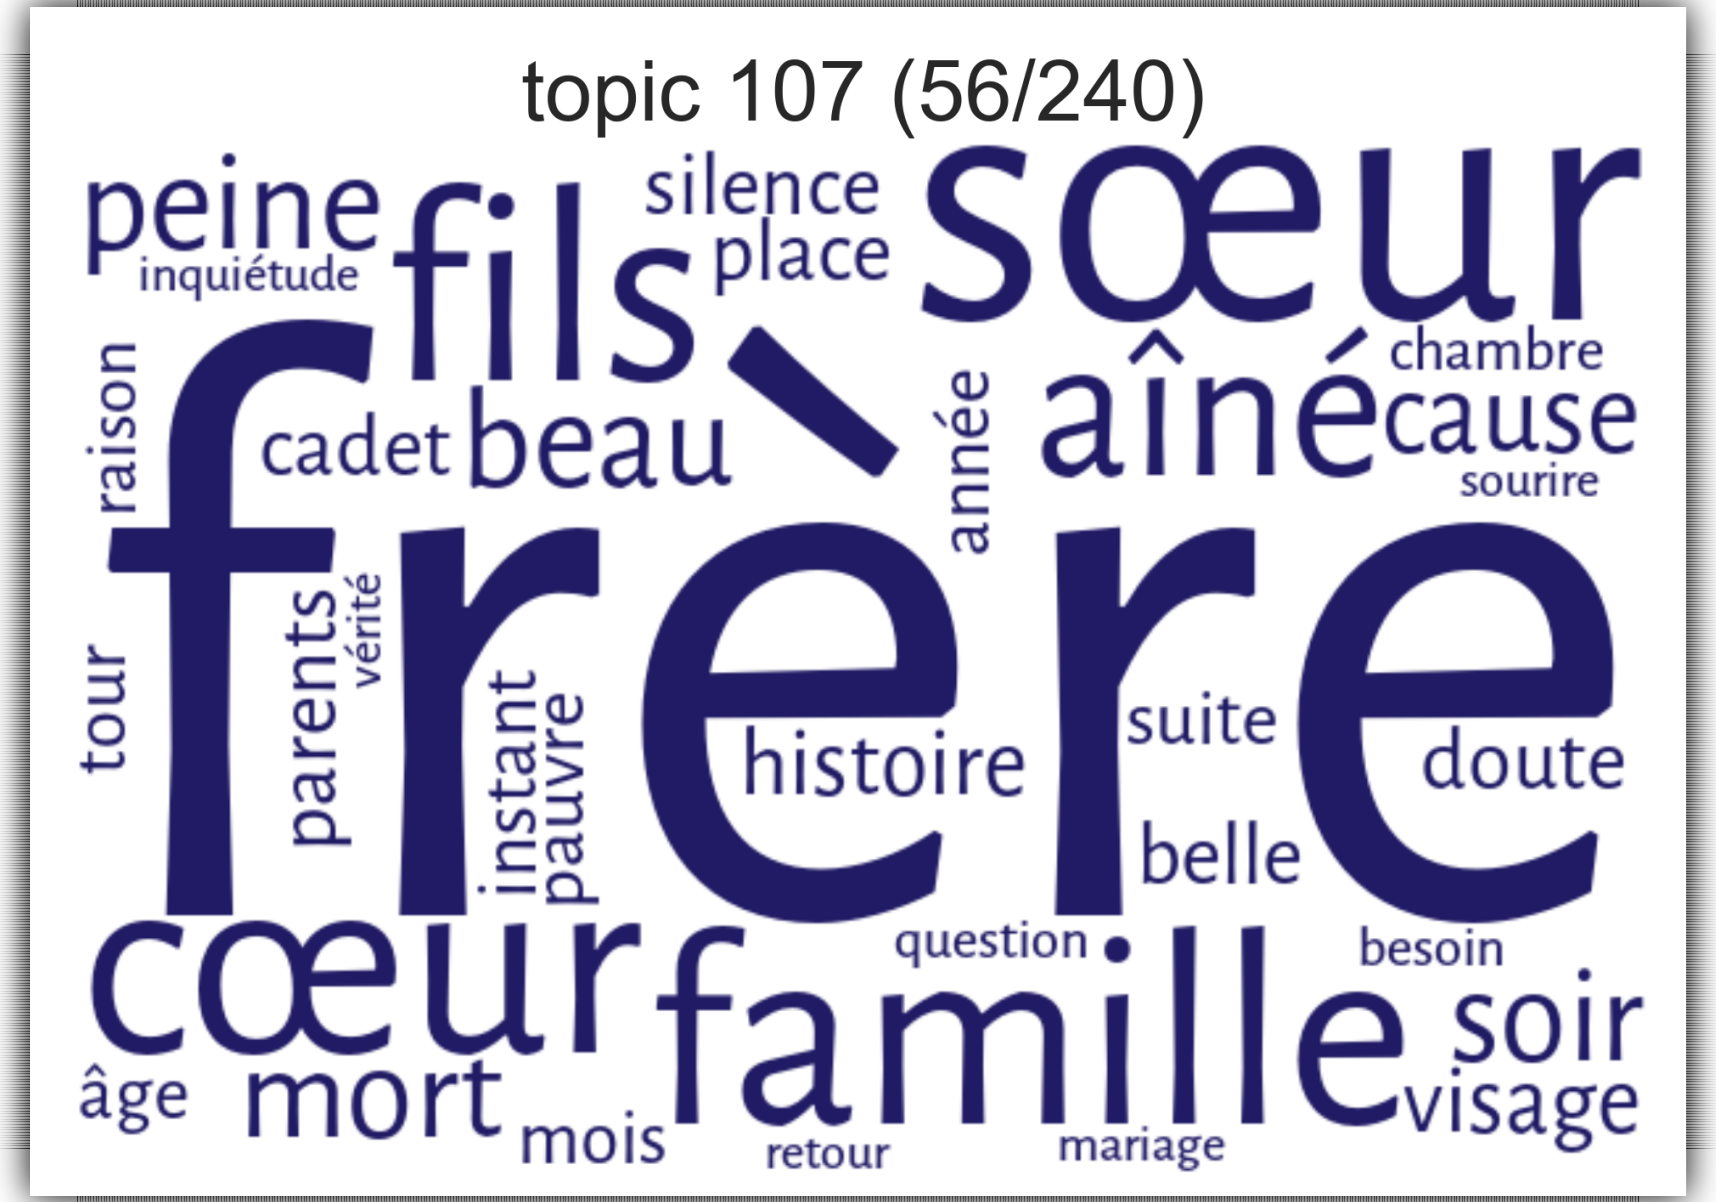

Bruder, Schwester, Familie

Setting

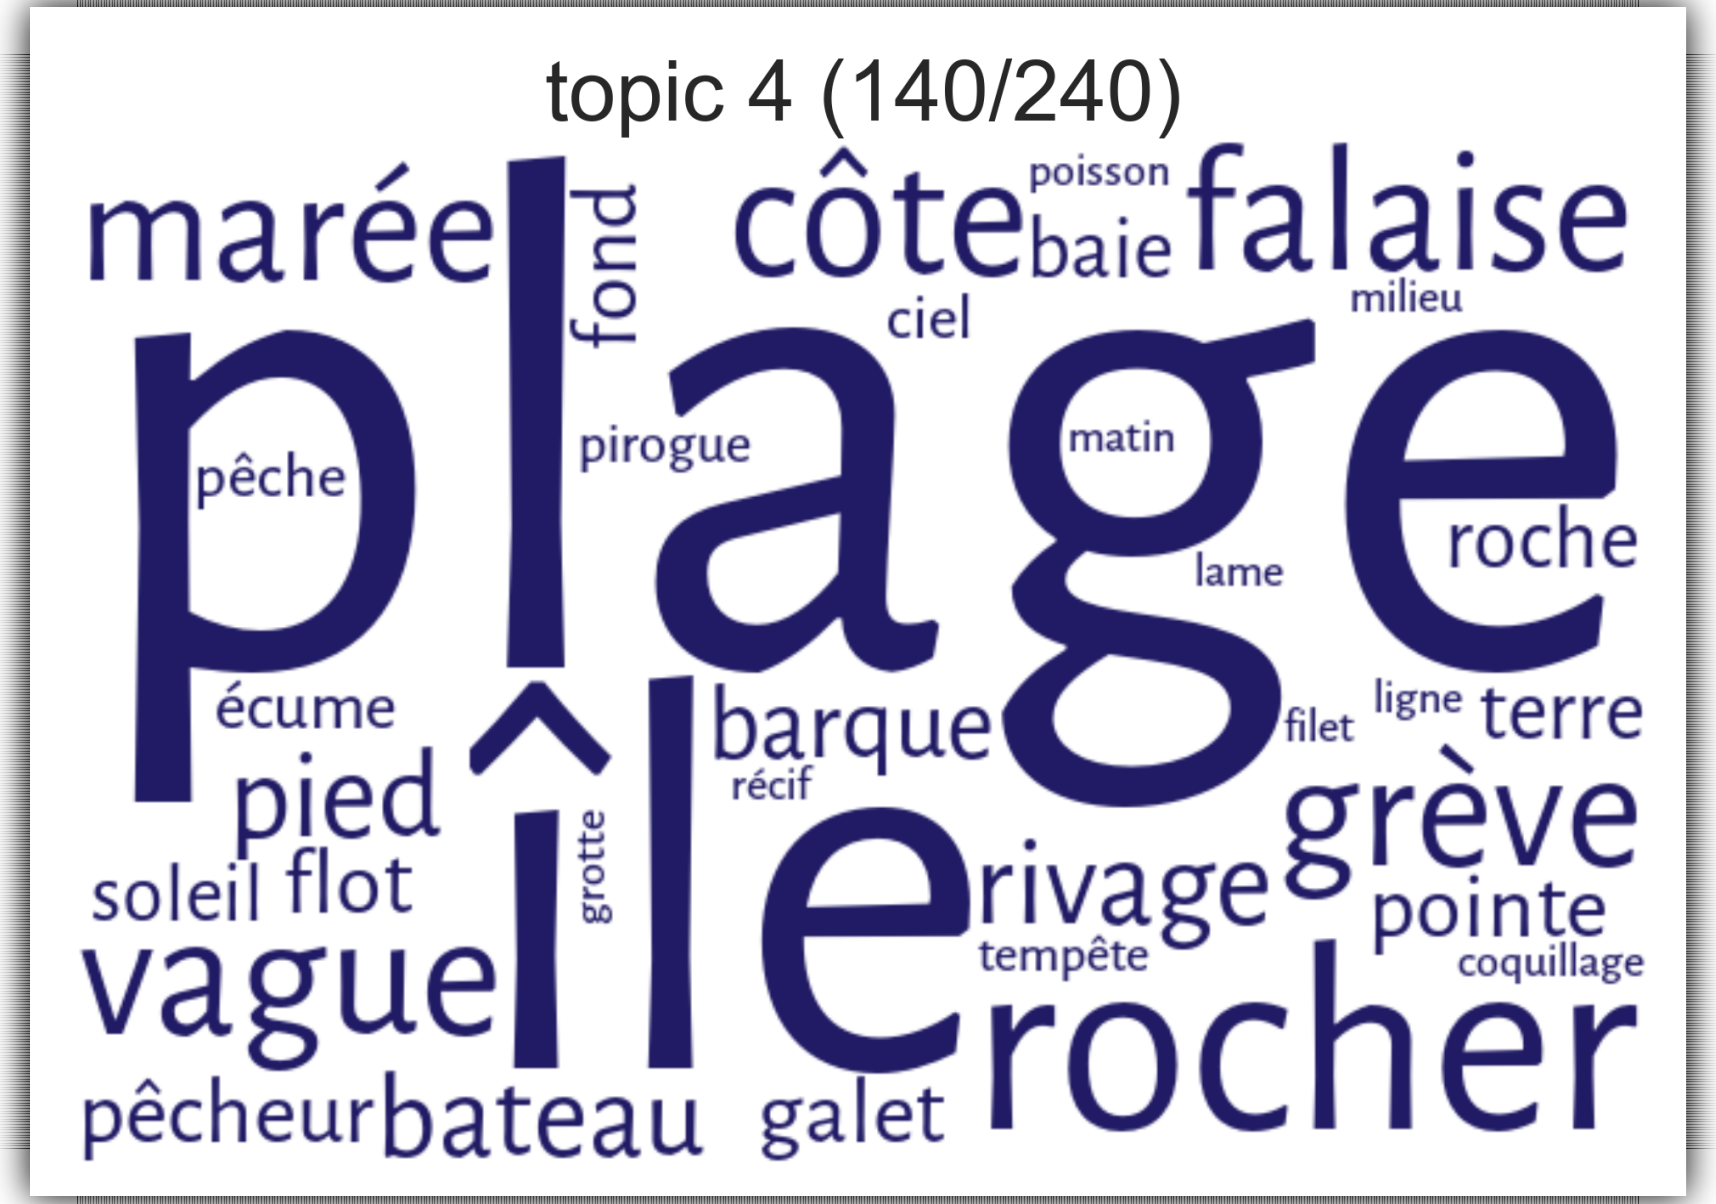

Strand, Insel, Felsen

Setting

Schloß, Turm, Ruine

Handlungsmotiv

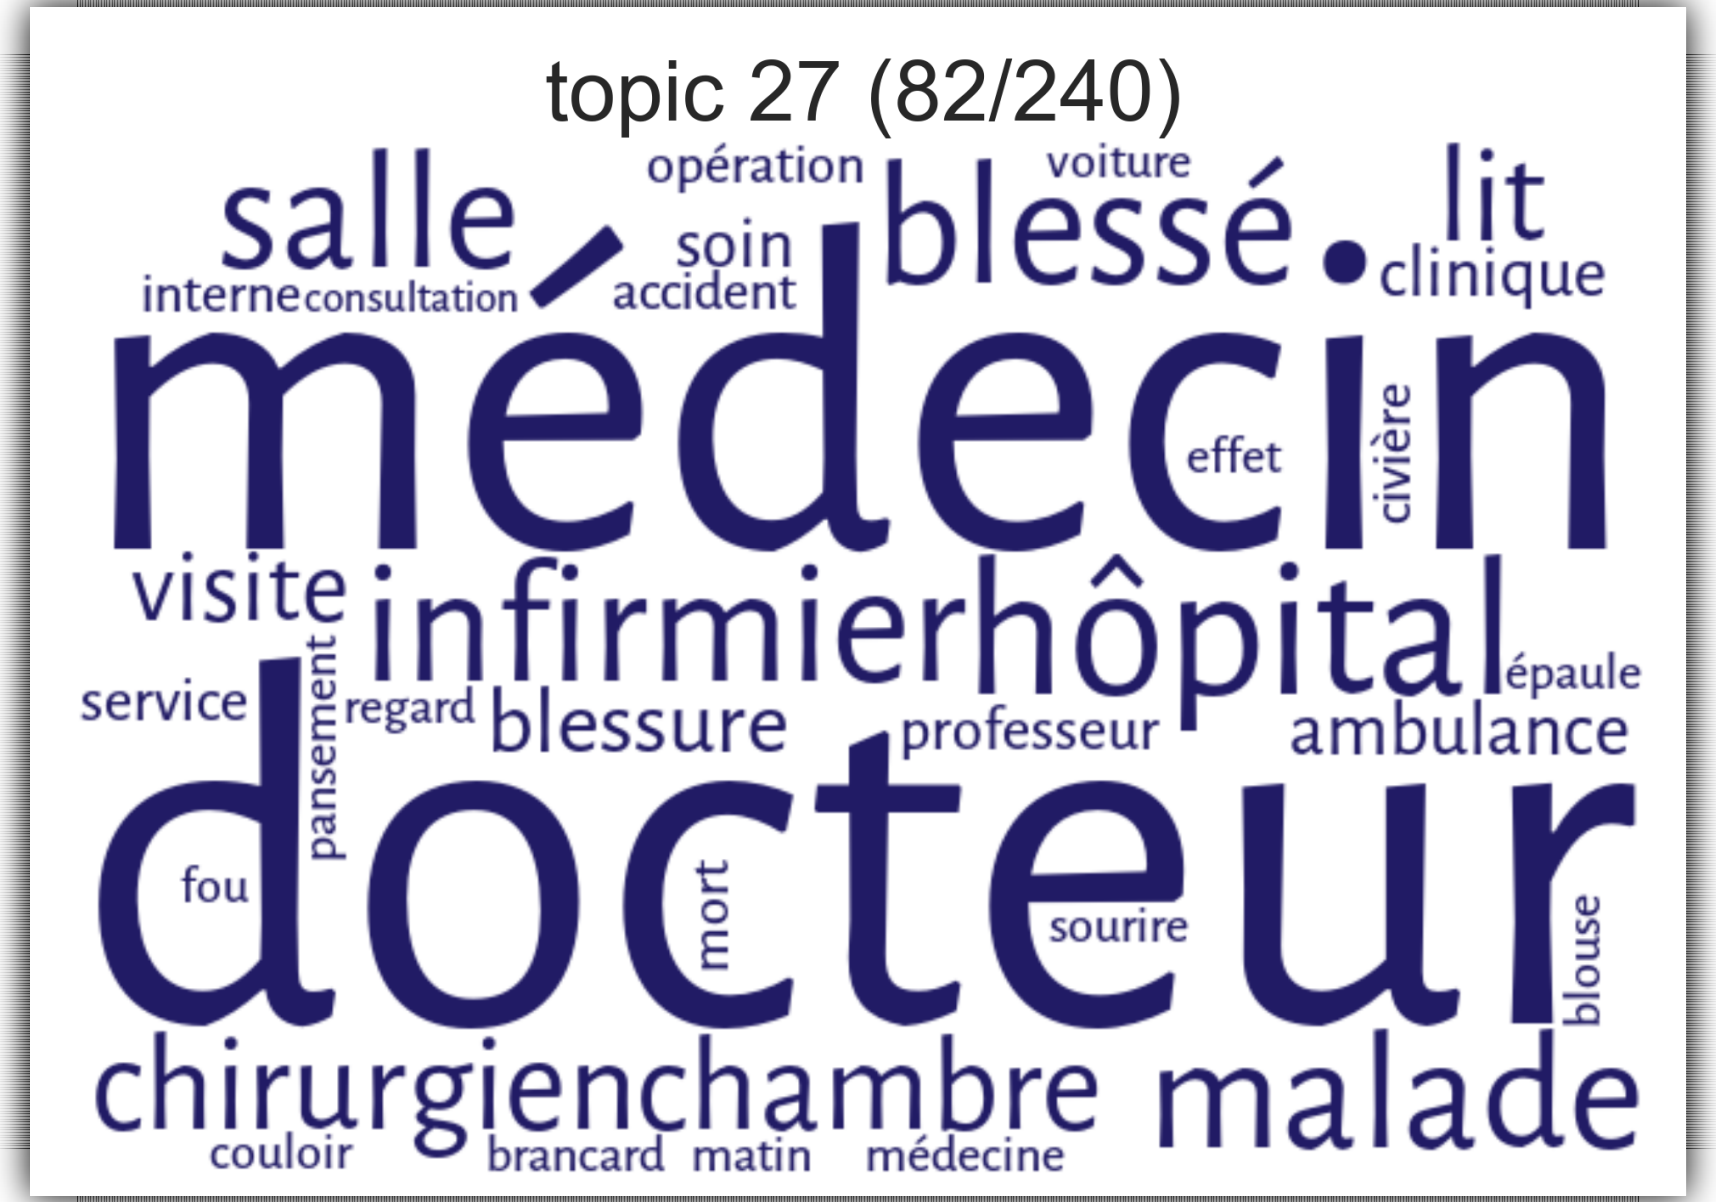

Doktor, Arzt, Verletzter

Handlungsmotiv

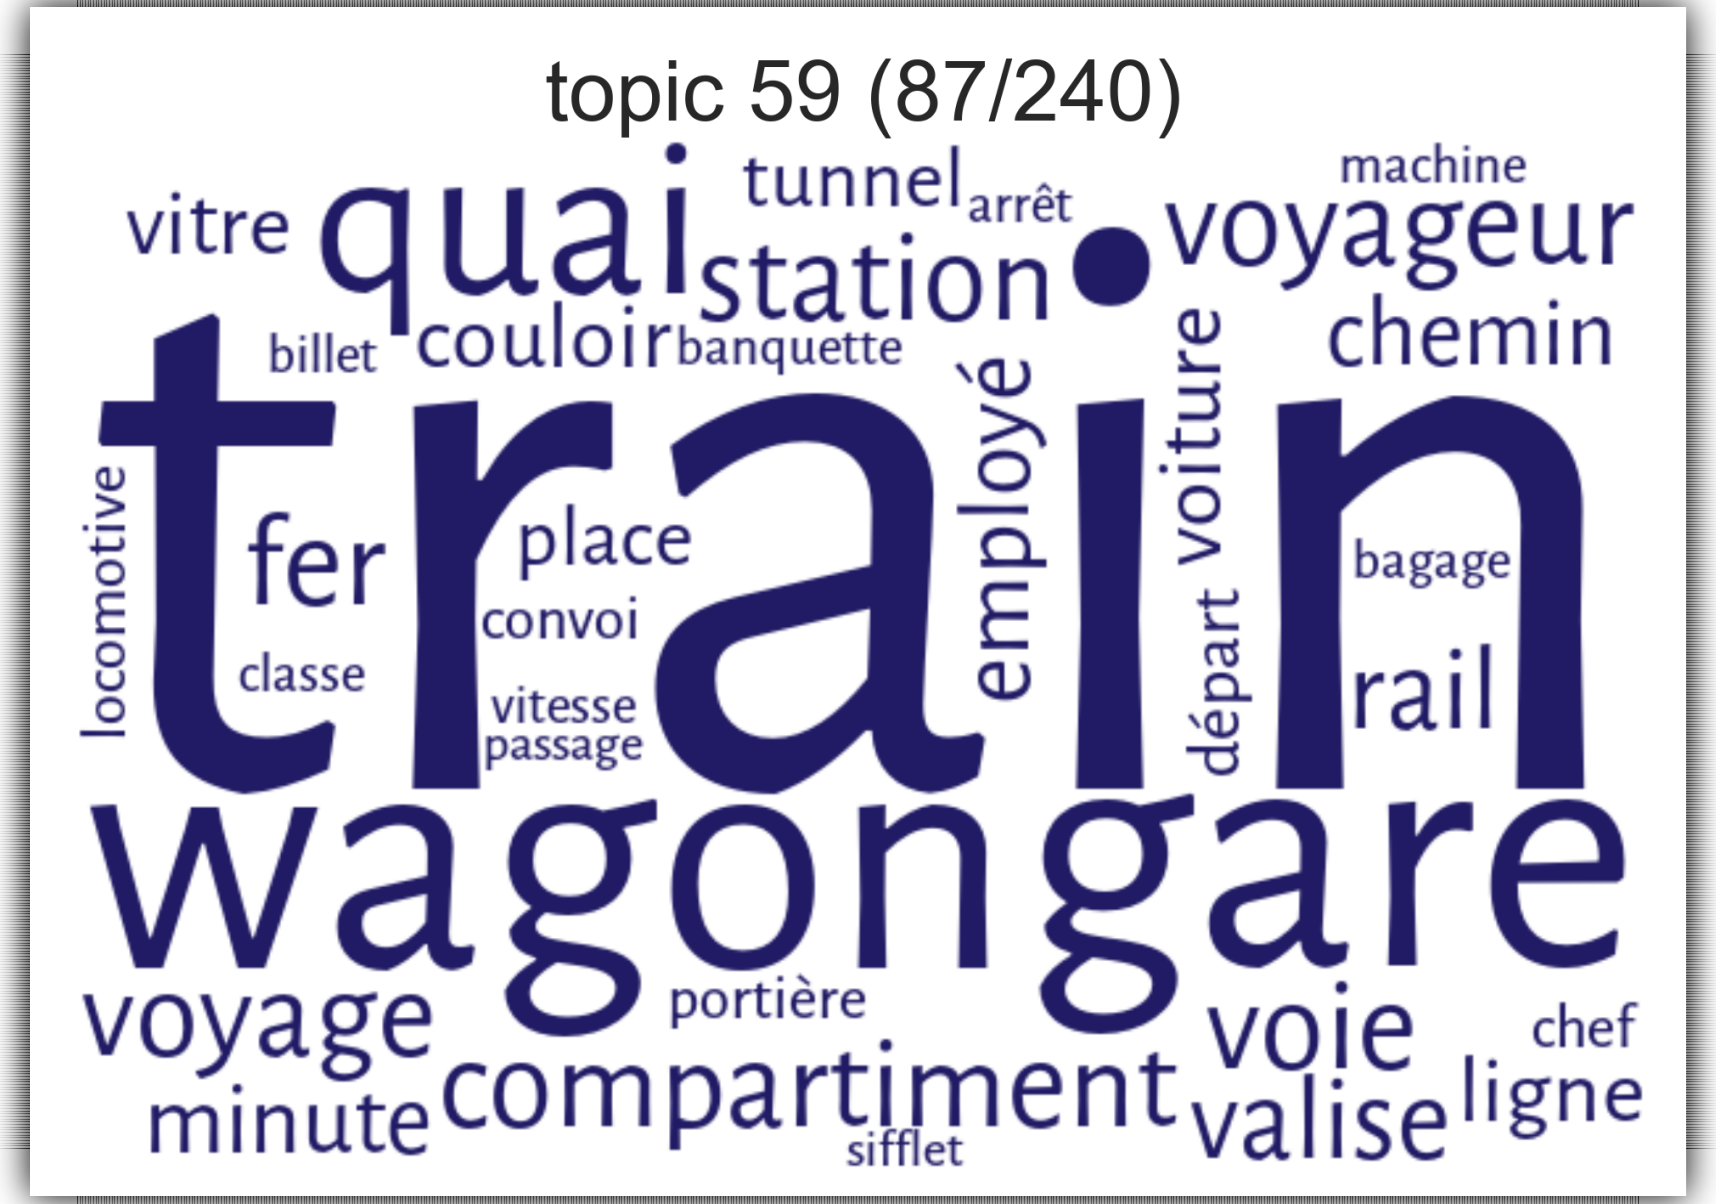

