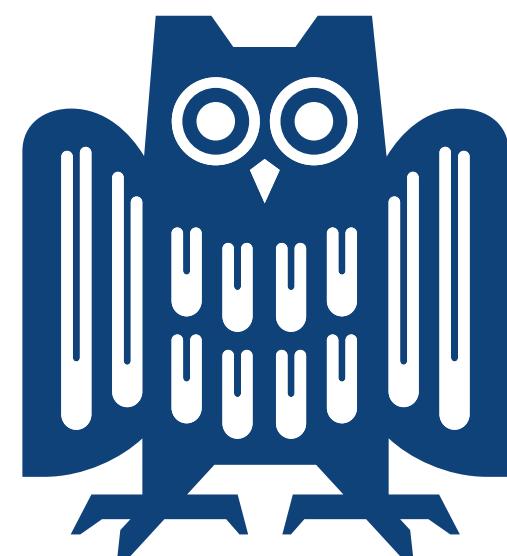


Wie können uns informationstheoretische Maße helfen, die Produktion und die Verarbeitung gesprochener Sprache zu modellieren?

Text+ Plenary

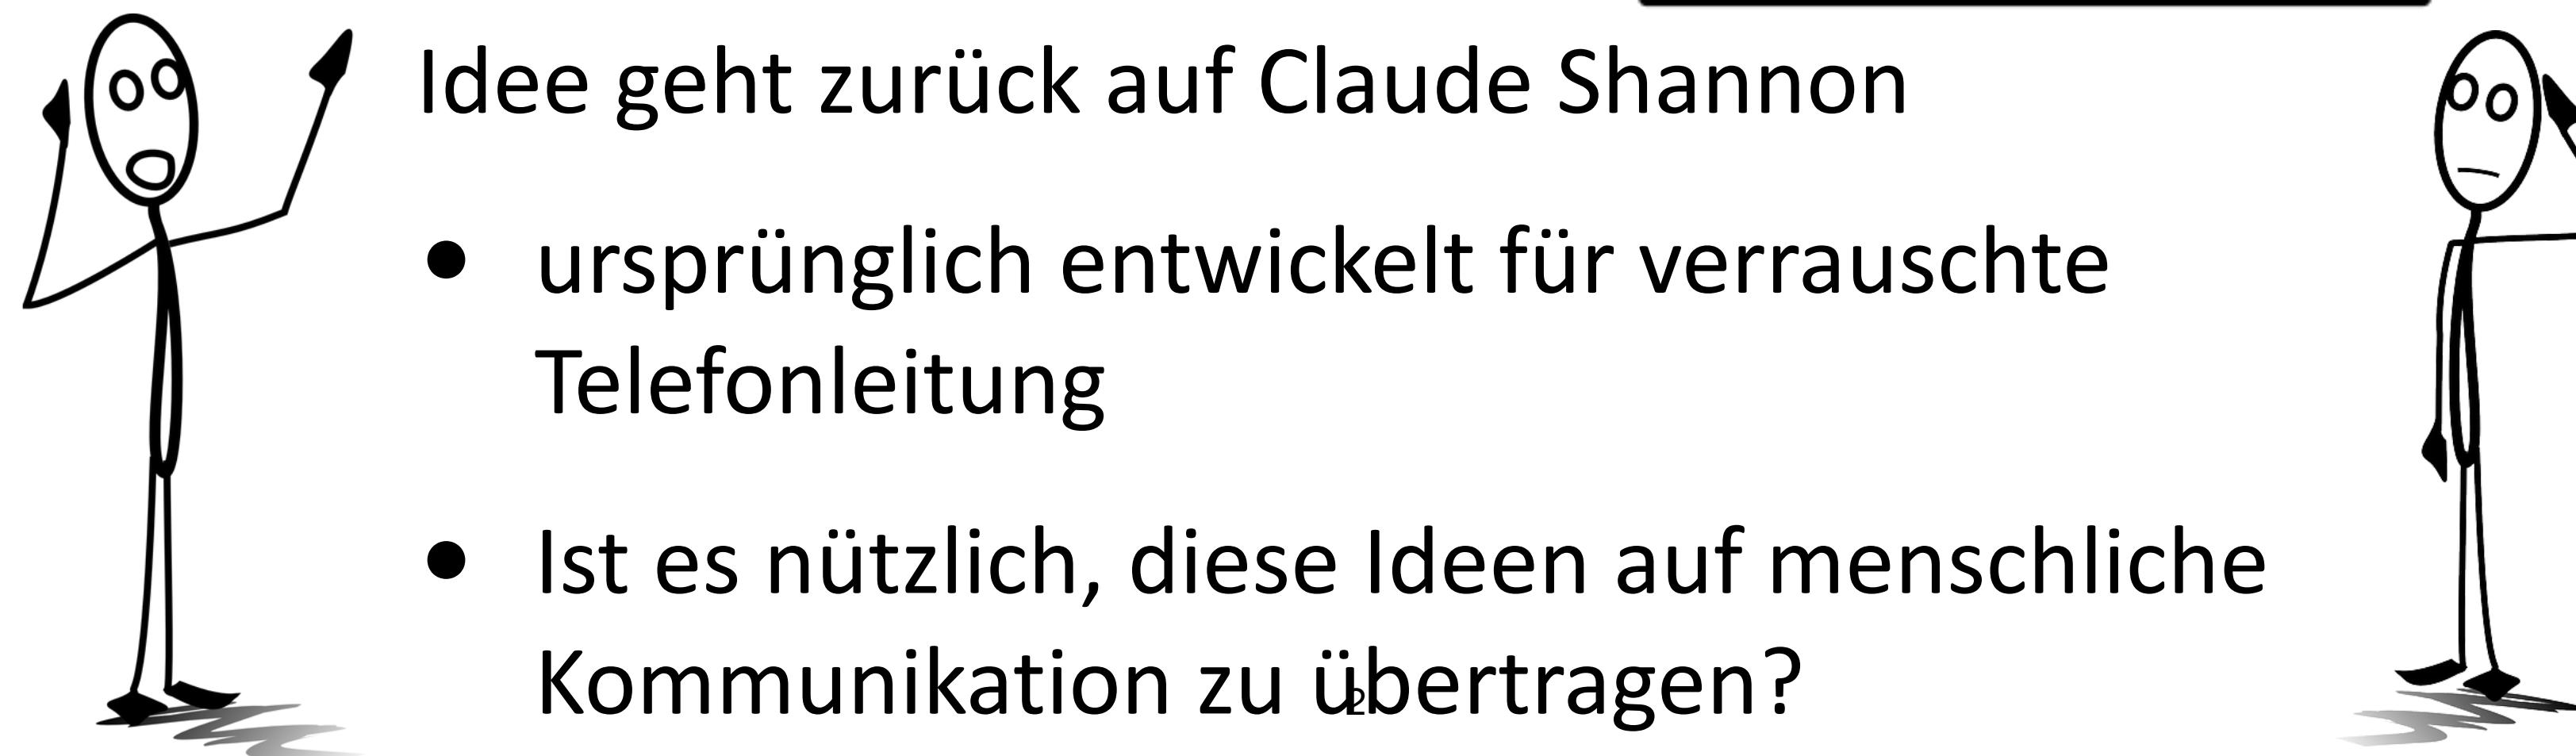