Zug, Waggon, Bahnhof

Künste

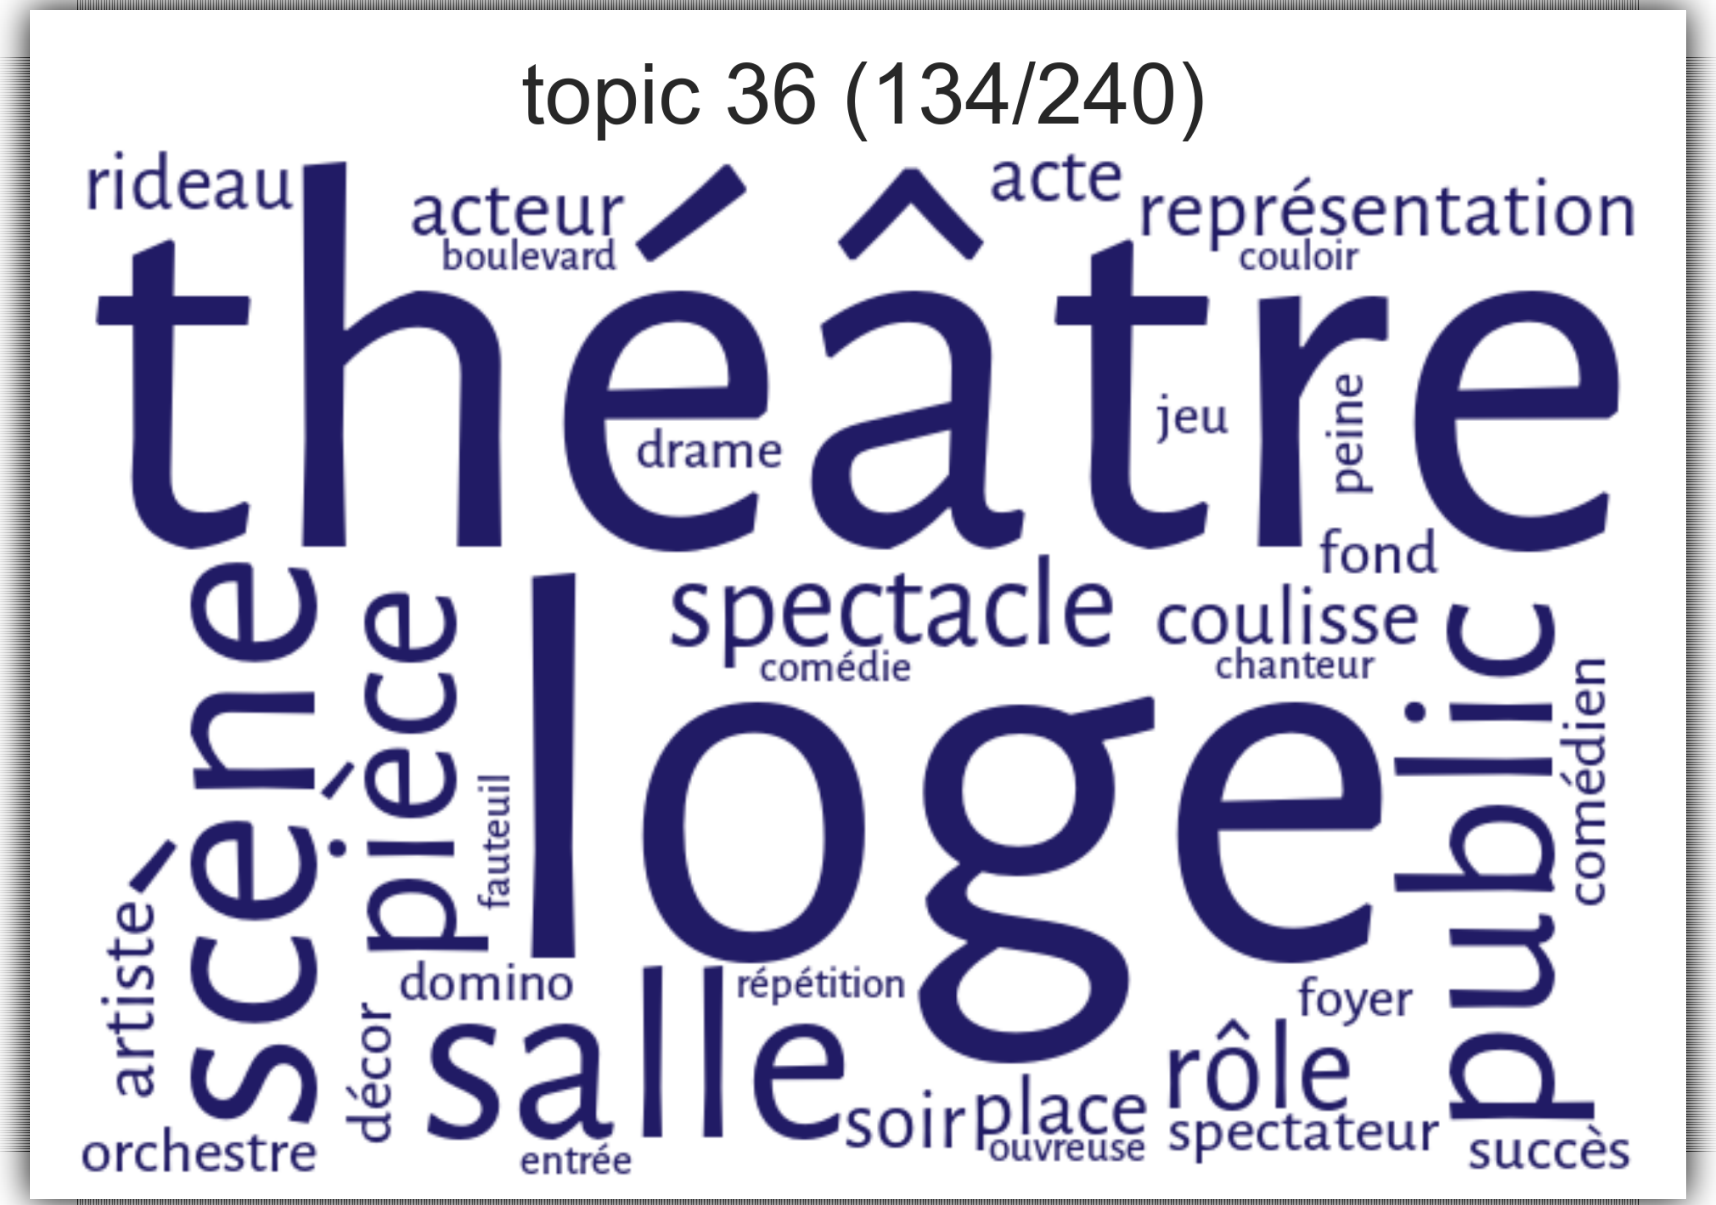

Theater, Loge, Bühne

Künste

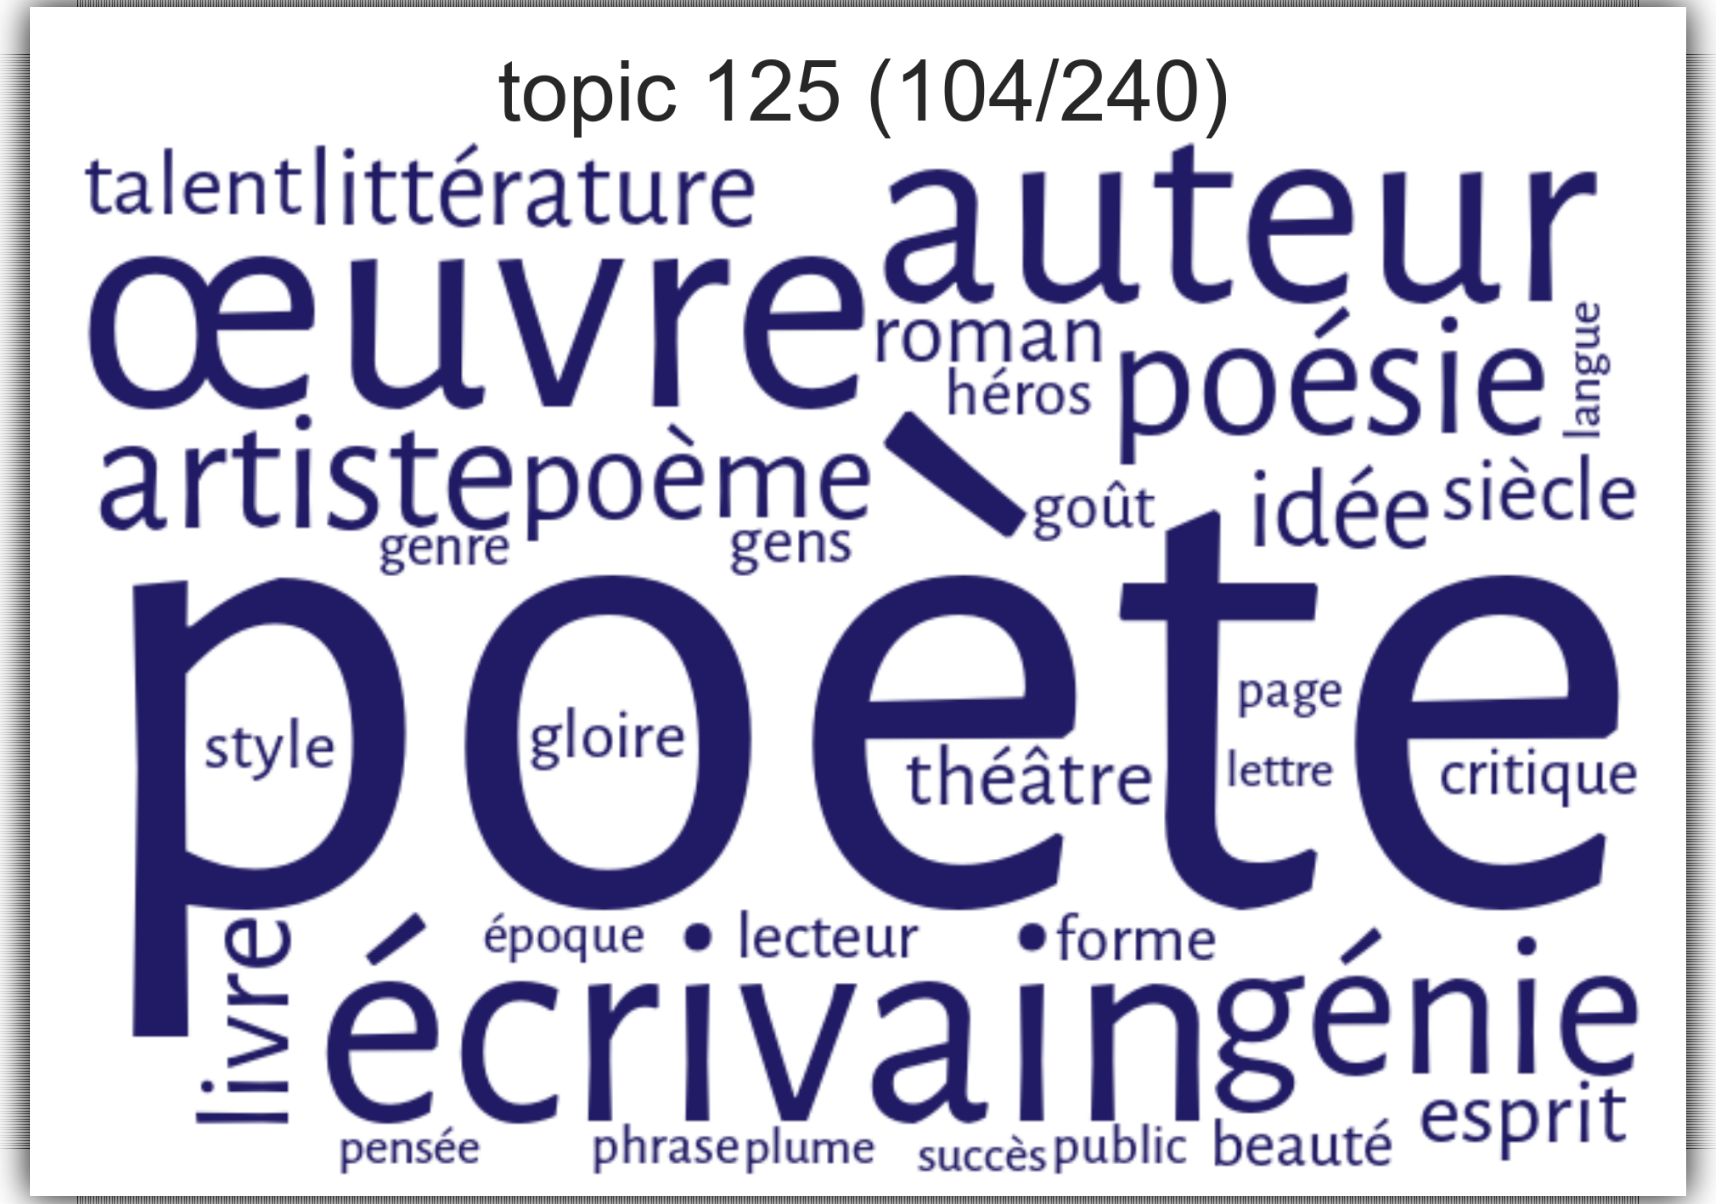

Dichter, Werk, Autor, Schriftsteller

Meta-Topics

Sprache, Phrase, Sprache

Meta-Topics

Geschichte, Erzählung, Detail

Register (umgangssprachlich)

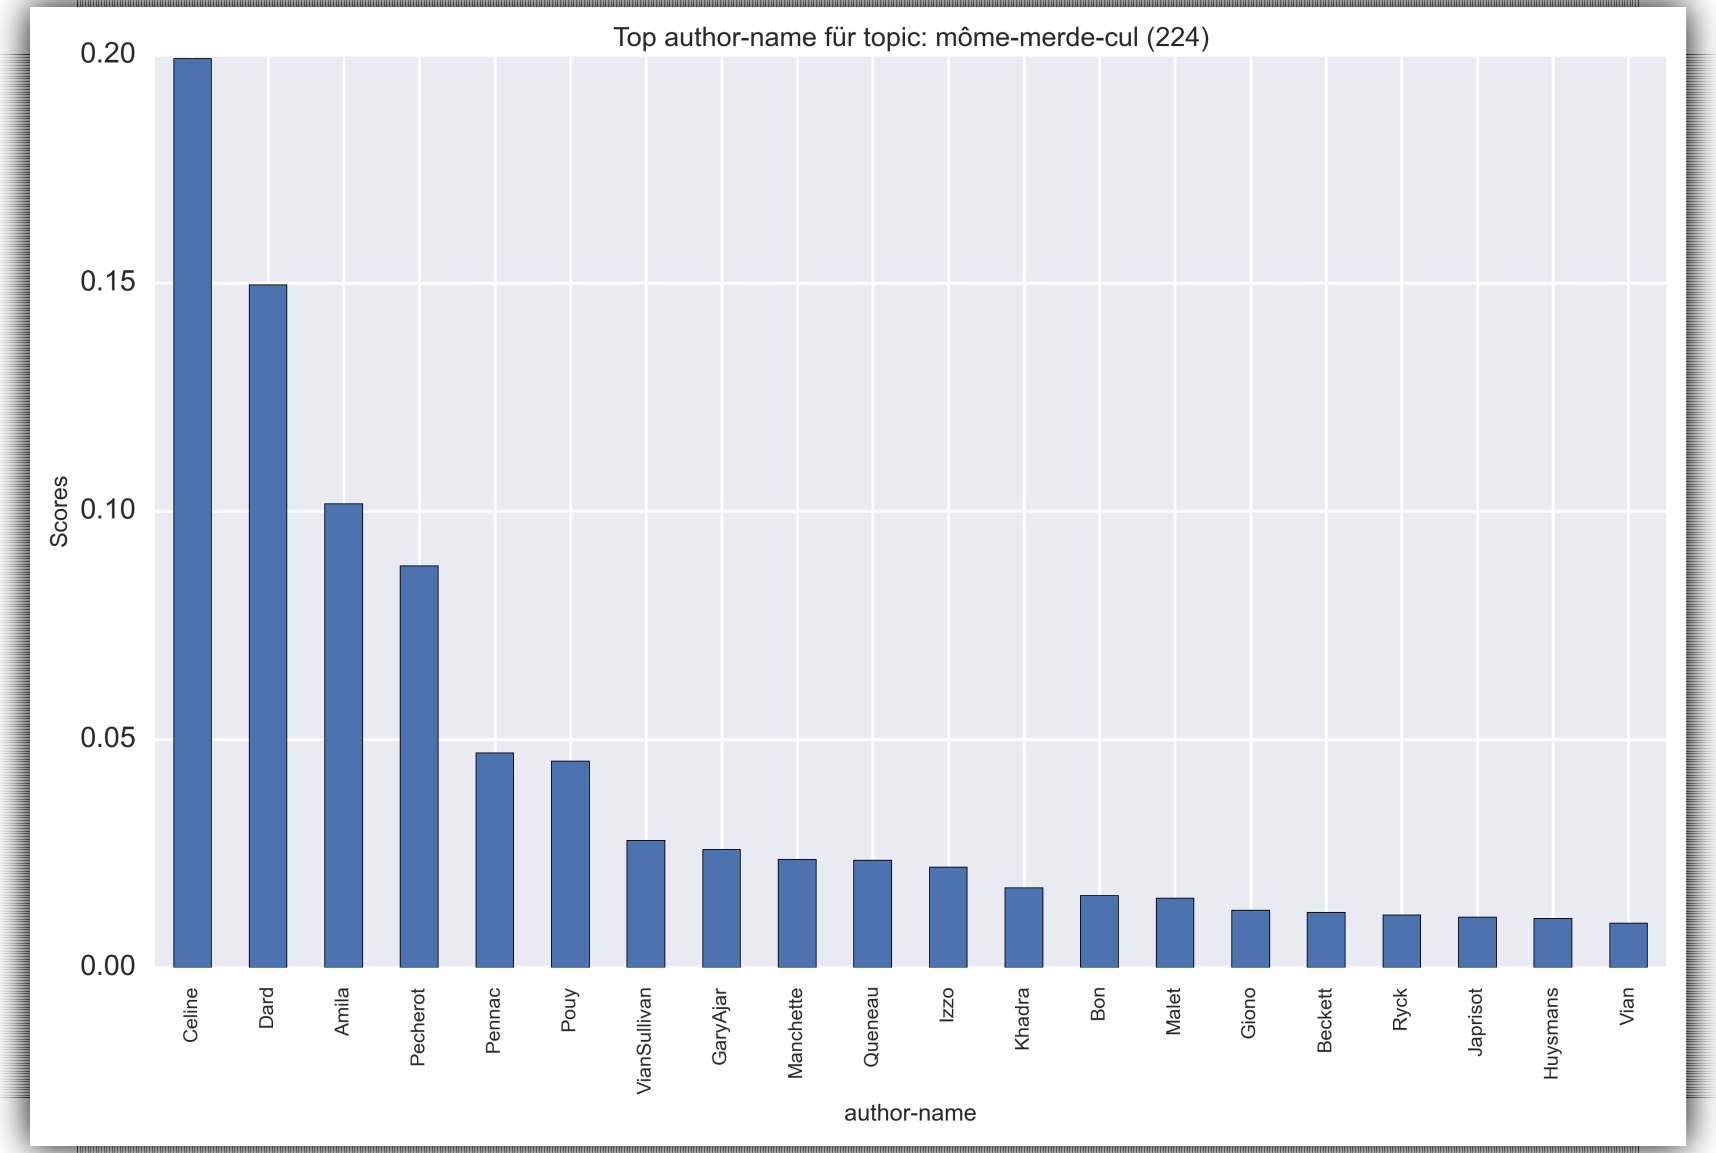

Kleine/r, Hintern, Sch**ße

Themen

Krieg, Regierung, Volk

Themen

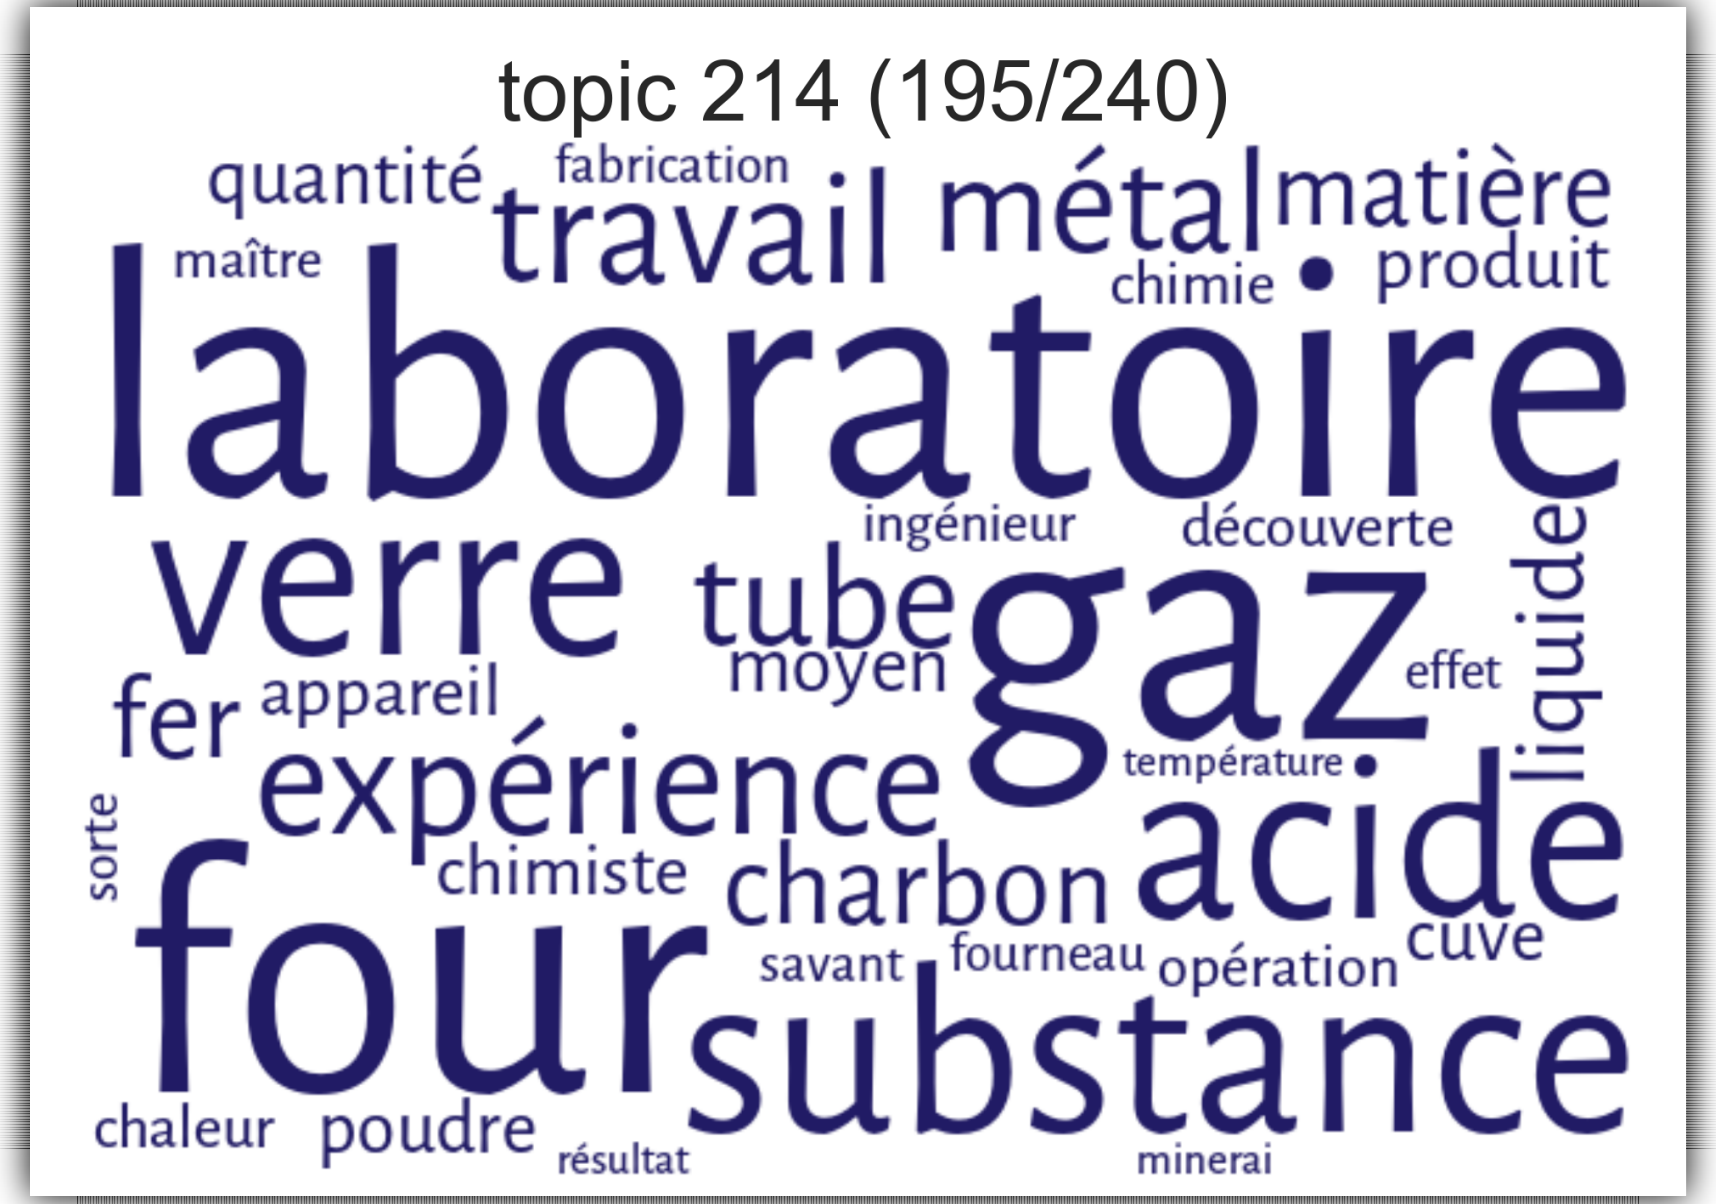

Ofen, Gaz, Labor, Substanz

Semantik: Polysemie

15 **billet** franc argent poche banque portefeuille pièce papier liasse monnaie chèque dollar caisse numéro besoin paquet compte table valeur louis carnet carte geste caissier vol million garçon minute voleur attention ...

59 train gare wagon quai compartiment voyageur voie station fer voyage valise rail employé minute chemin voiture couloir ligne vitre place tunnel départ locomotive convoi chef portière banquette **billet** machine classe ...

108 lettre enveloppe papier écriture adresse poste ligne matin courrier **billet** doute réponse cachet poche soir correspondance bureau lecture signature timbre mois table facteur pli cœur message rendez-vous paquet ...

(frz. billet = Geldschein, Fahrschein, kurzer Brief)

Struktur: steil abfallend

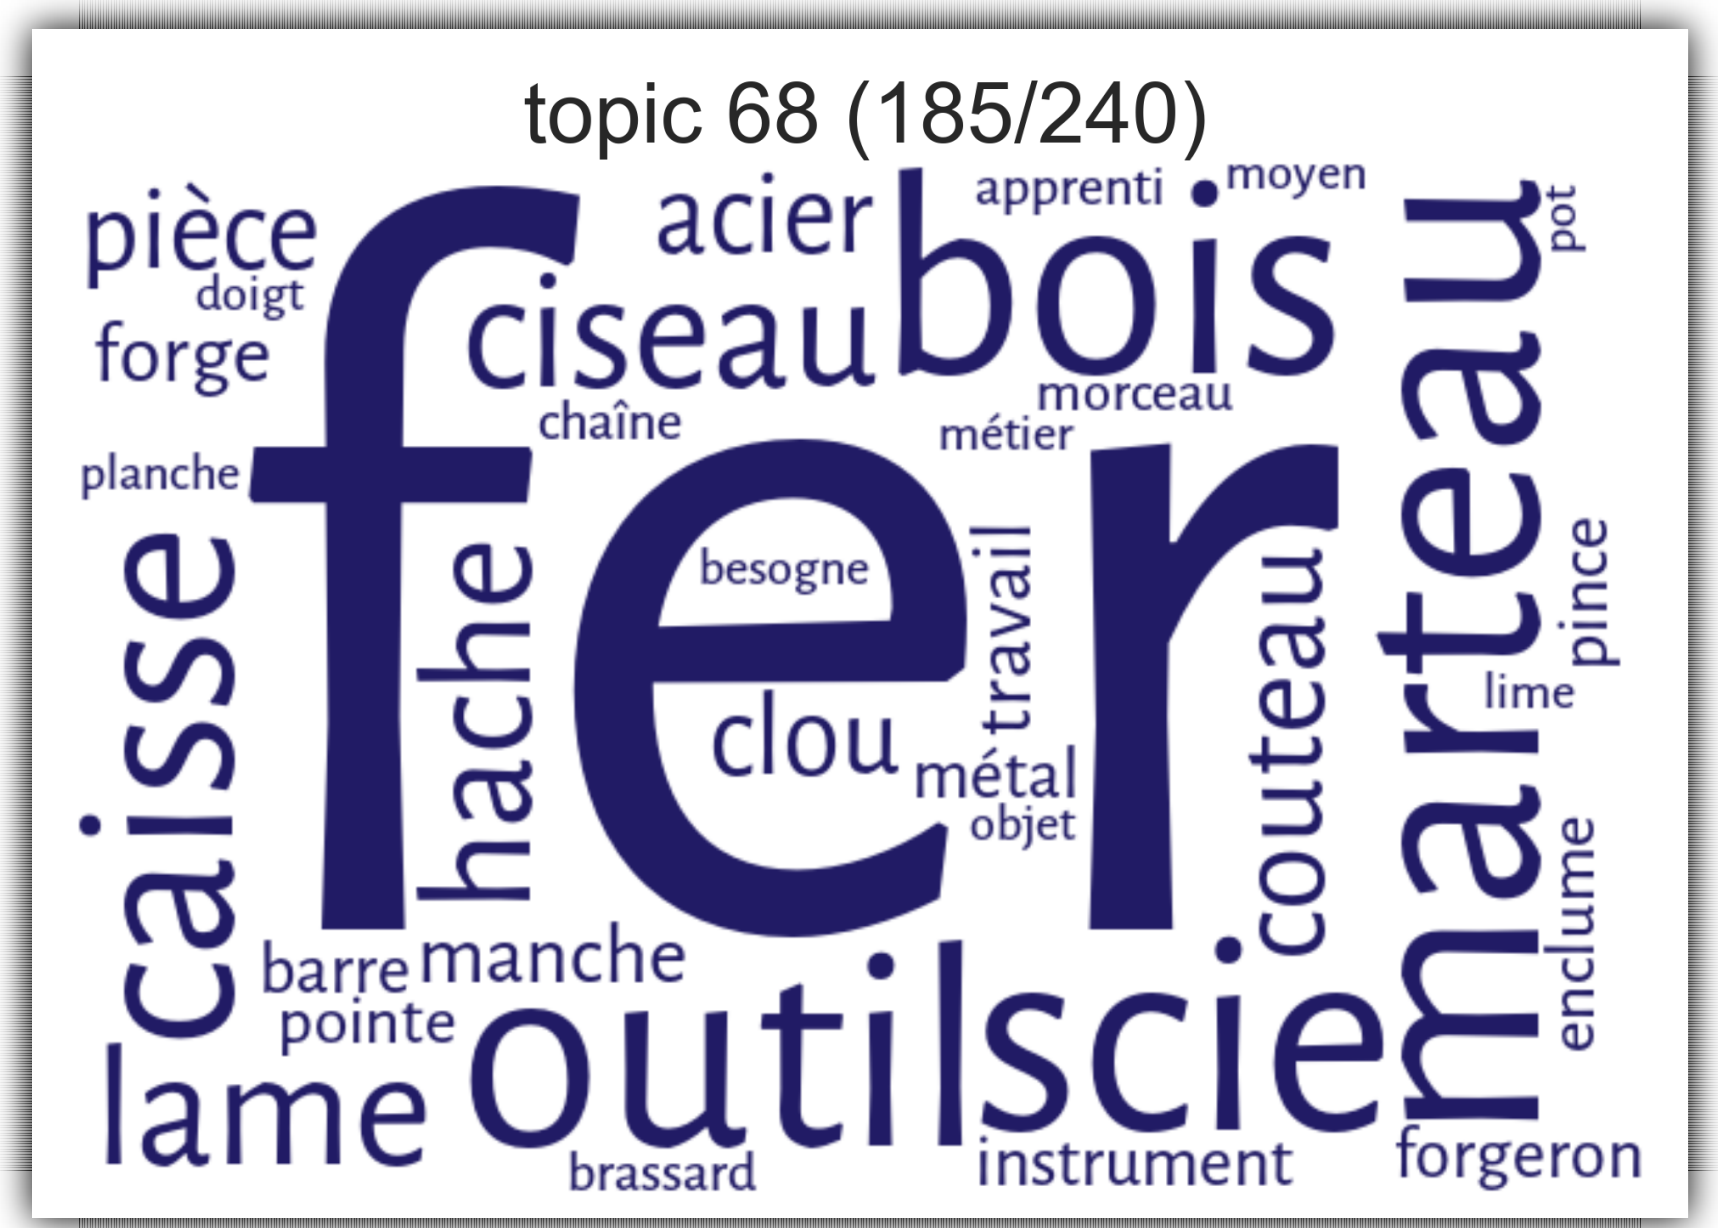

Eisen, Hammer, Säge

Struktur: steil abfallend

Schlüssel, Tresor, Schloss, Schublade

Struktur: flach abfallend

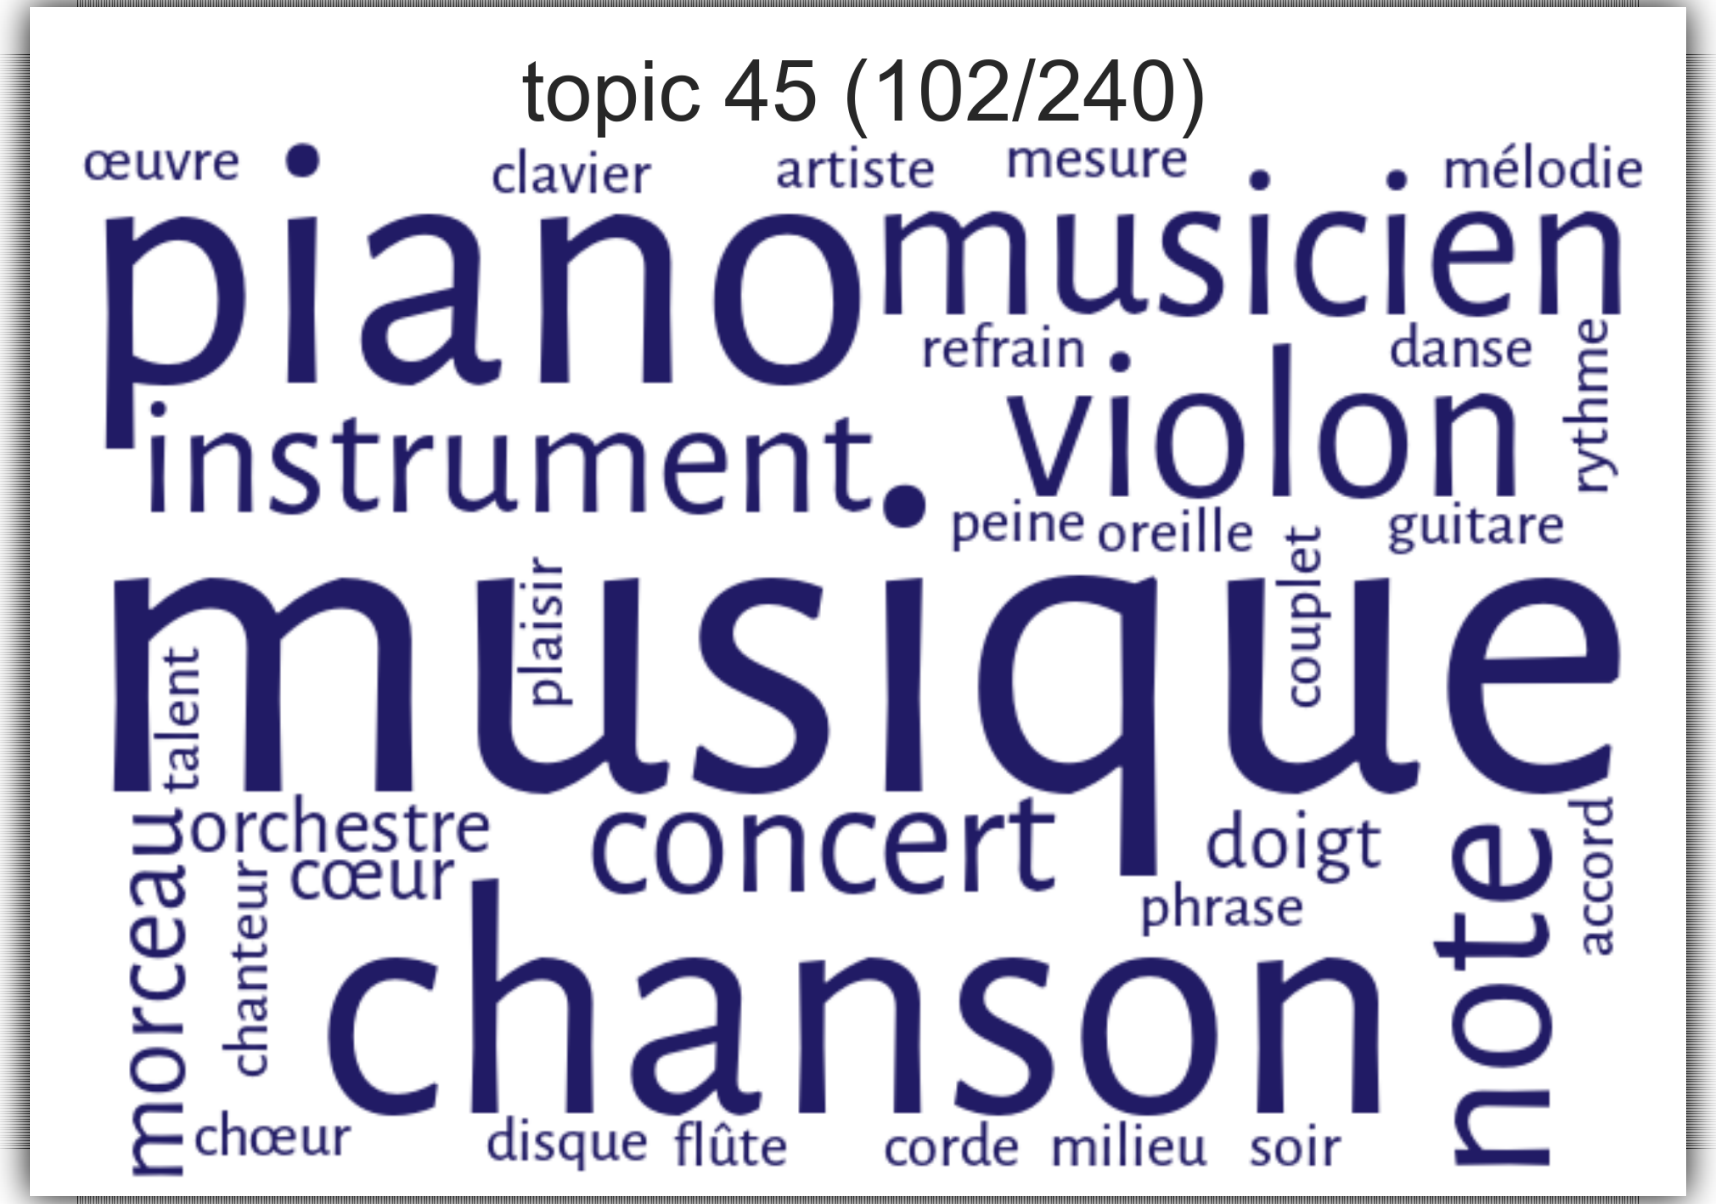

Musik, Lied, Klavier

Struktur: flach abfallend

Polizist, Kommissar, Killer

Verteilung: breit

Frage, Vernunft, Affäre

Verteilung: breit

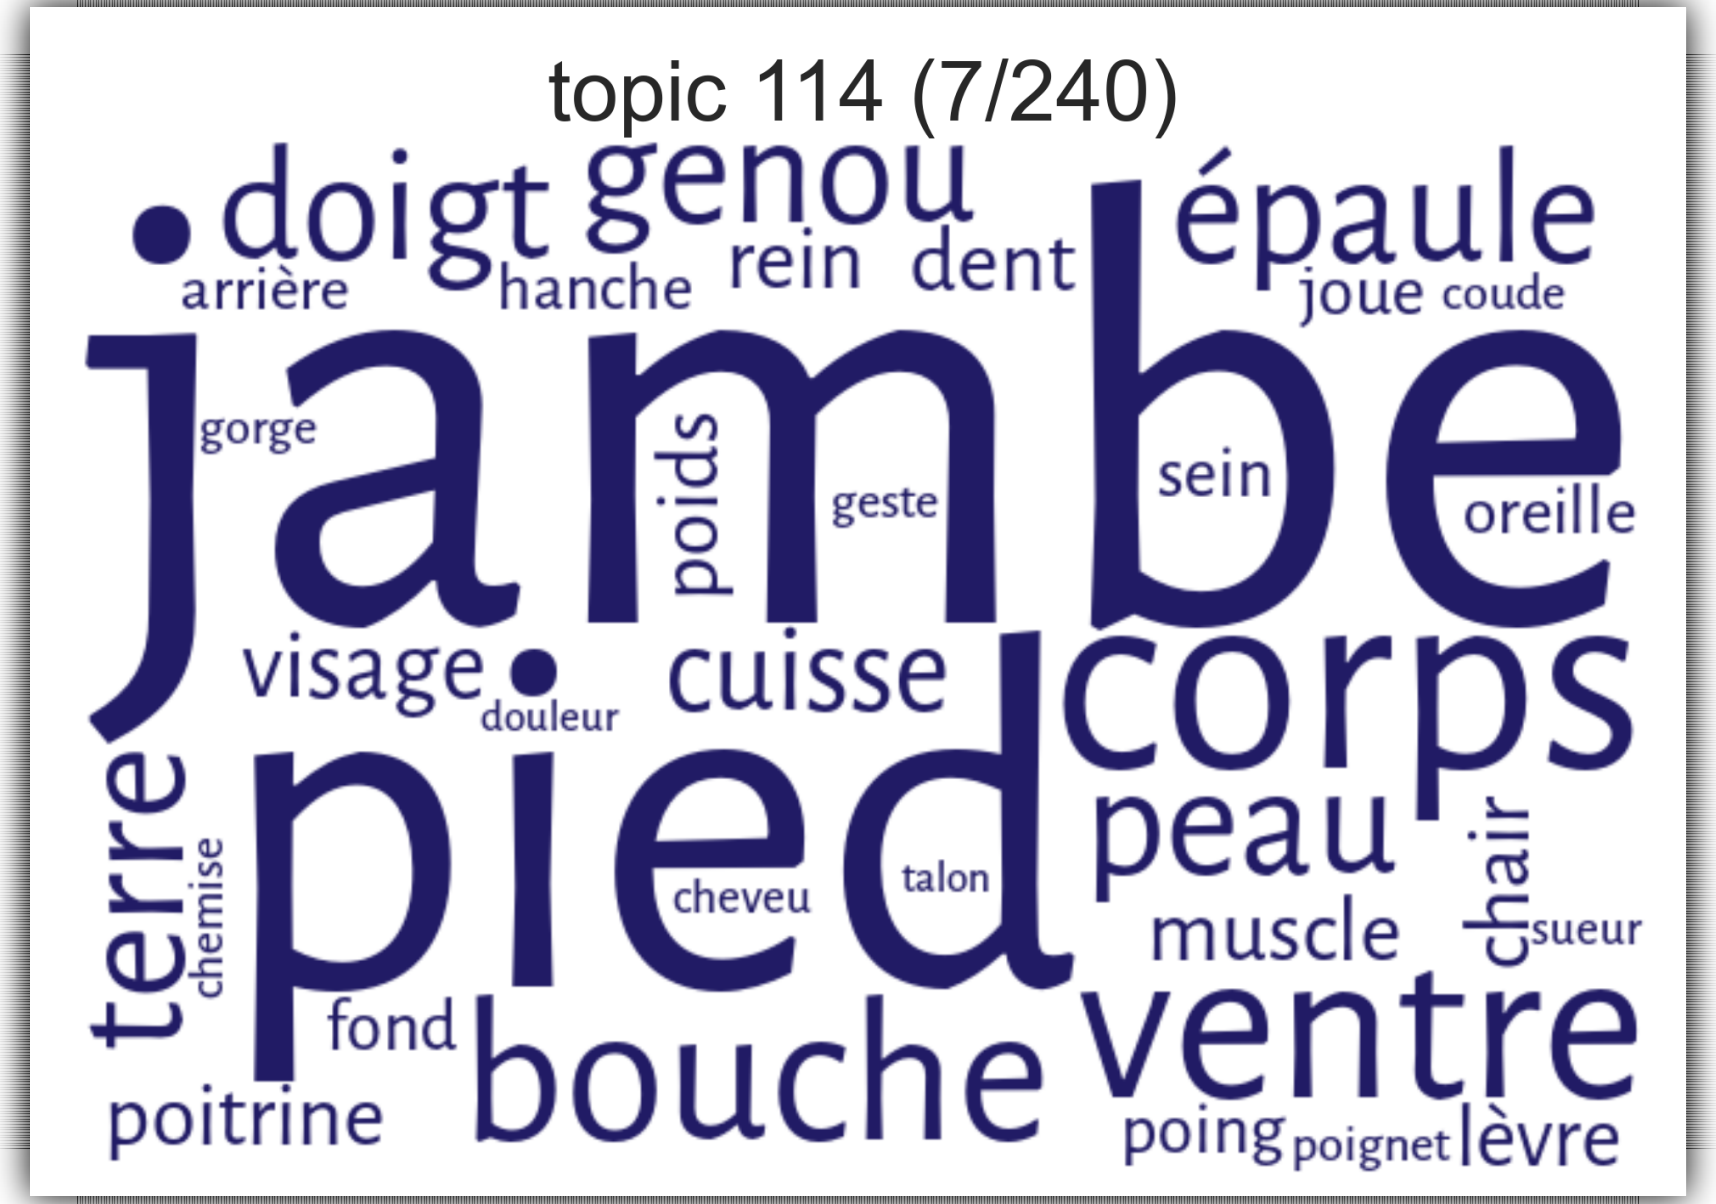

Bein, Fuß, Körper

Verteilung: spezifisch

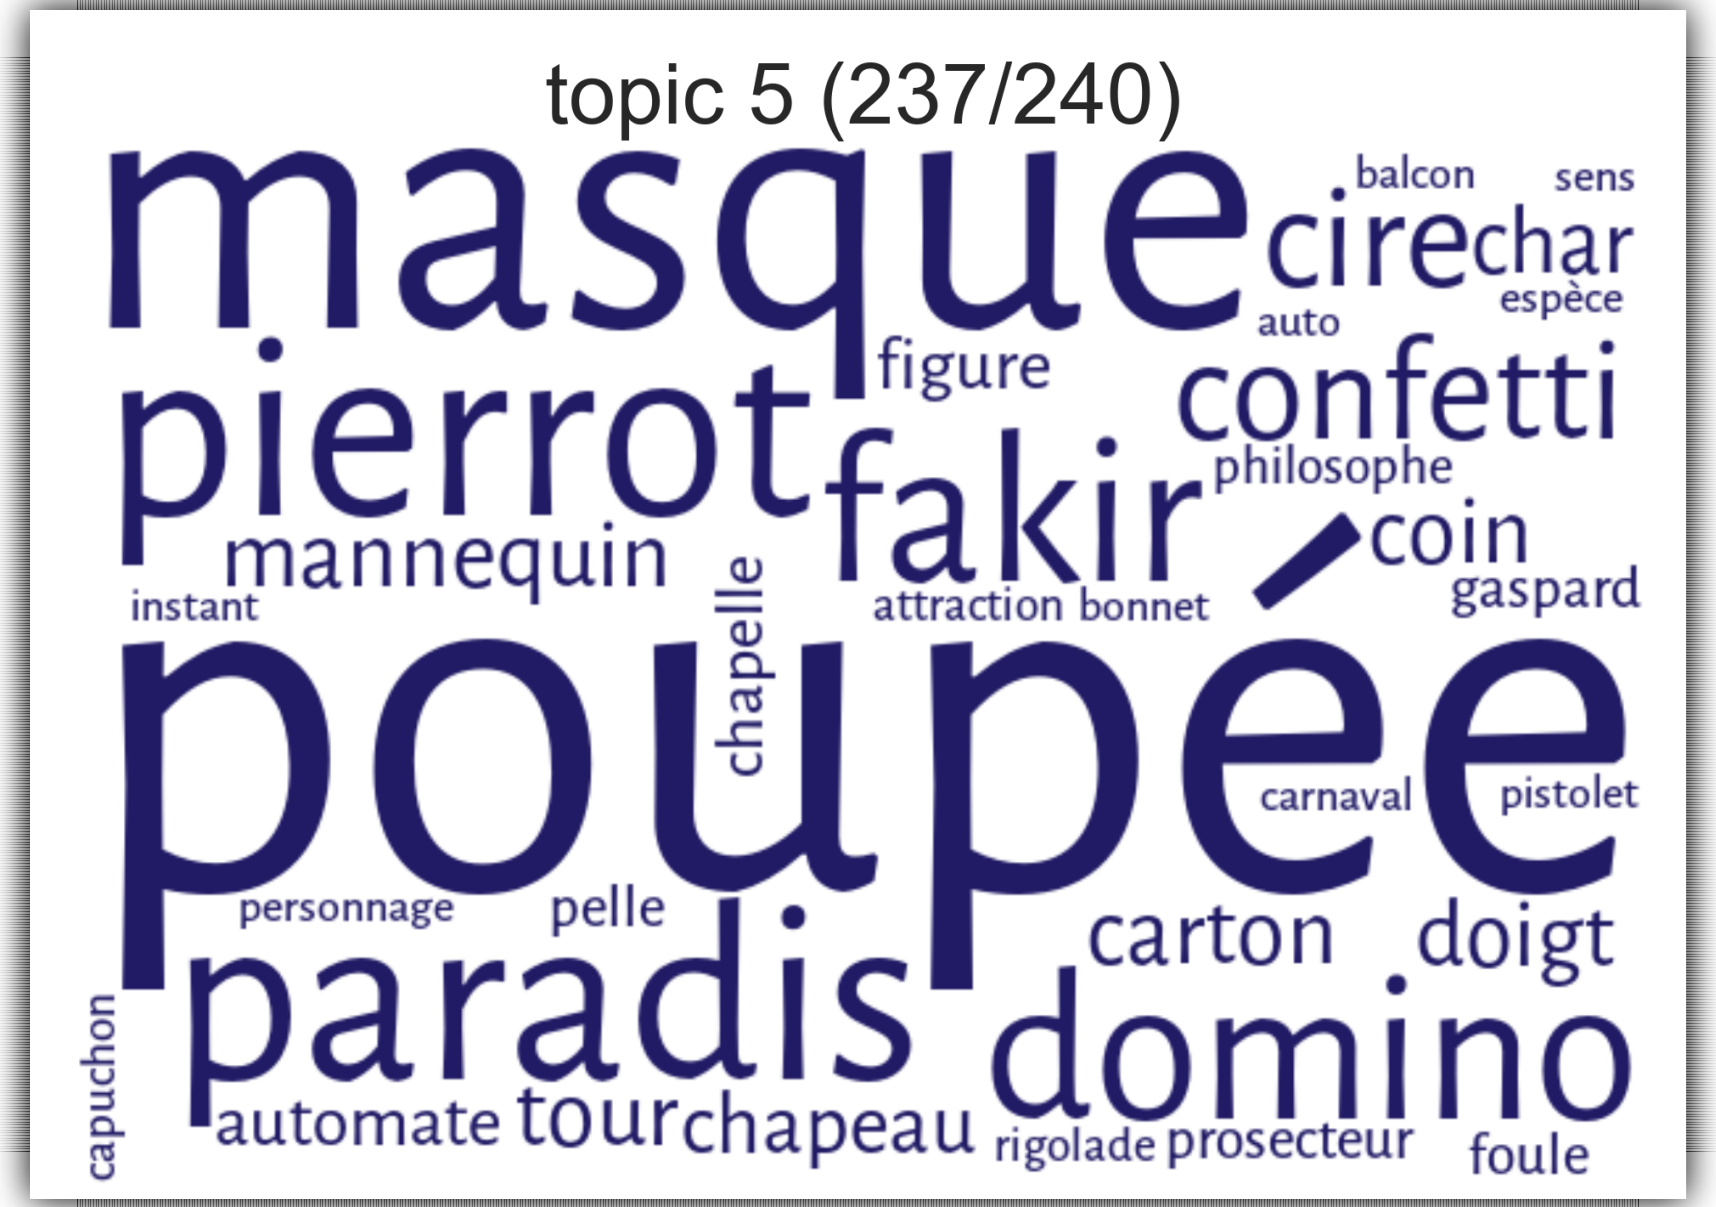

Puppe, Maske, Pierrot (Clown)

Verteilung: spezifisch

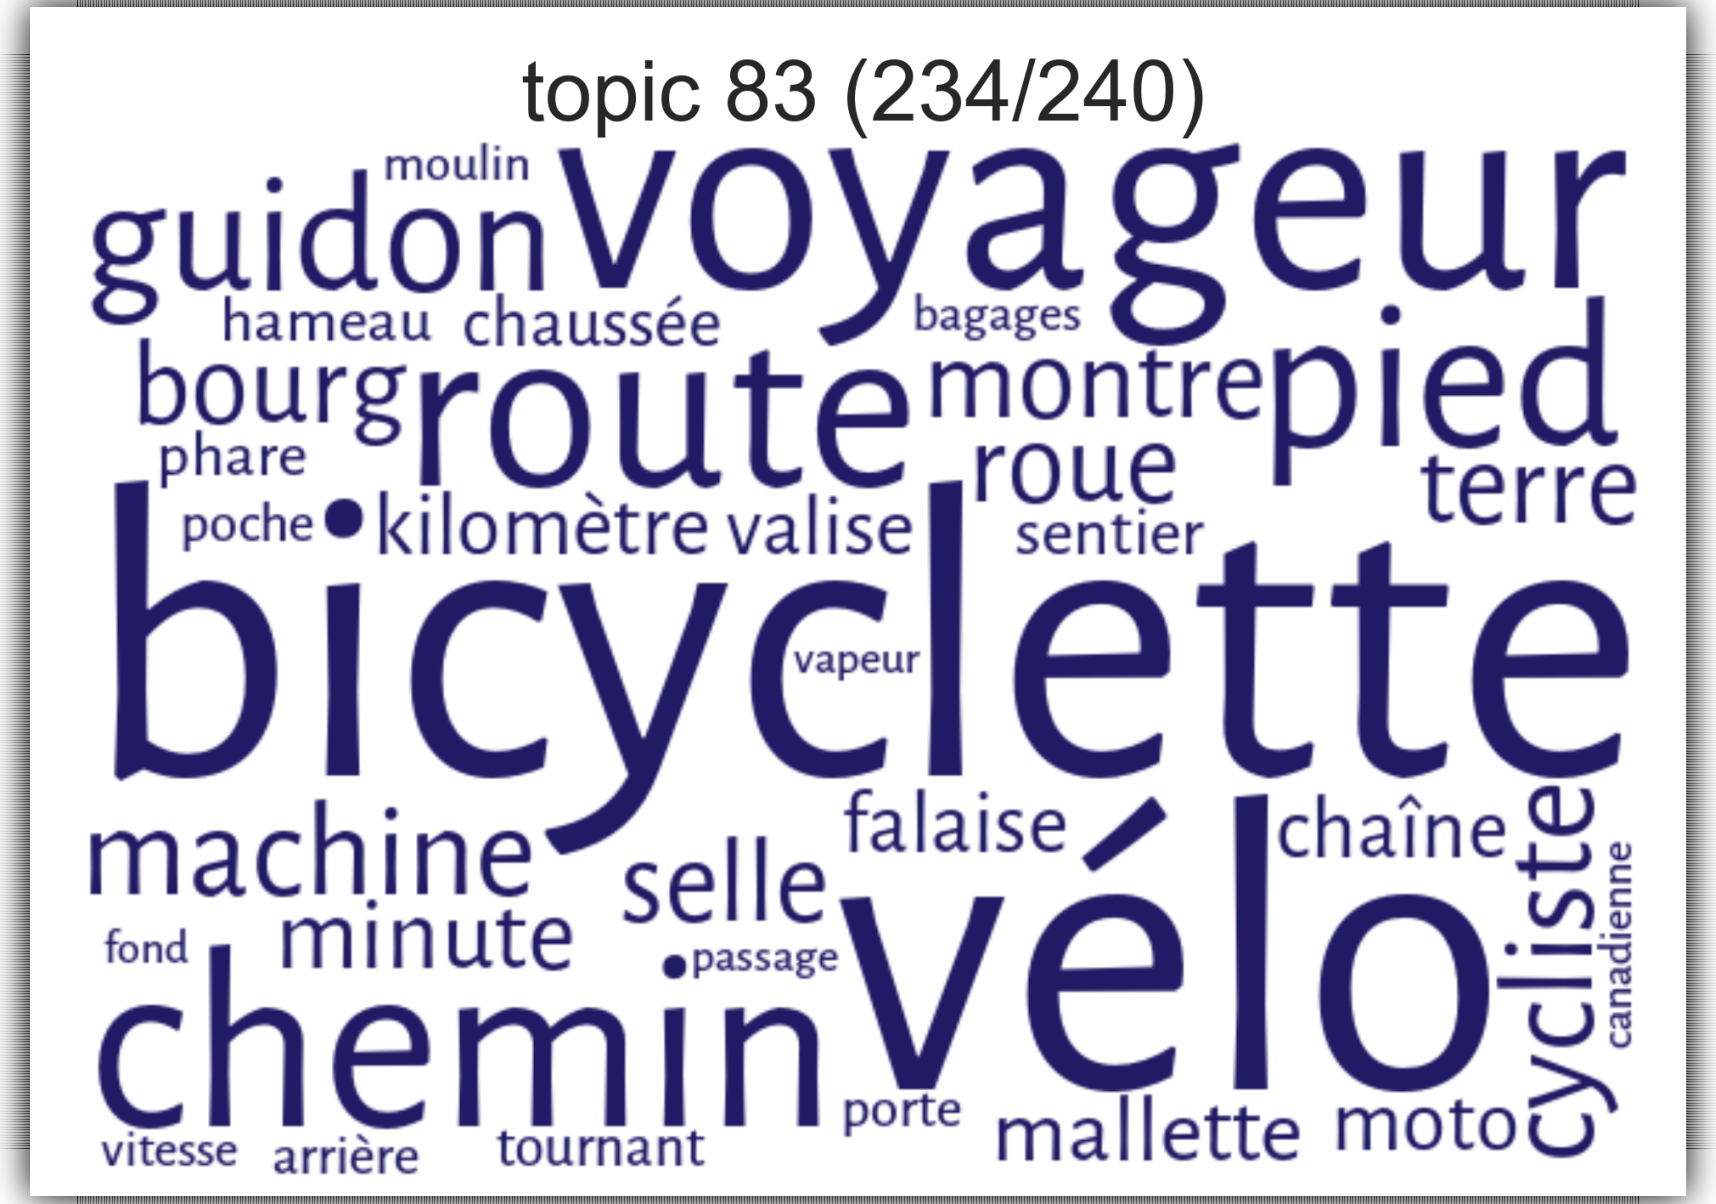

Fahrrad, Rad, Reisender

Verteilung: mittel

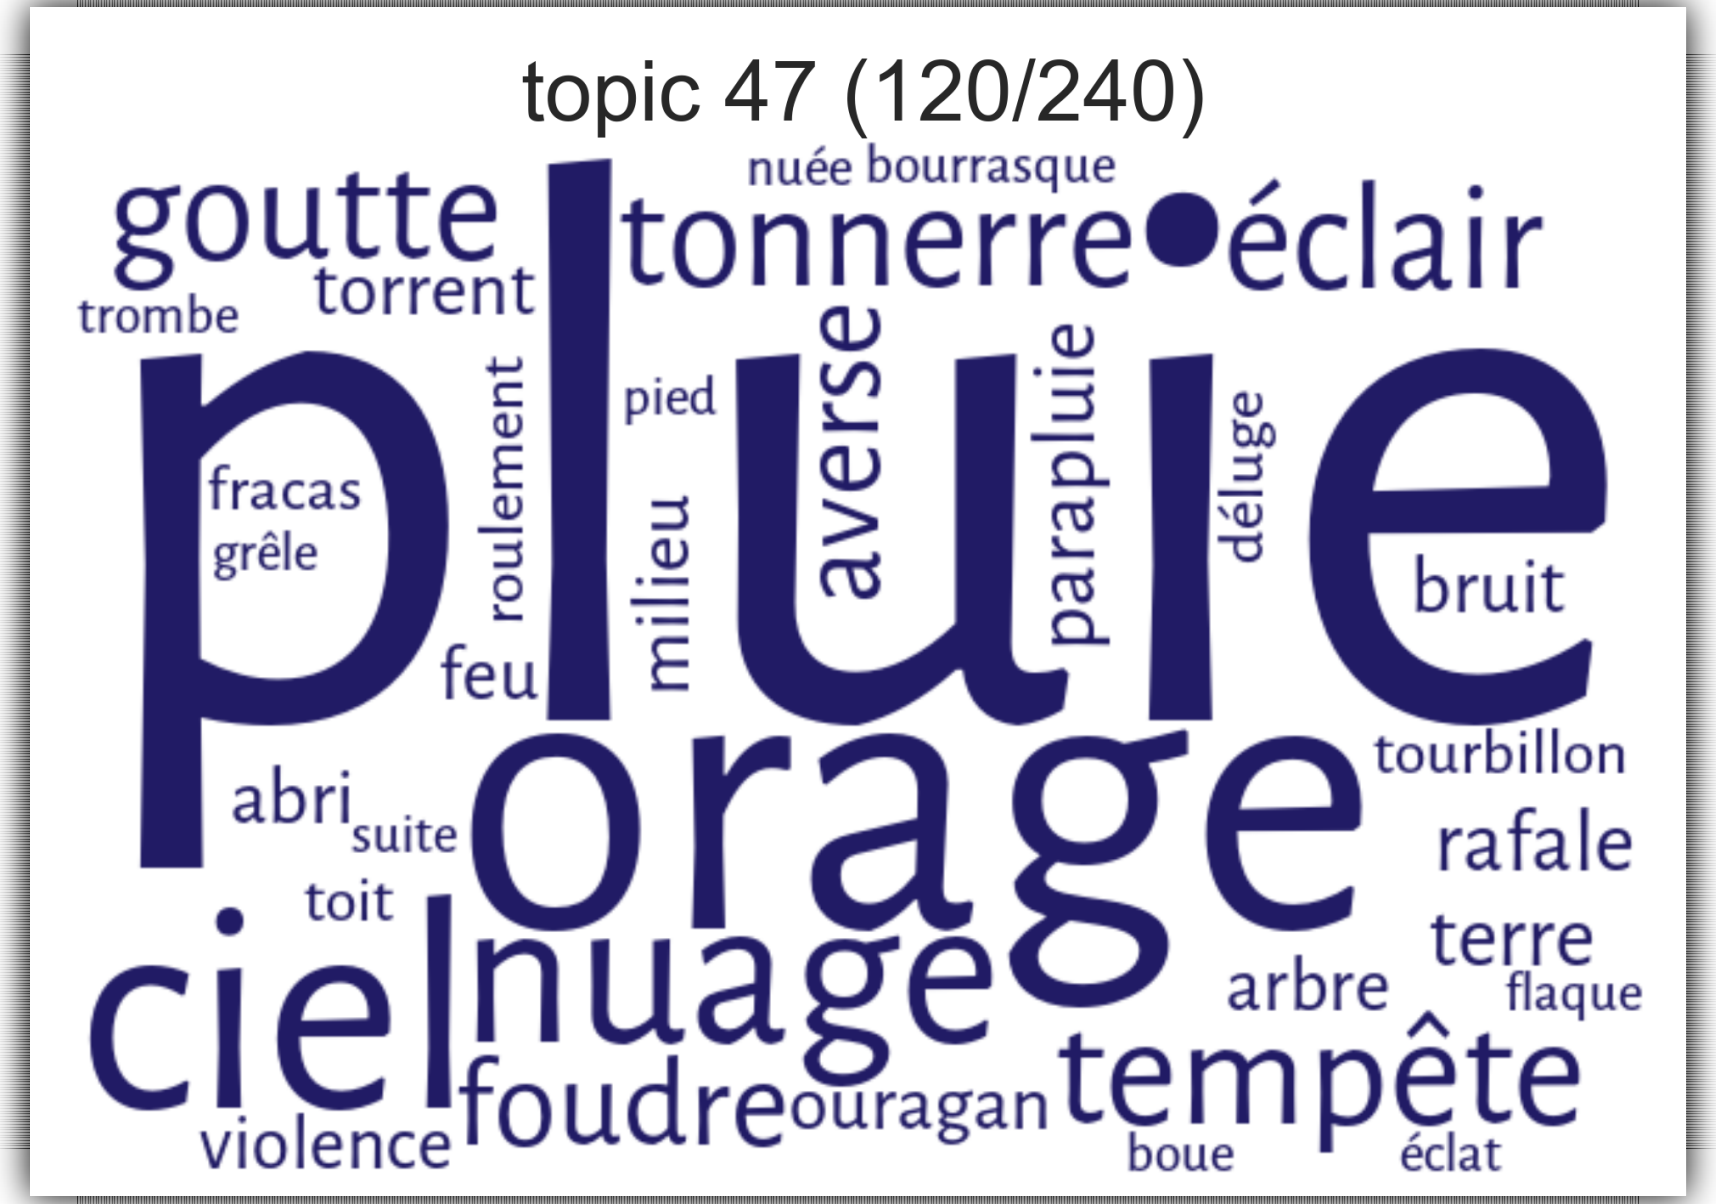

Regen, Gewitter, Himmel

Verteilung: mittel

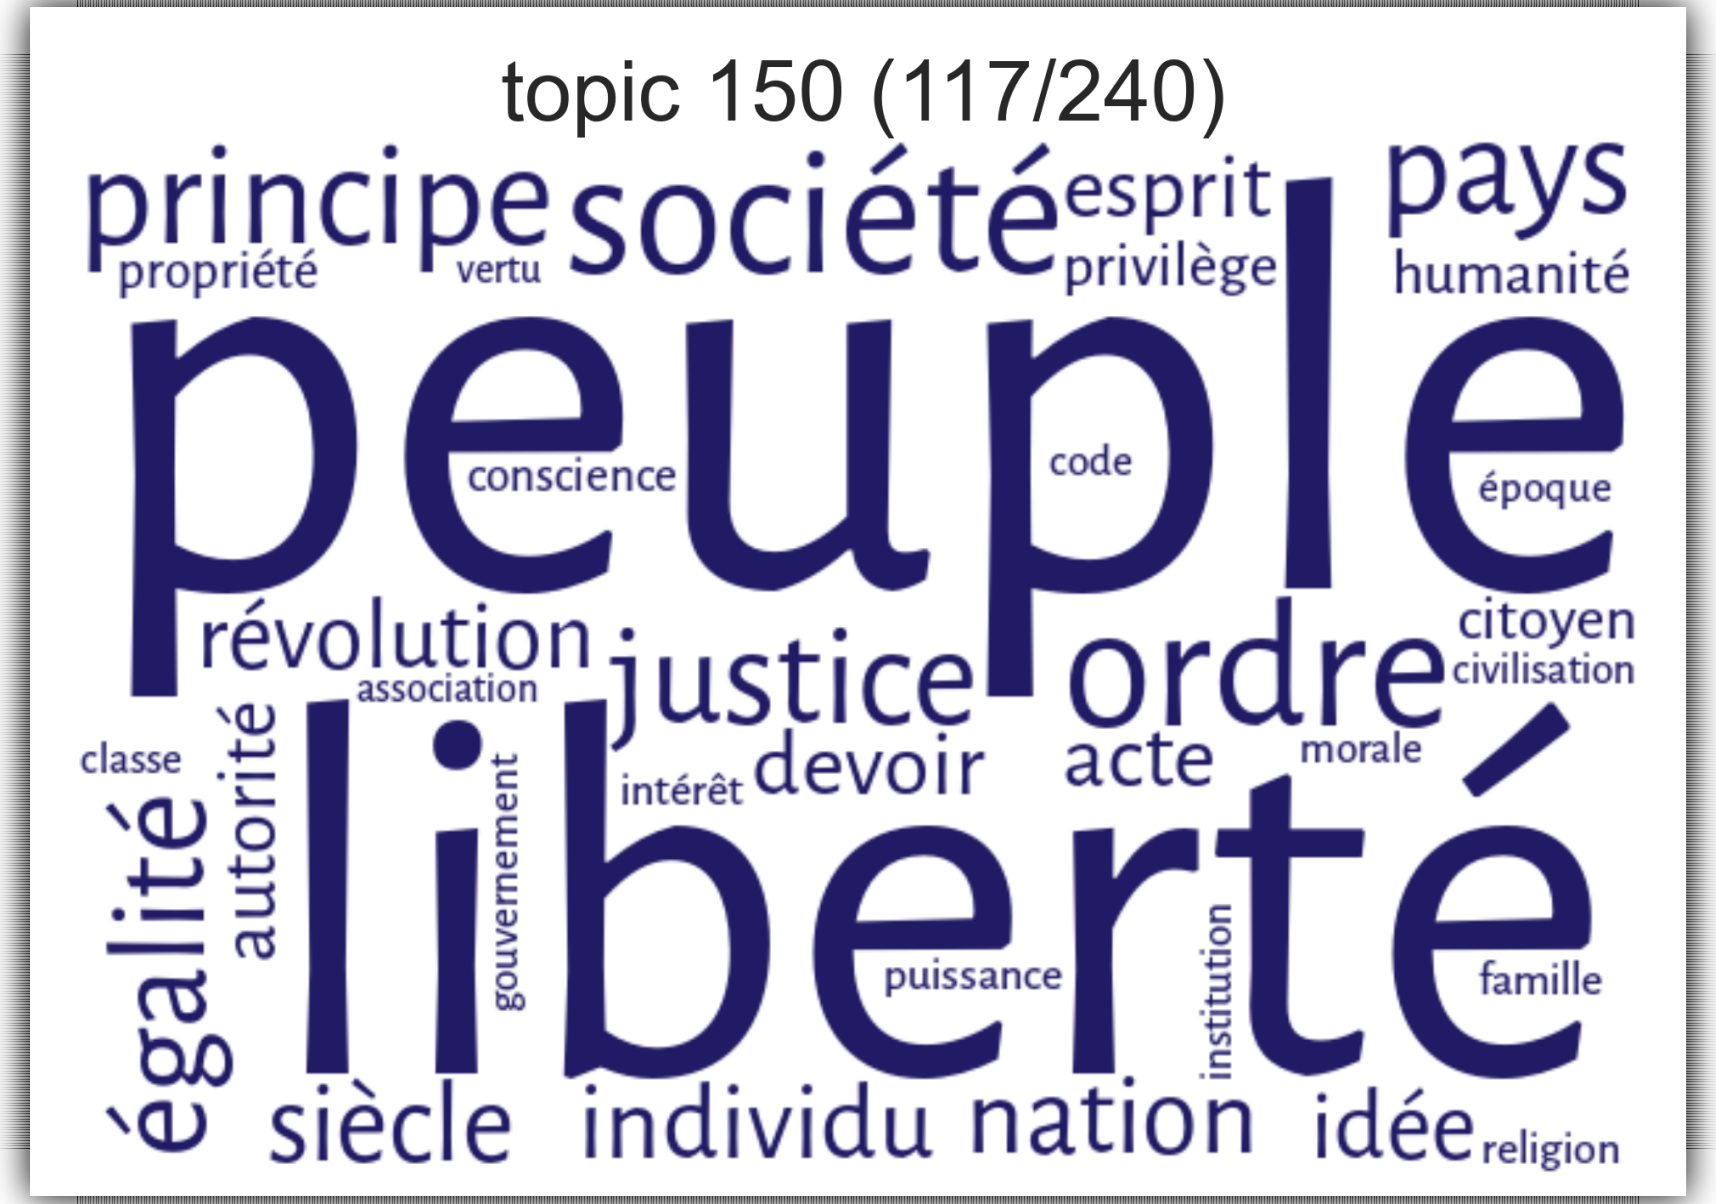

Volk, Freiheit, Gesellschaft

Ähnlichkeit von Topics

Ähnlichkeit: Clustering

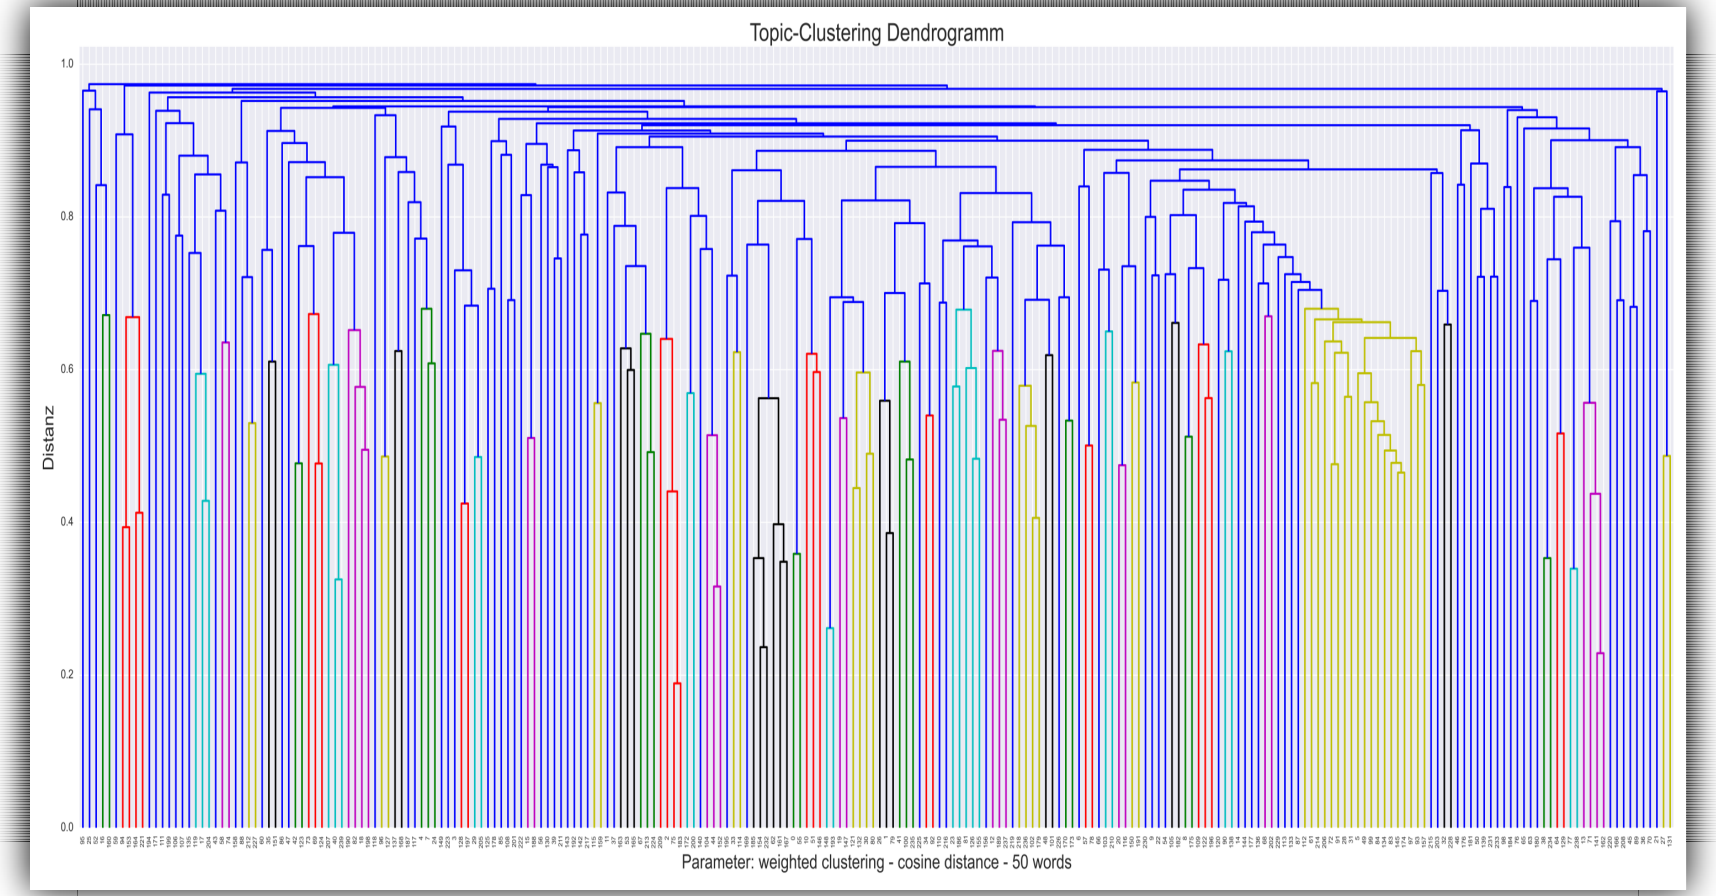

(50 Wörter, Cosine-Distanz, weighted-Clustering)

Clustering (Detail)

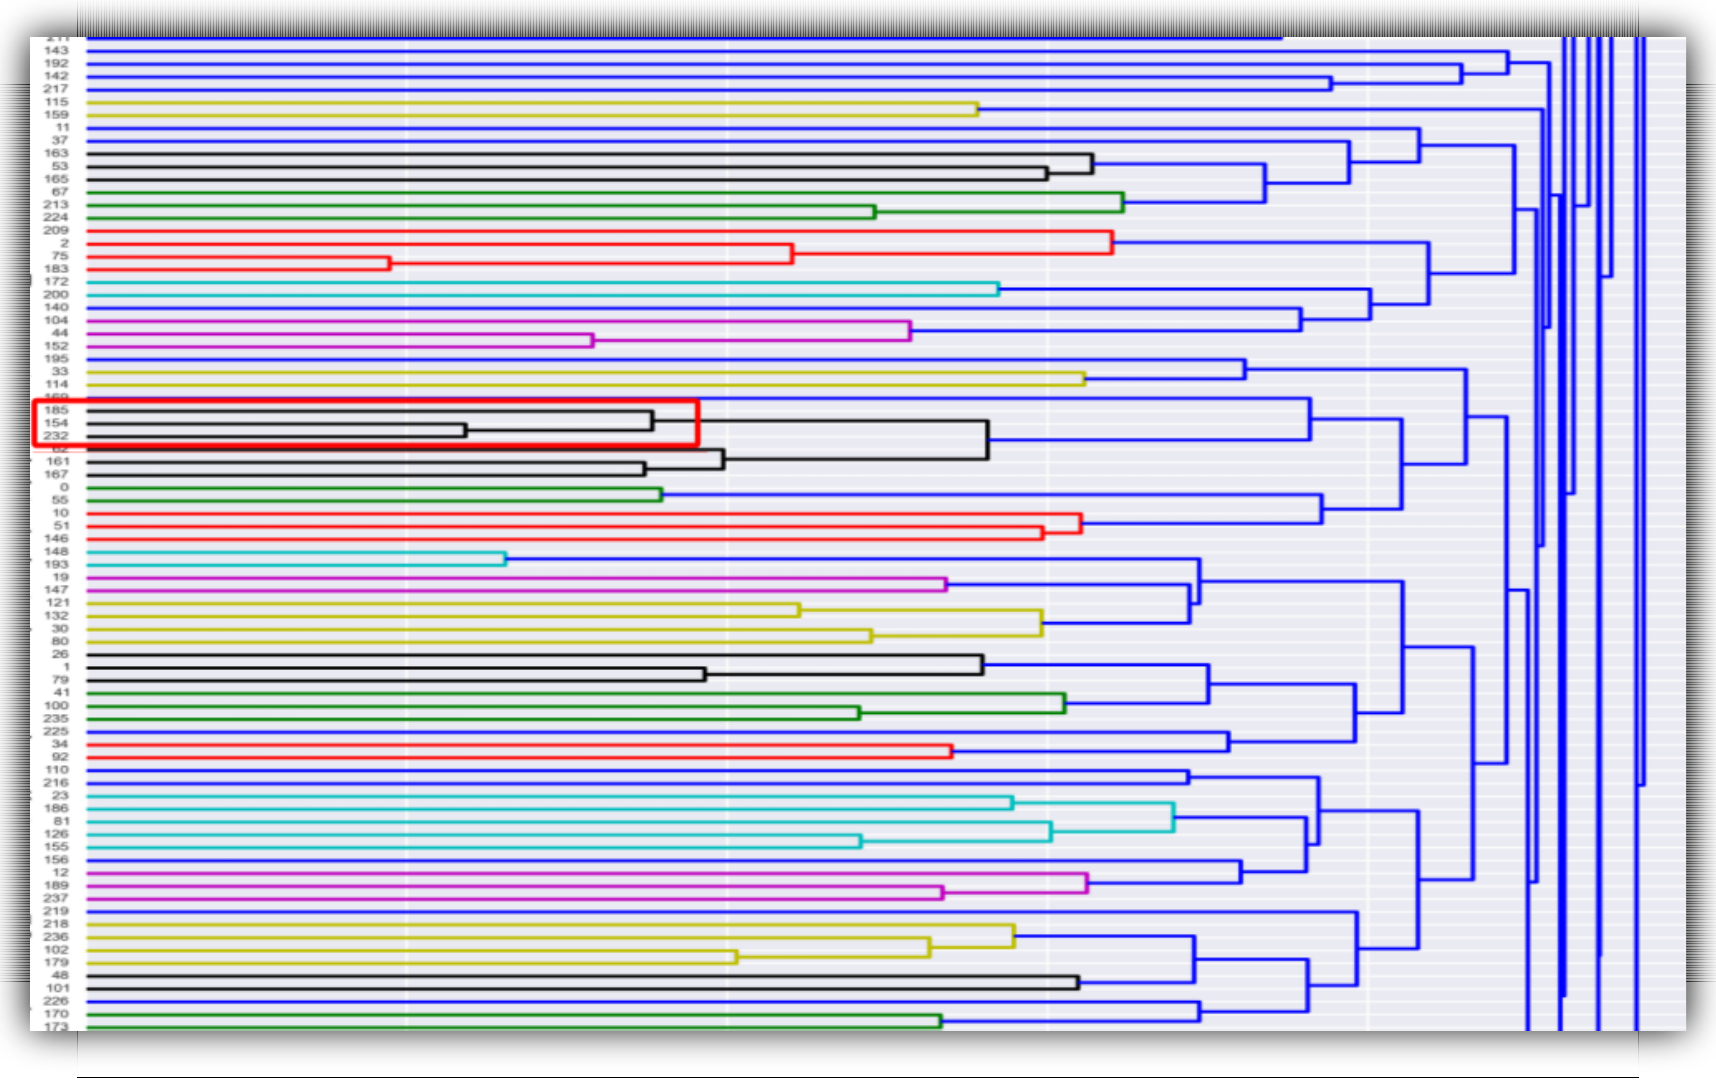

(50 Wörter, Cosine-Distanz, weighted-Clustering)

Clustering (Detail)

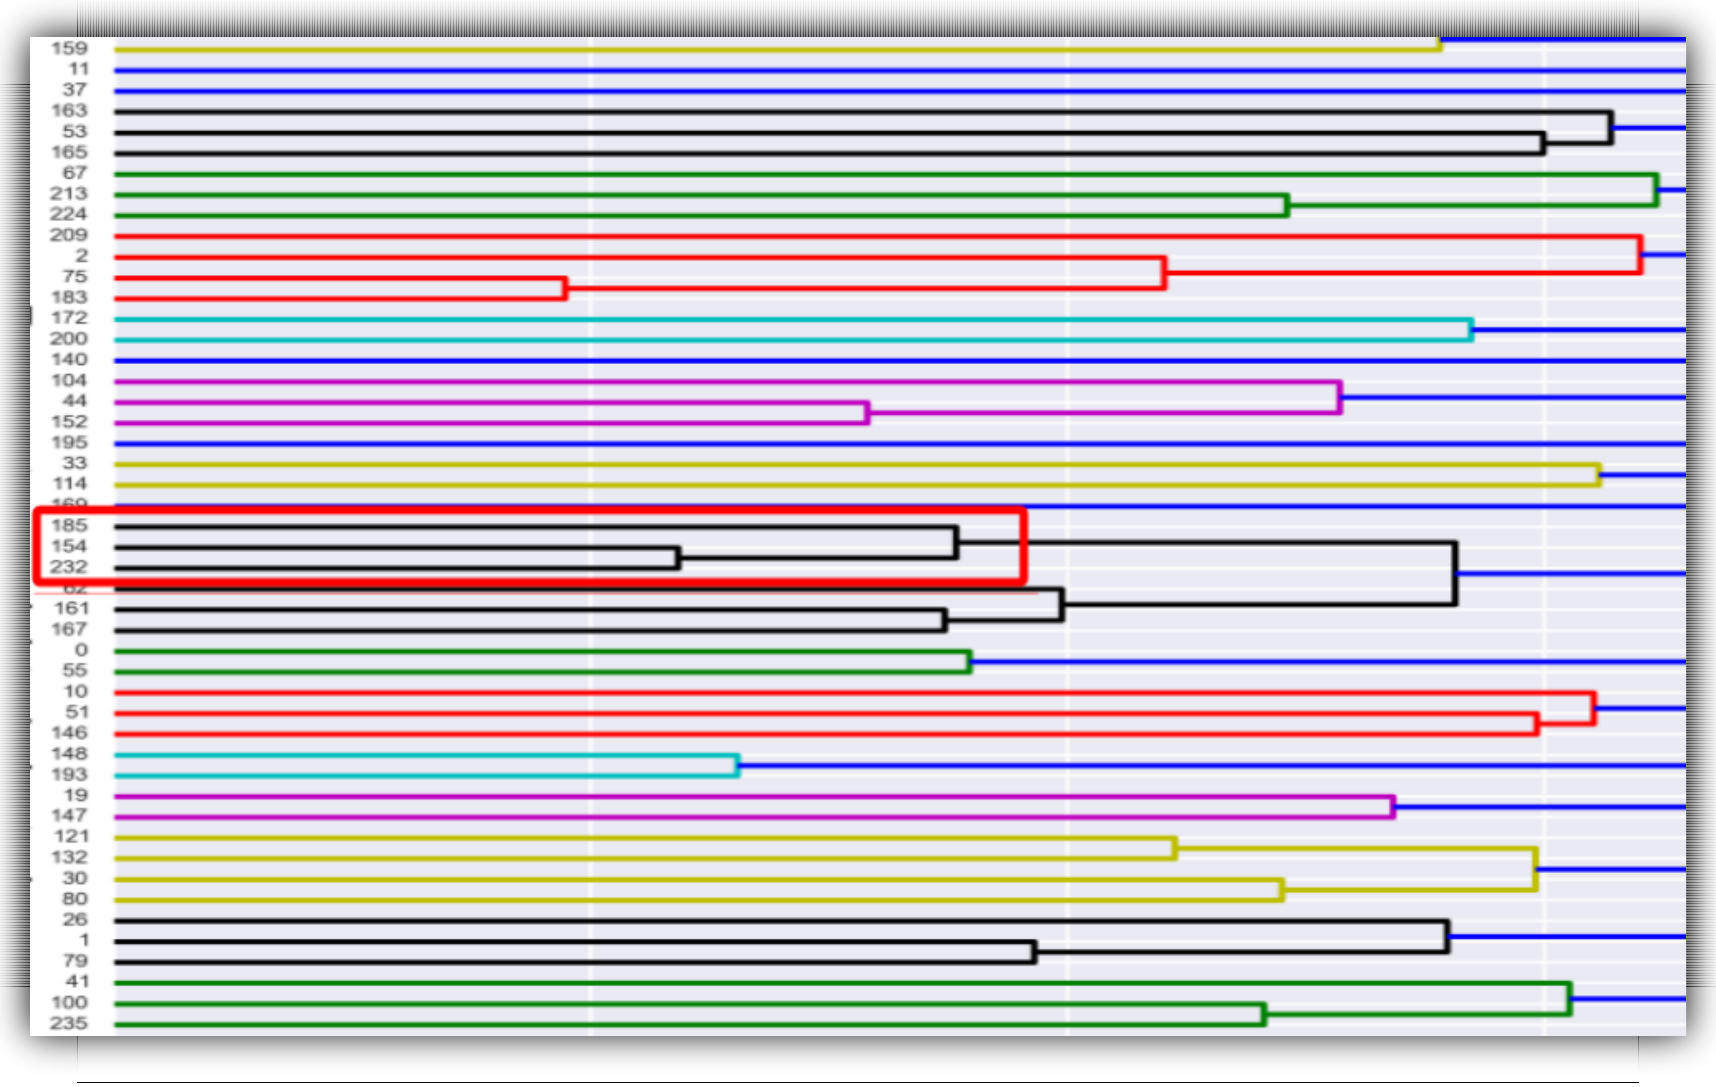

(50 Wörter, Cosine-Distanz, weighted-Clustering)

Topics über die Zeit

Sich ablösende Topics

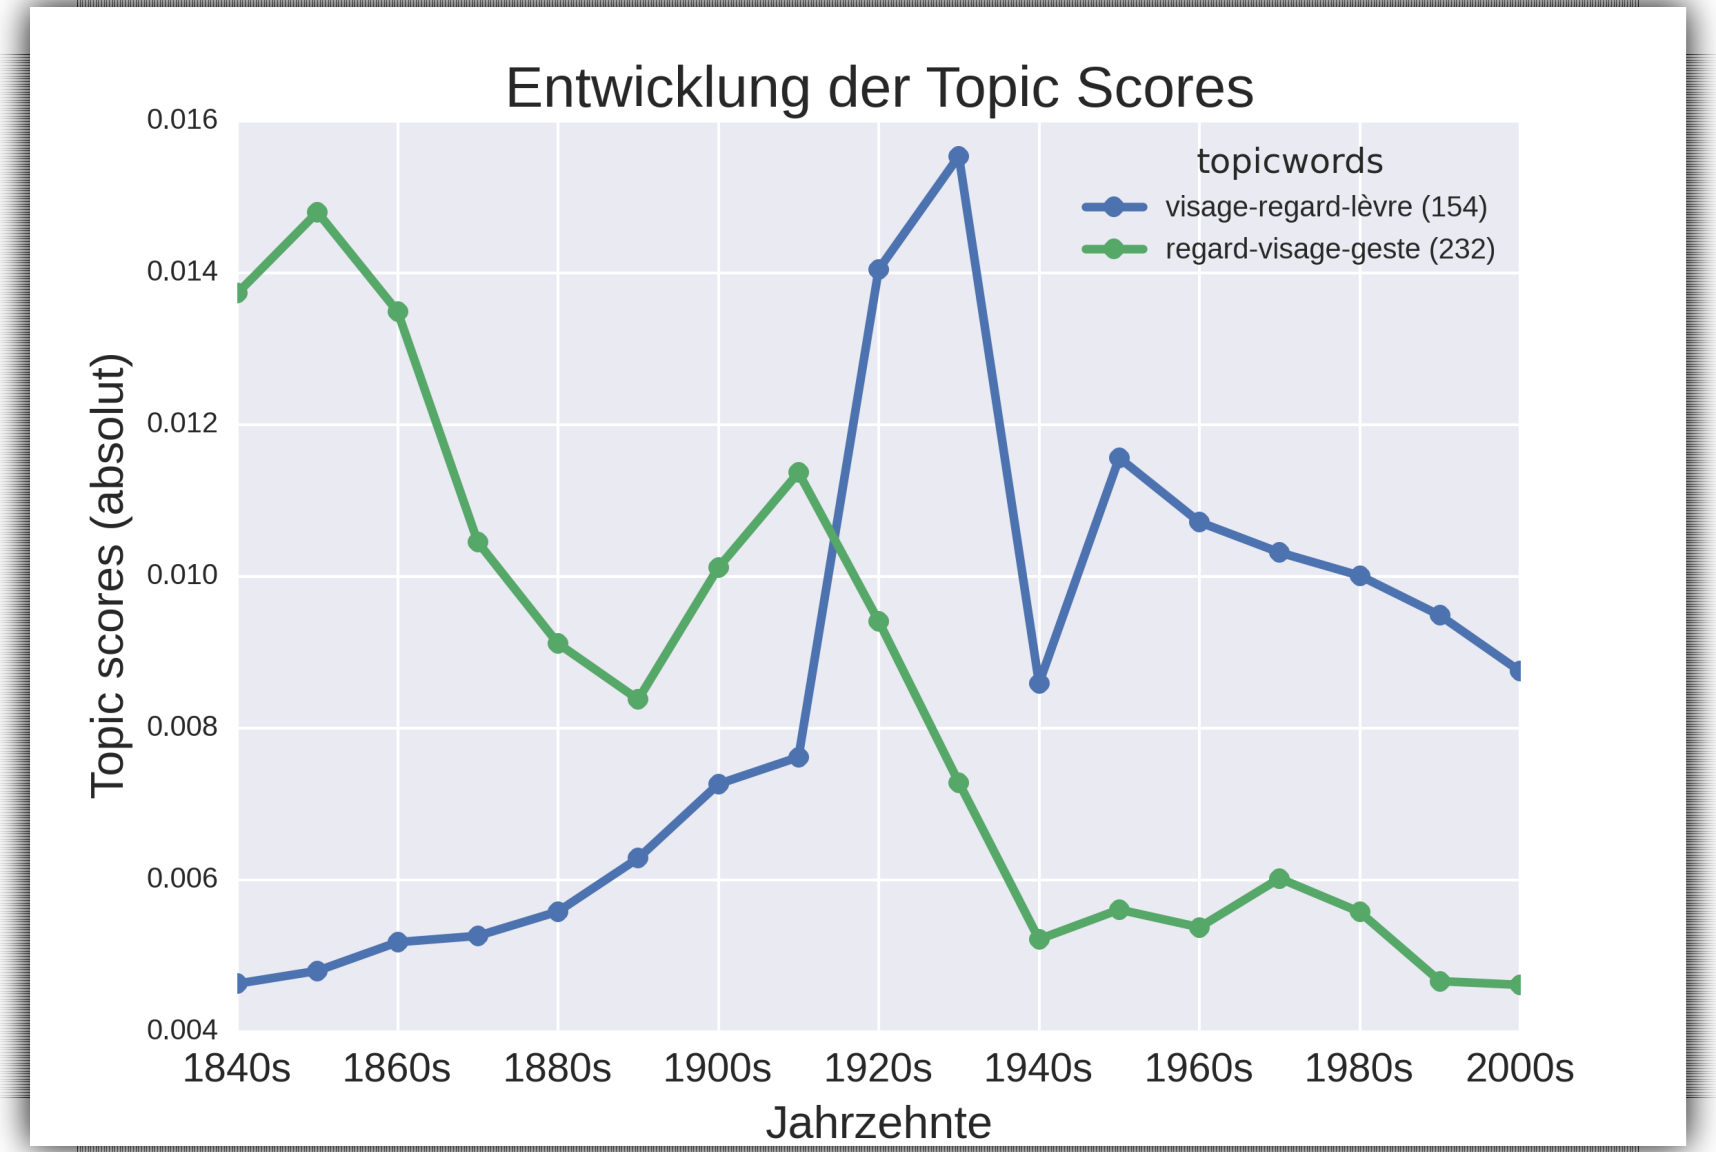

Gesicht, Blick, Lippe / Blick, Gesicht, Geste

Analoge Topics: Korrelation

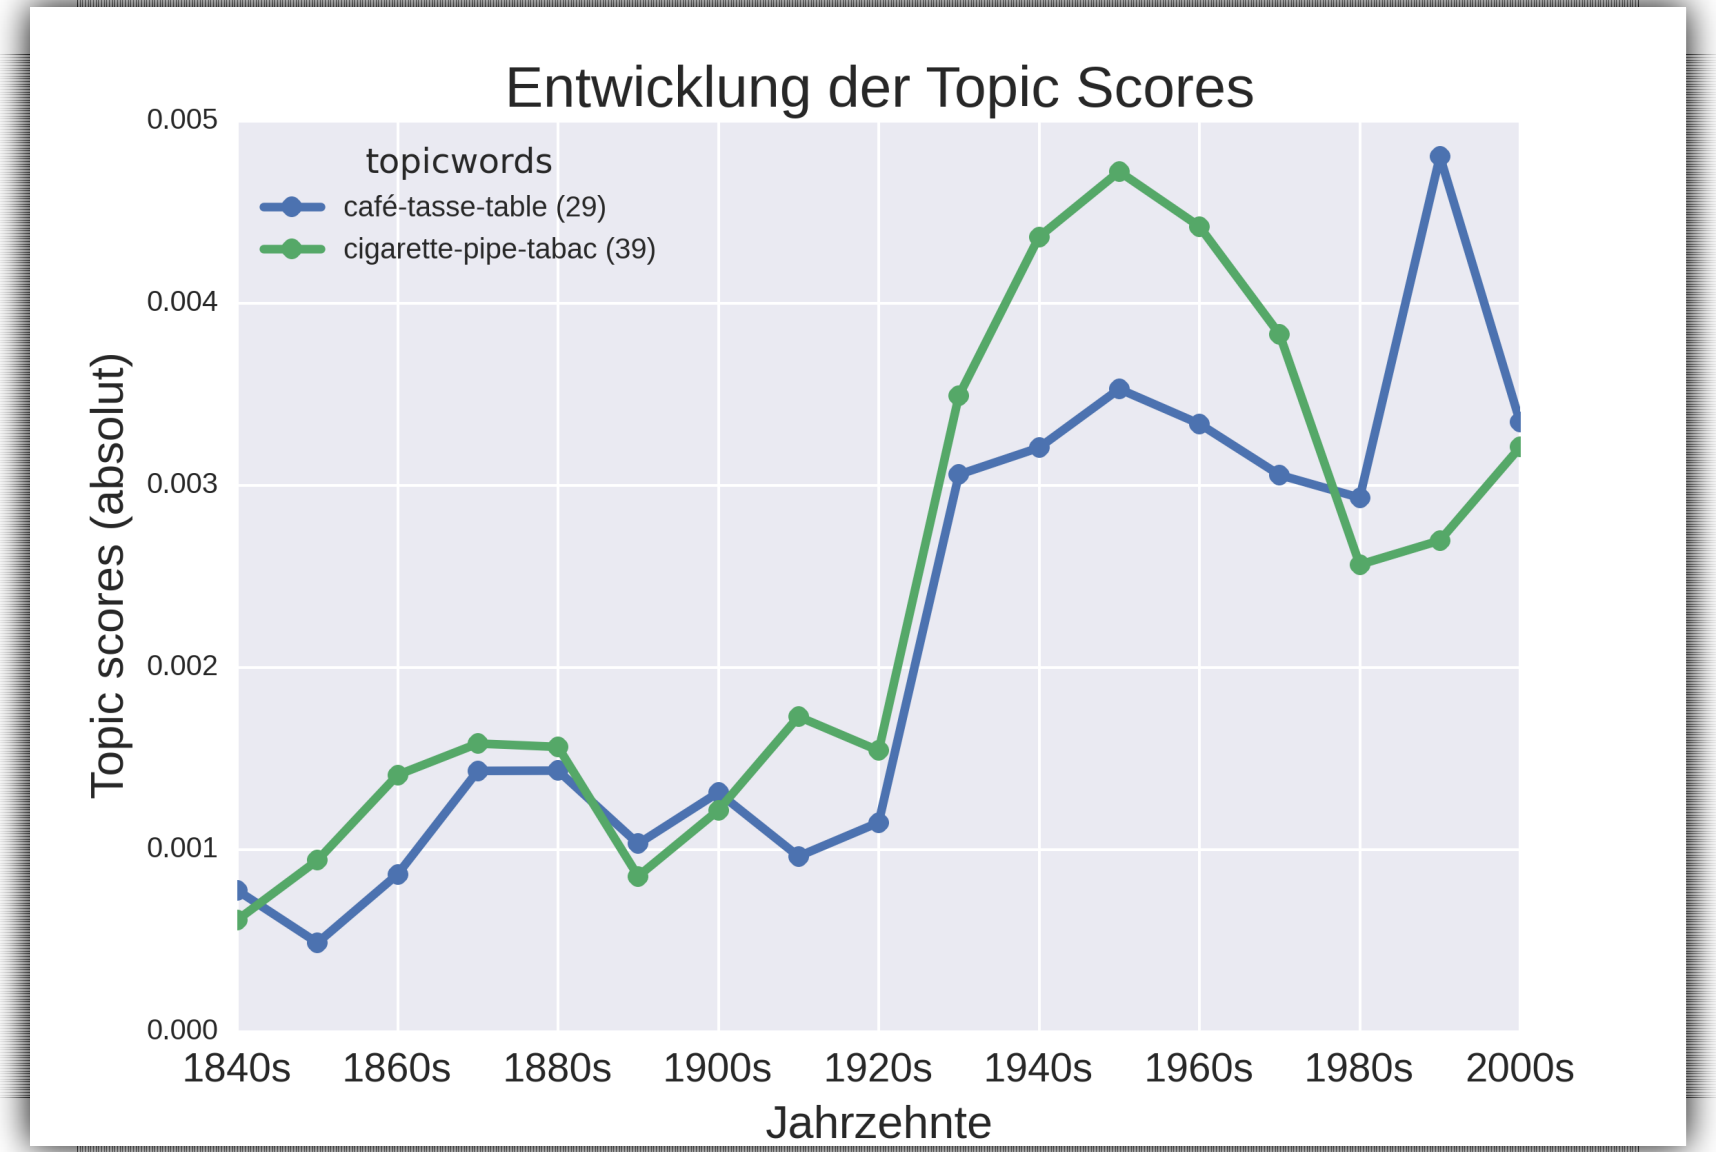

Kaffee, Tasse, Tisch / Zigarette, Pfeife, Tabak

5. Perspektiven auf die Kriminalromane

Überblick

- Krimi-Topics
  - inhaltlich
  - statistisch
- Topics nach Untergattungen
  - Überblick
  - Gruppierung nach Topic-Ähnlichkeit

Krimi-Topics: inhaltlich und statistisch

Inhaltlich typisch

Polizei, Kommissar, Agent / Beamter

Inhaltlich typisch

Verbrechen, Justiz/Gerechtigkeit, Tod

Inhaltlich typisch?

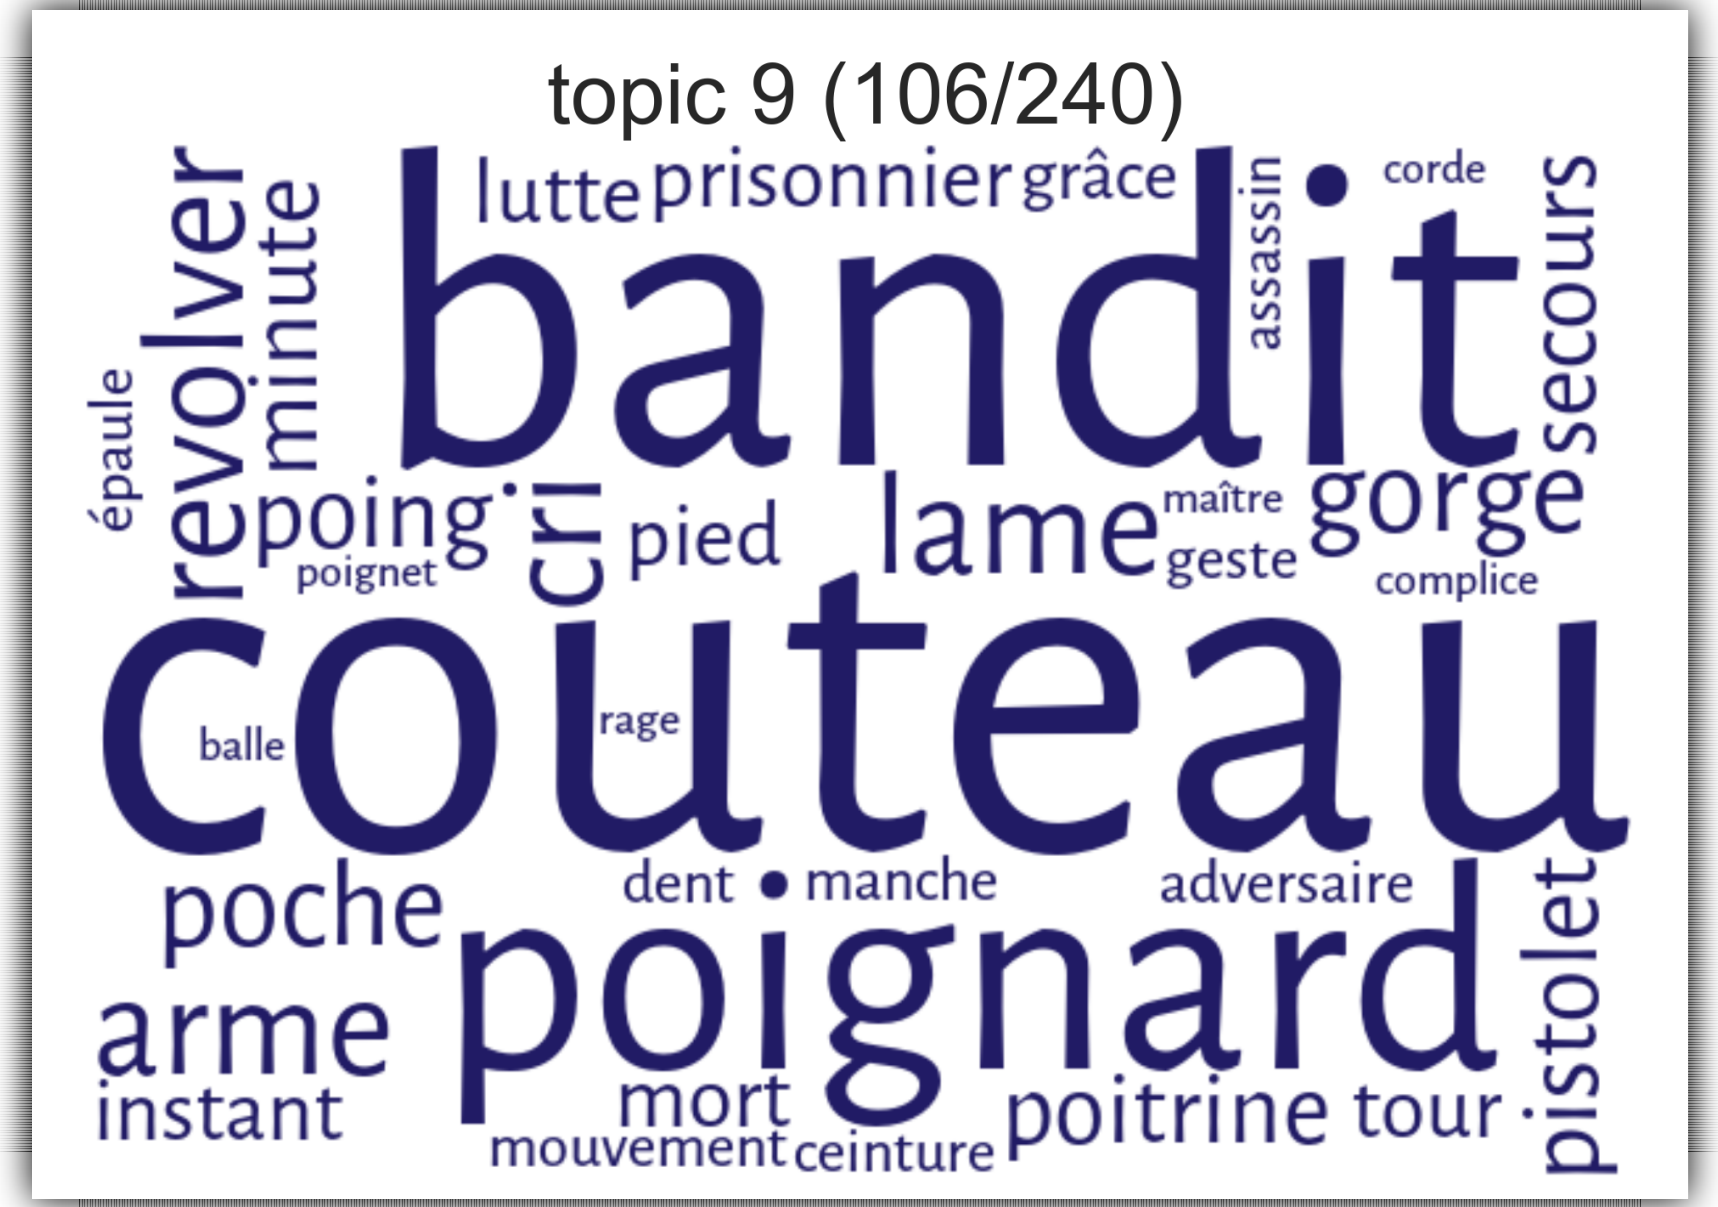

Räuber, Messer, Dolch

Inhaltlich typisch?

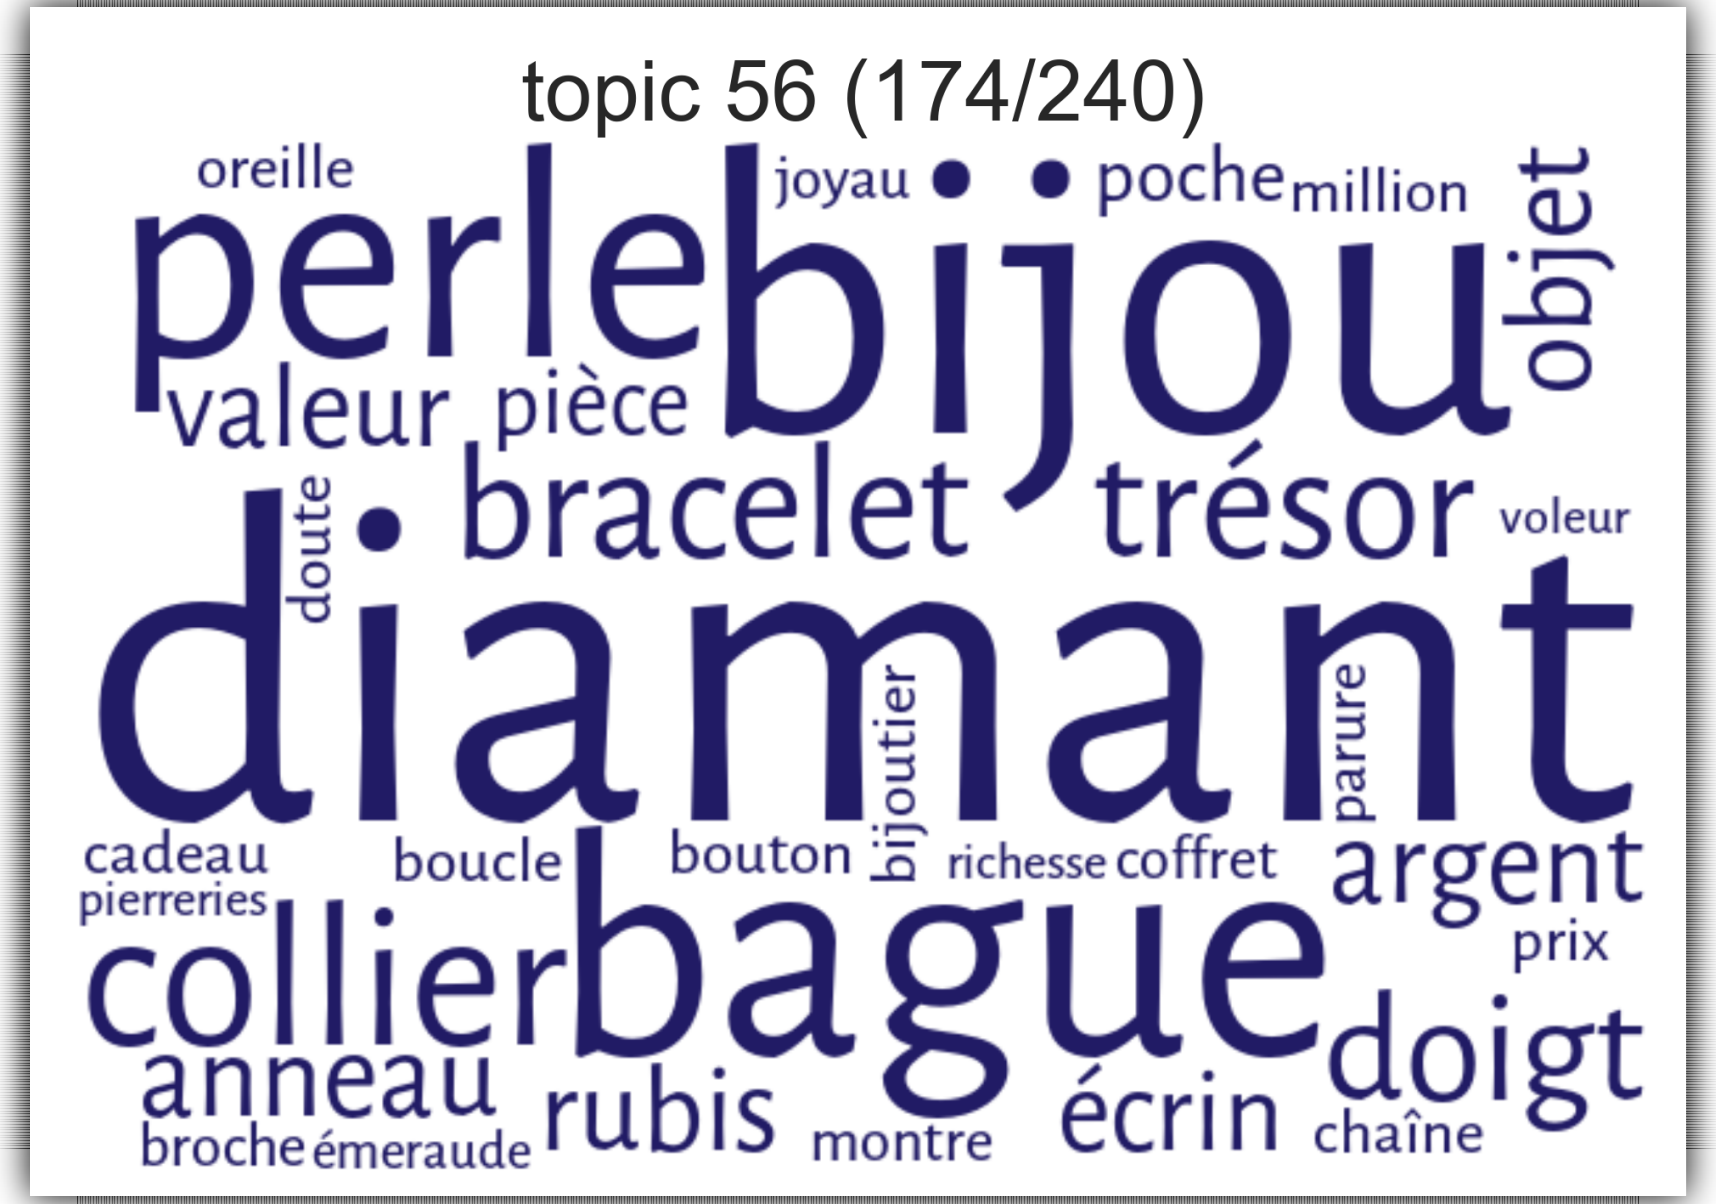

Diamant, Schmuck, Ring, Perle

Statistisch: Überblick

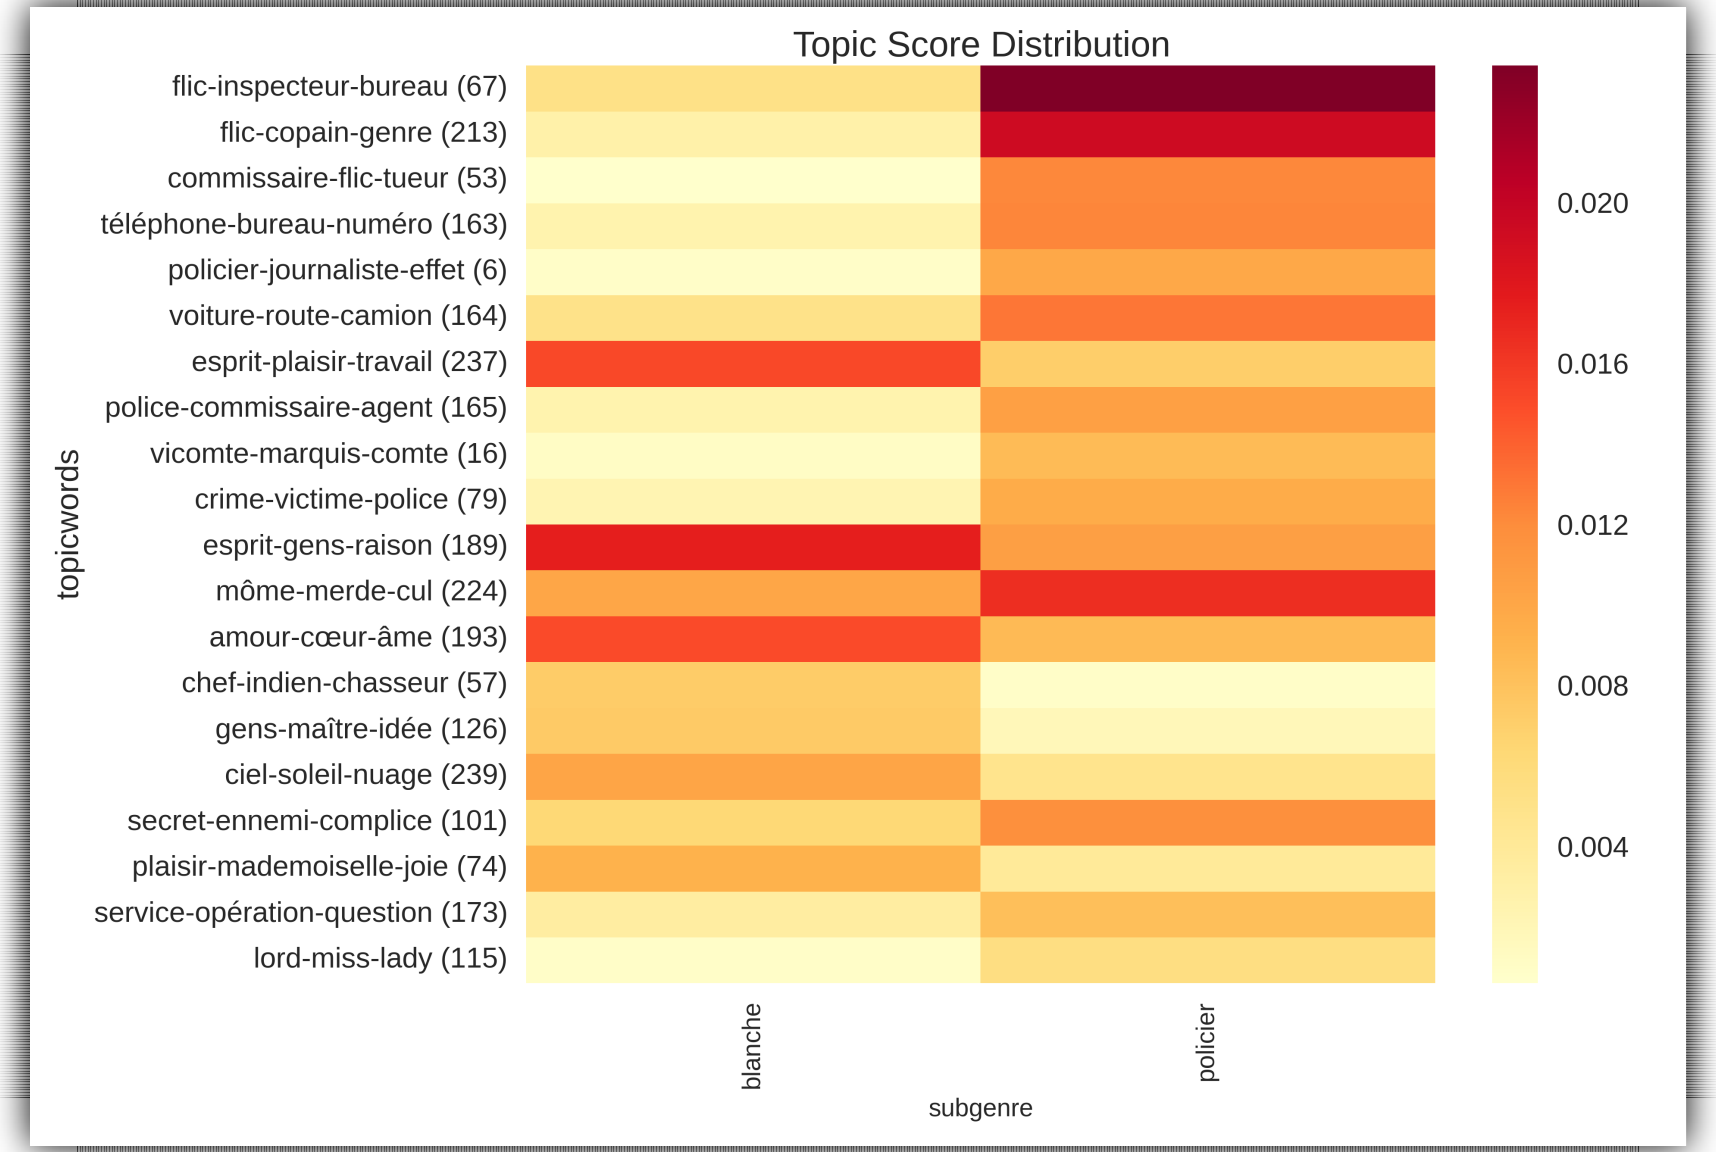

(z-score-Normalisierung - Sortierung nach Standardabweichung)

Statistisch: Nicht-Krimis

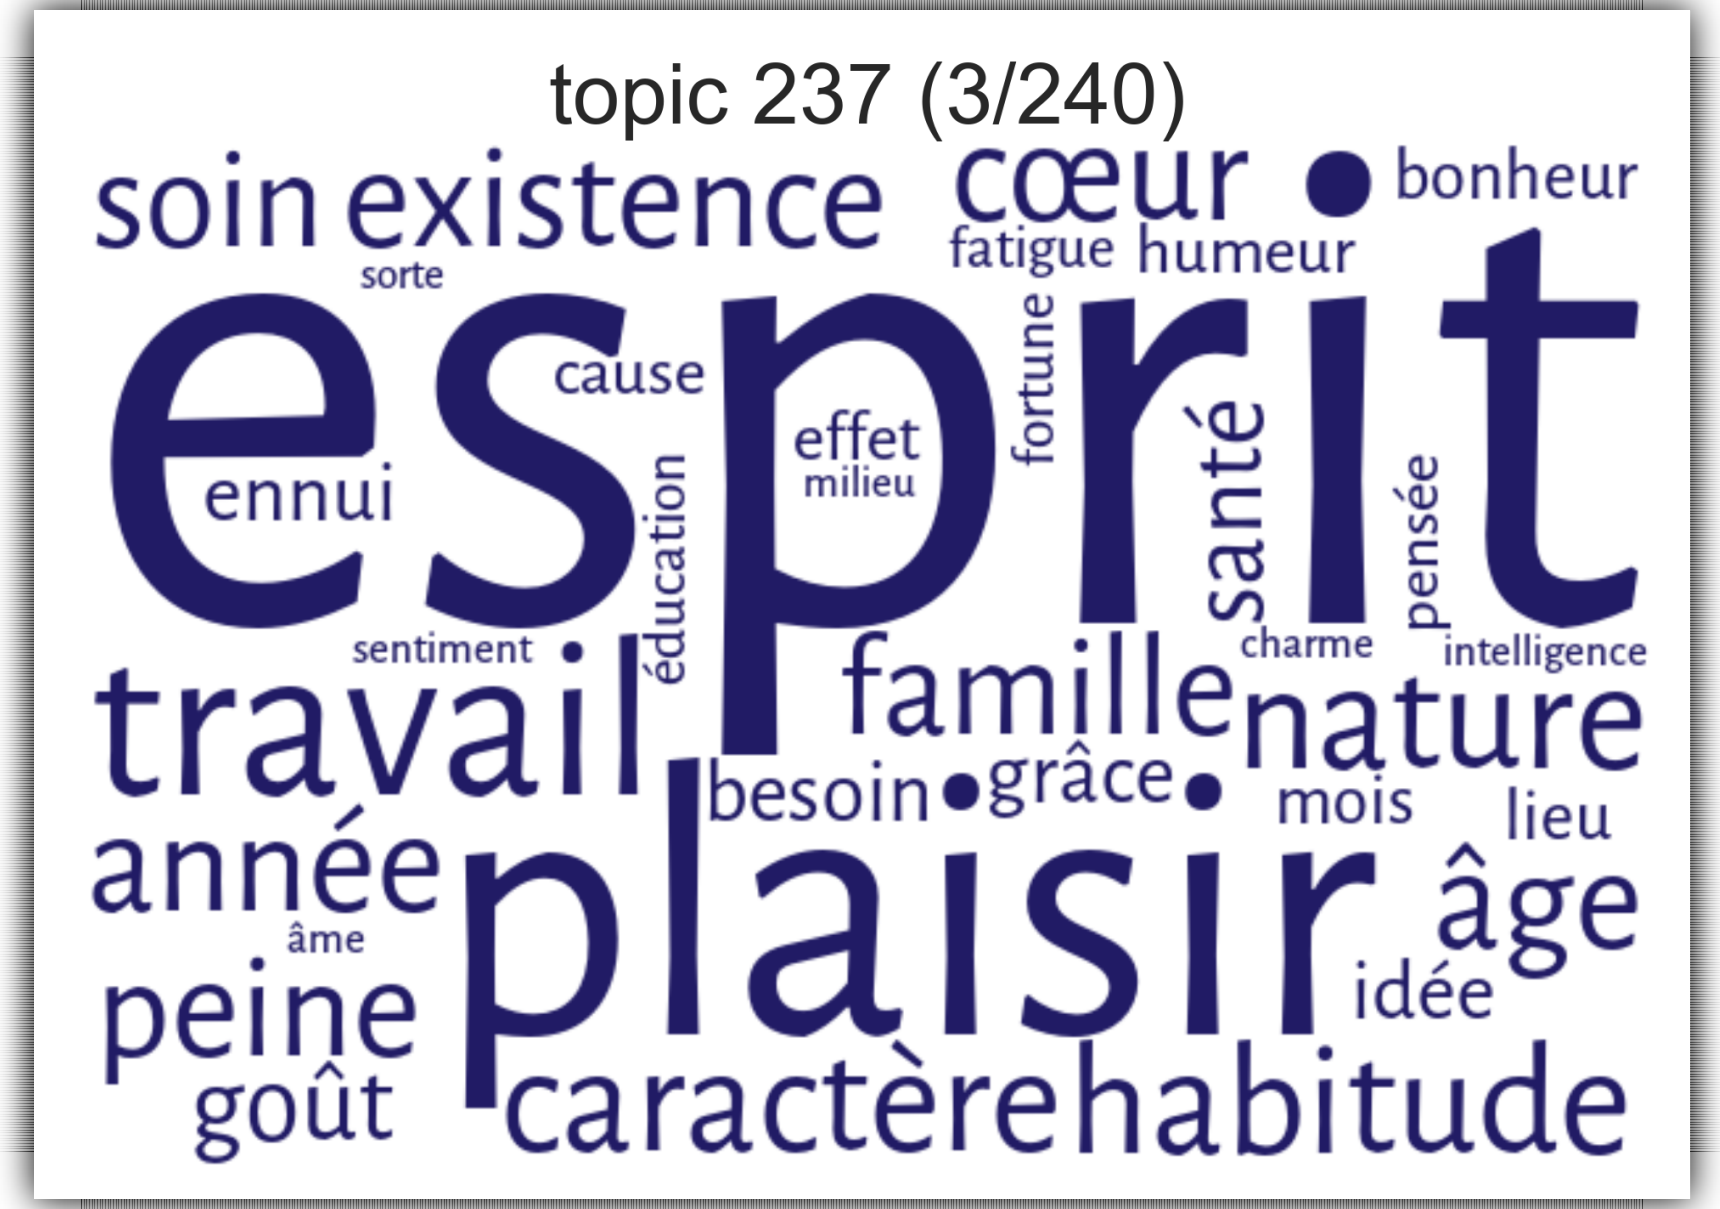

Geist, Arbeit, Vergnügen

Statistisch: Nicht-Krimis

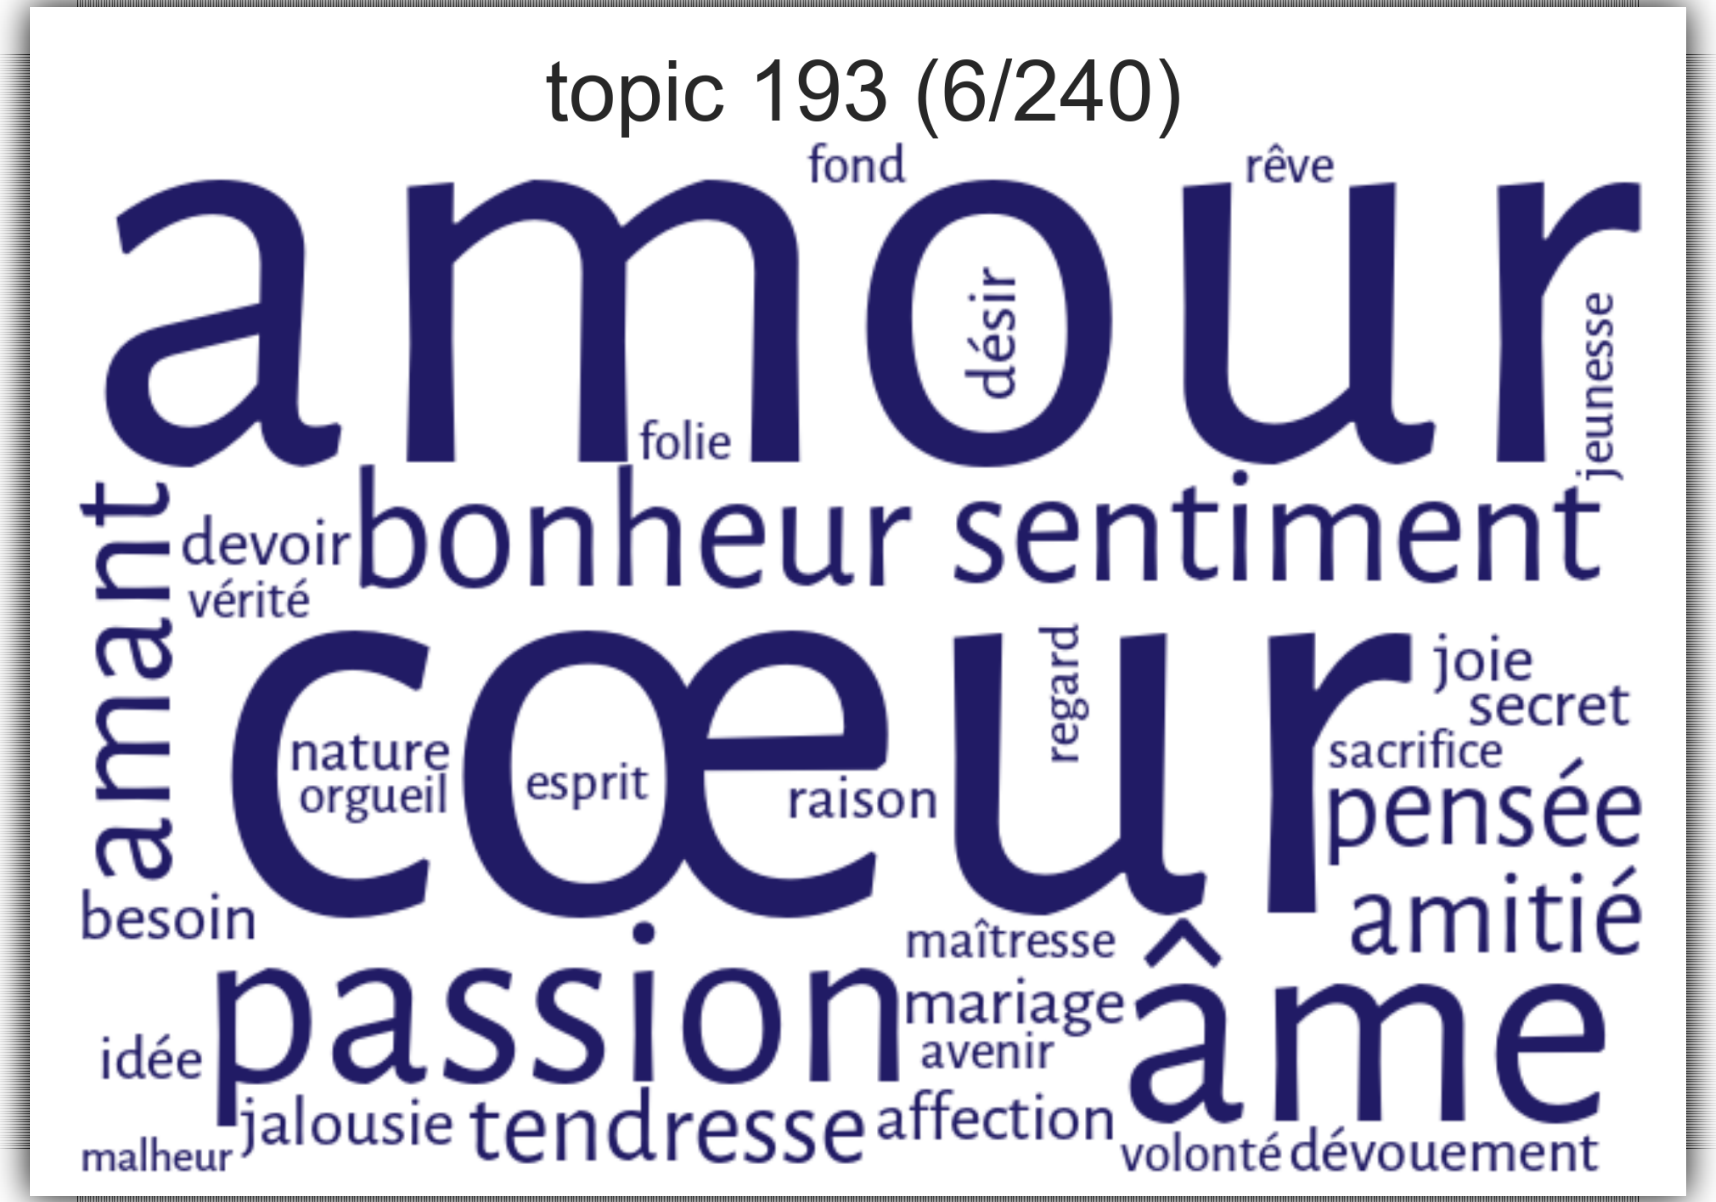

Liebe, Herz, Seele

Statistisch: Krimis

Polizist, Inspektor, Büro

Statistisch: Krimis

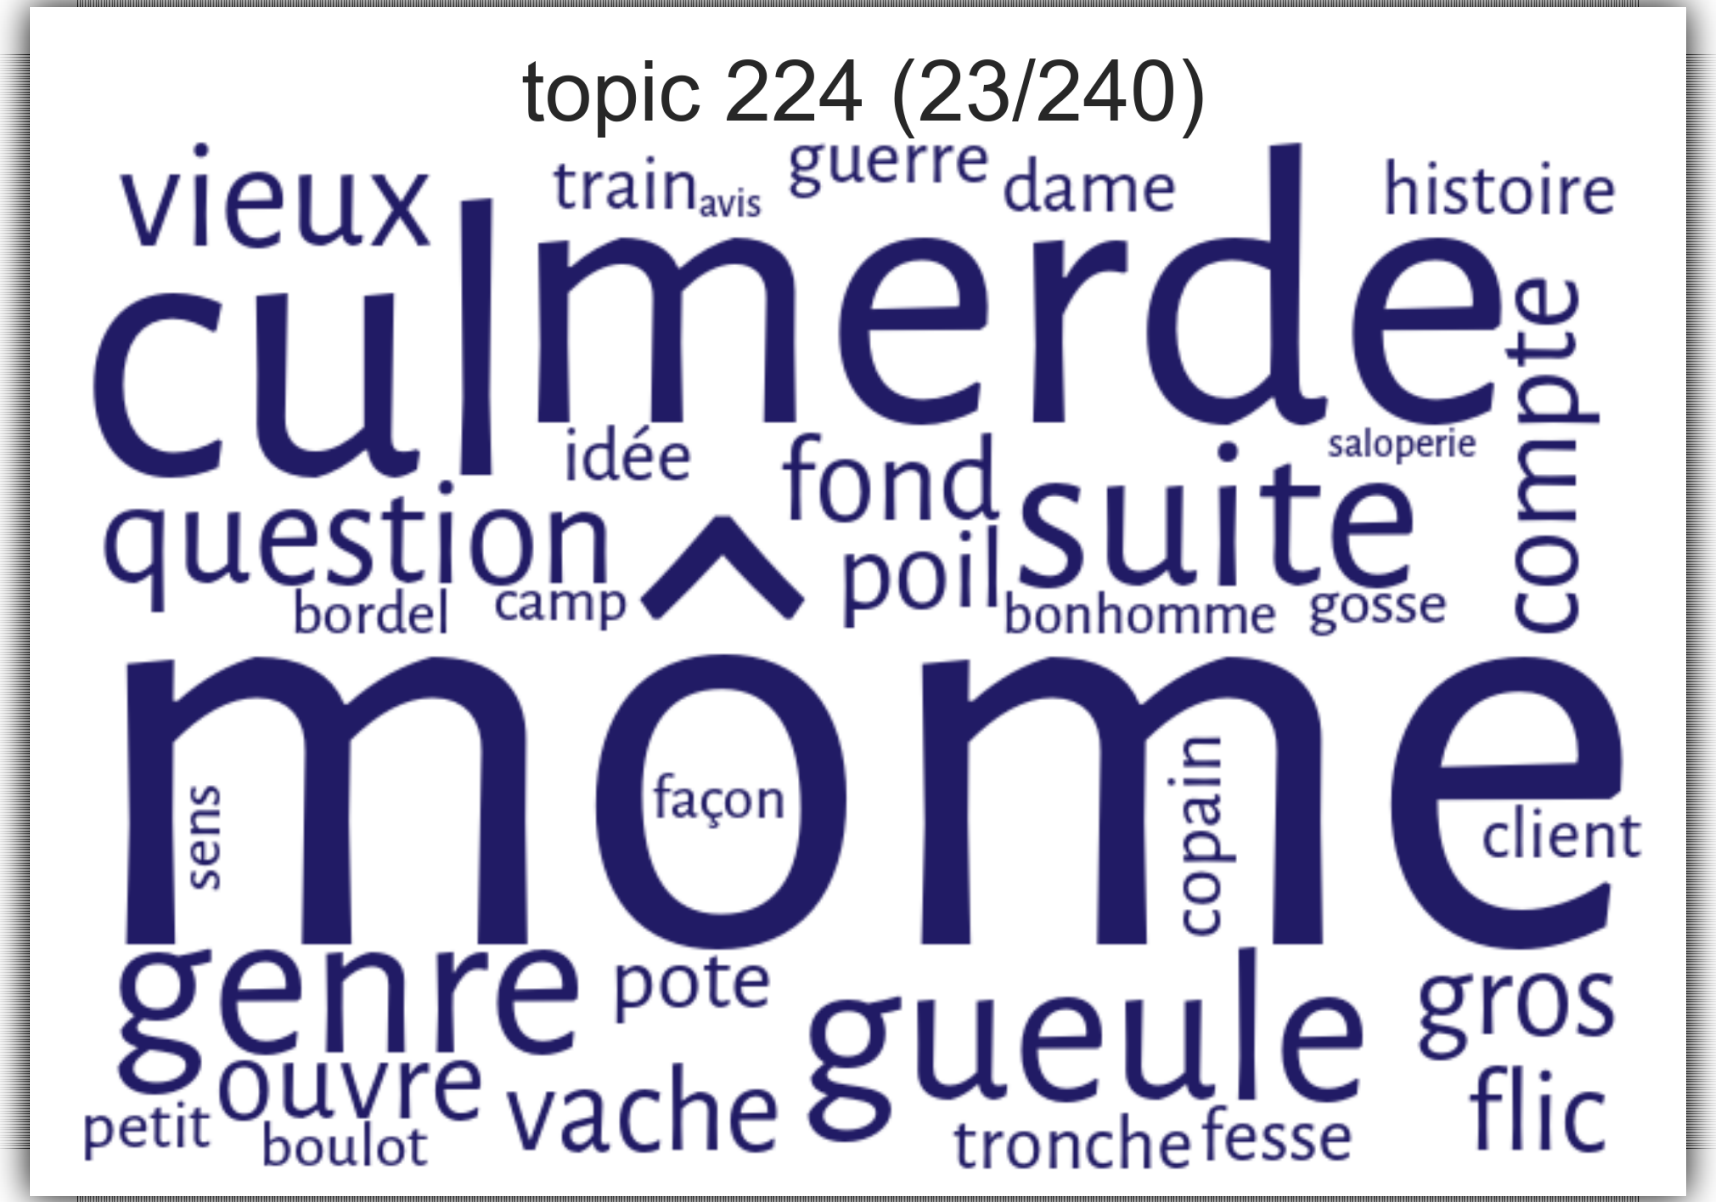

Kleine/r, Hintern, Sch**ße

Topic 224: Autoren?

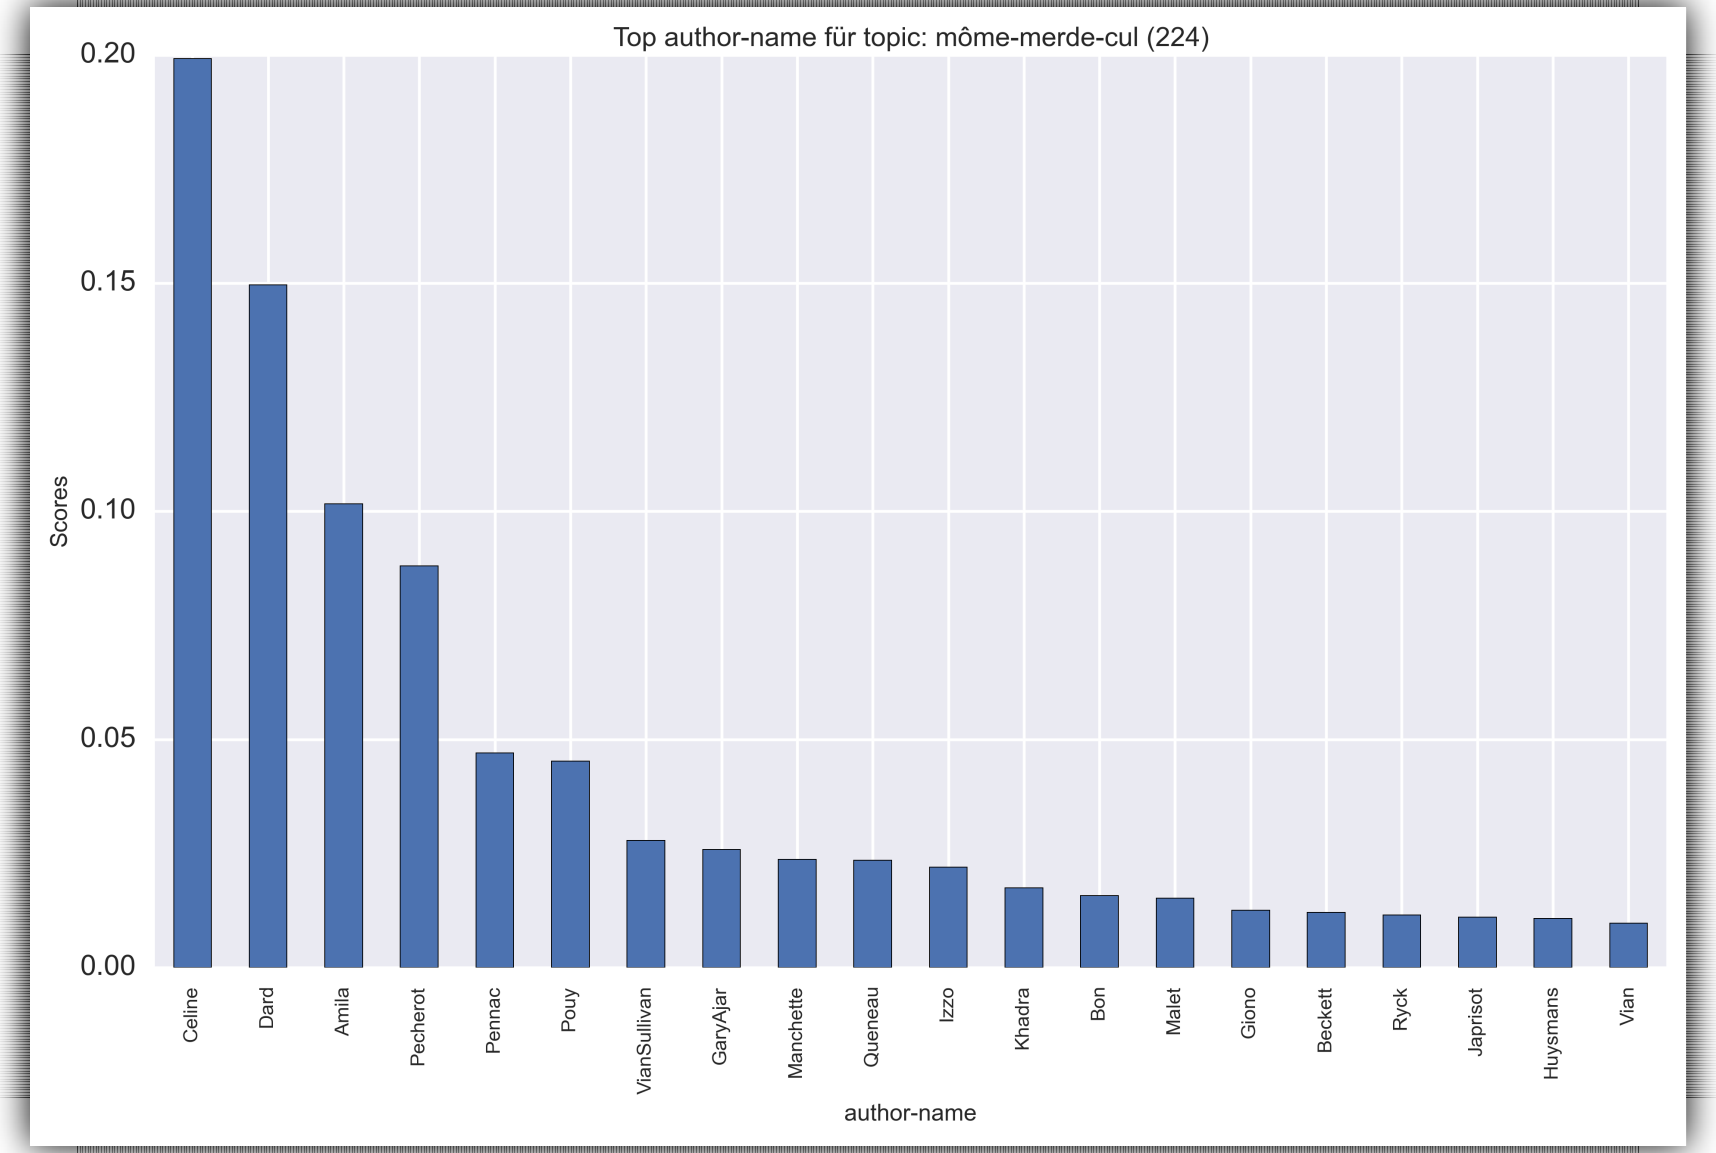

Kleine/r, Hintern, Sch**ße

Distinktivität vs. Clustering

Distinktive Topics (nur Krimis)

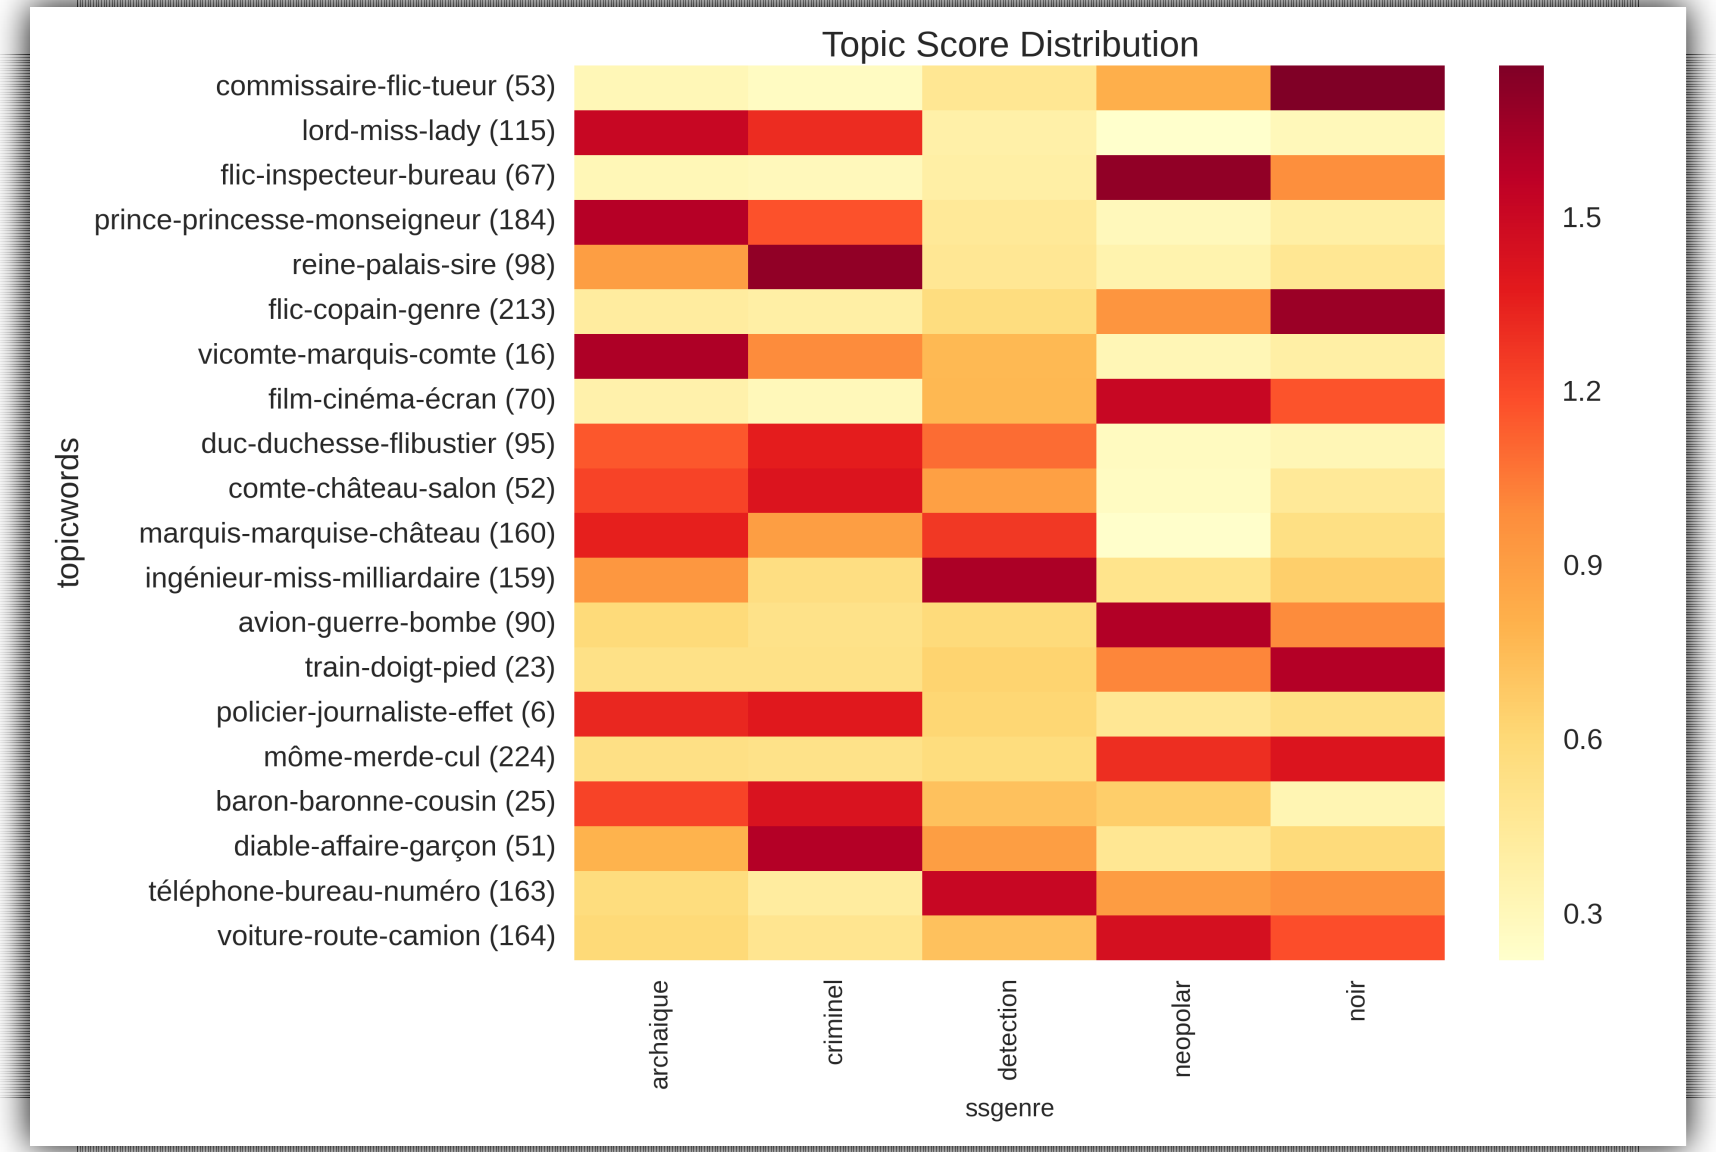

PCA der (Krimi-)Autoren

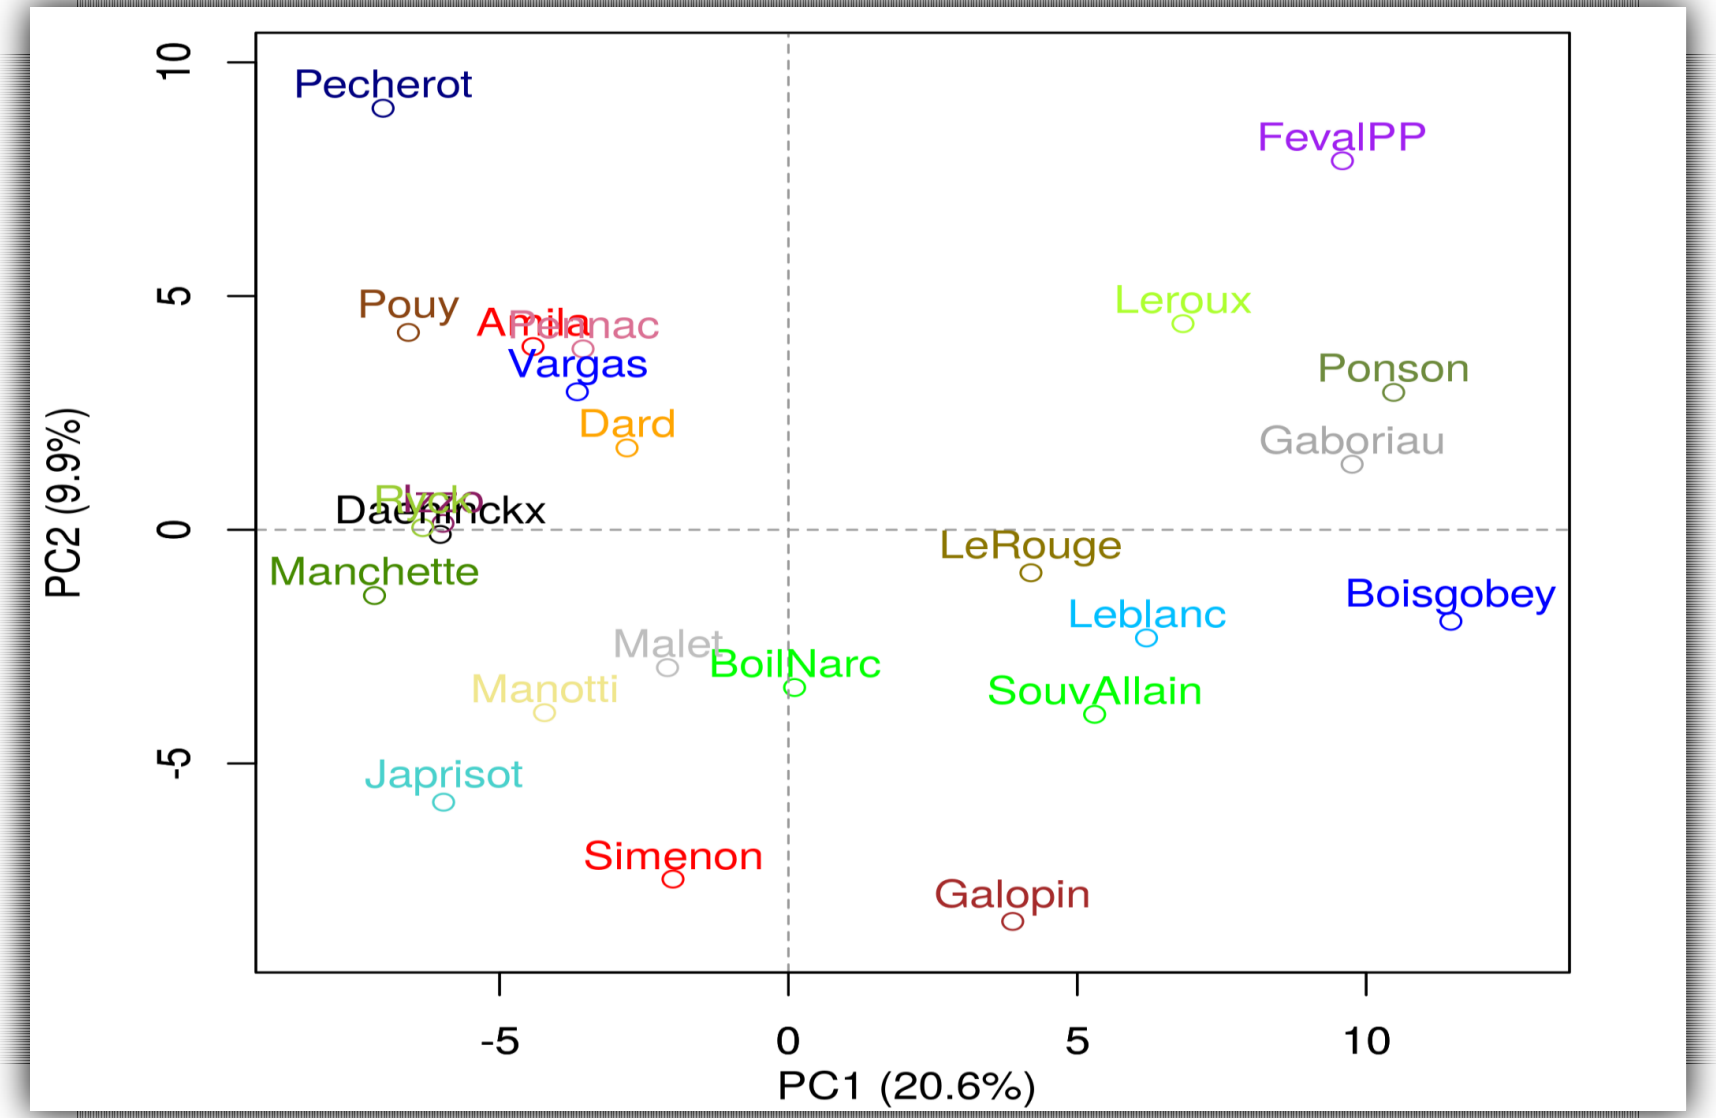

(Grundlage: Topics 20-220 aus 240)

Distanz-Clustering

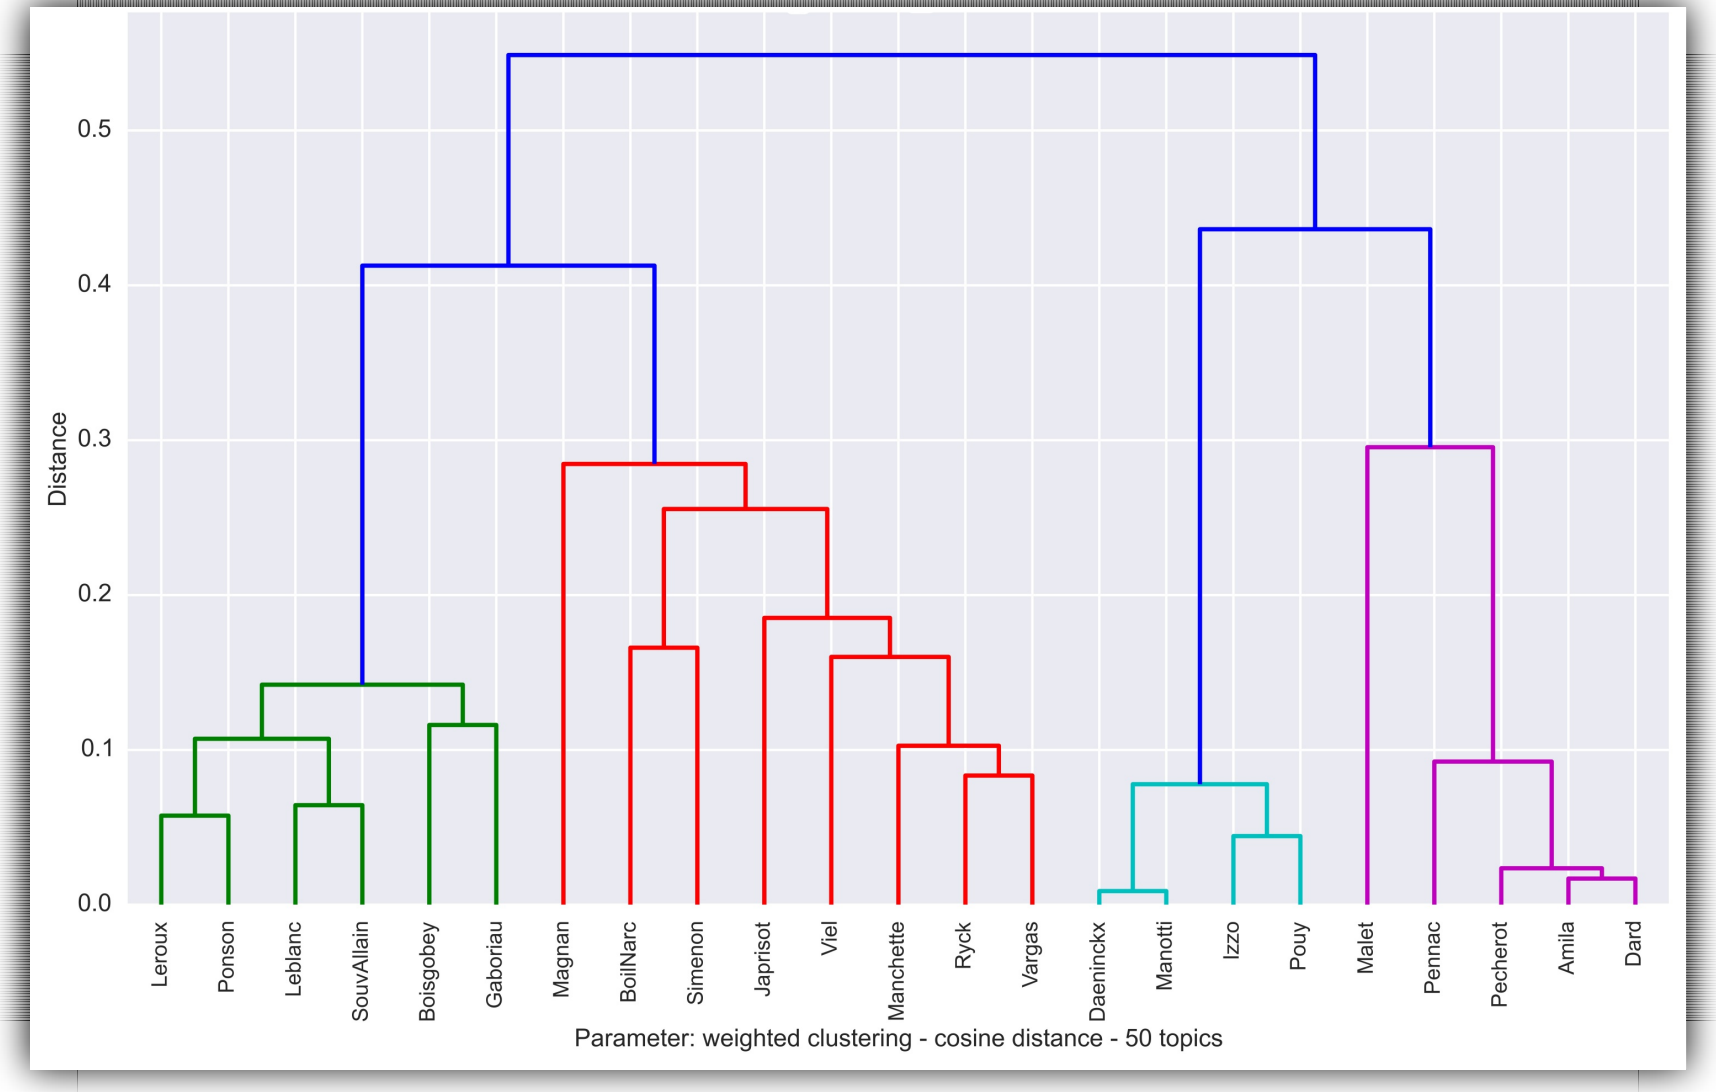

,

Fazit

Wesentliche Aspekte

- Topics ≠ Themen, sondern auch: Personal, Setting, Motive, Metatopics
- Inhaltlich typisch ≠ statistisch distinktiv
- Gesamtsammlung: max. 10% "Krimi-Topics"; große Topic-Gemeinsamkeiten
- Clustering nach Topic-Werten: Zeit stärkster Faktor!
- Visualisierung als Instrument der "Makroanalyse" (Jockers)
- Dynamische, interaktive Verknüpfung der Visualisierungen
- Viel über wenige Texte sagen vs. wenig über viele Texte sagen?

Vielen Dank

http://www.christof-schoech.de

https://twitter.com/christof77

Lektürehinweise

- Blei, David M. « Probabilistic Topic Models ». *Communications of the ACM* 55, nº 4 (2012): 77-84.
- Dubois, Jacques. *Le roman policier, ou la modernité*. Paris: Colin, 2005.
- Jockers, Matthew. *Macroanalysis - Digital Methods and Literary History*. Champaign, IL: University of Illinois Press, 2013.
- Lits, Marc. *Le roman policier. Introduction à la théorie et l'histoire d'un genre littéraire*. Liège: Éd. du CÉFAL, 1993.
- Schöch, Christof. « Topic Modeling Genre: An Exploration of French Classical and Enlightenment Drama ». *Digital Humanities Quarterly*, 2015 (angenommen).
- Steyvers, Mark, et Tom Griffiths. « Probabilistic Topic Models ». In *Latent Semantic Analysis: A Road to Meaning*, ed. T. Landauer et al. Laurence Erlbaum, 2006.
- Todorov, Tzvetan. « Typologie du roman policier » (1966). *Poétique de la prose*, 55–65. Paris: Seuil, 1971.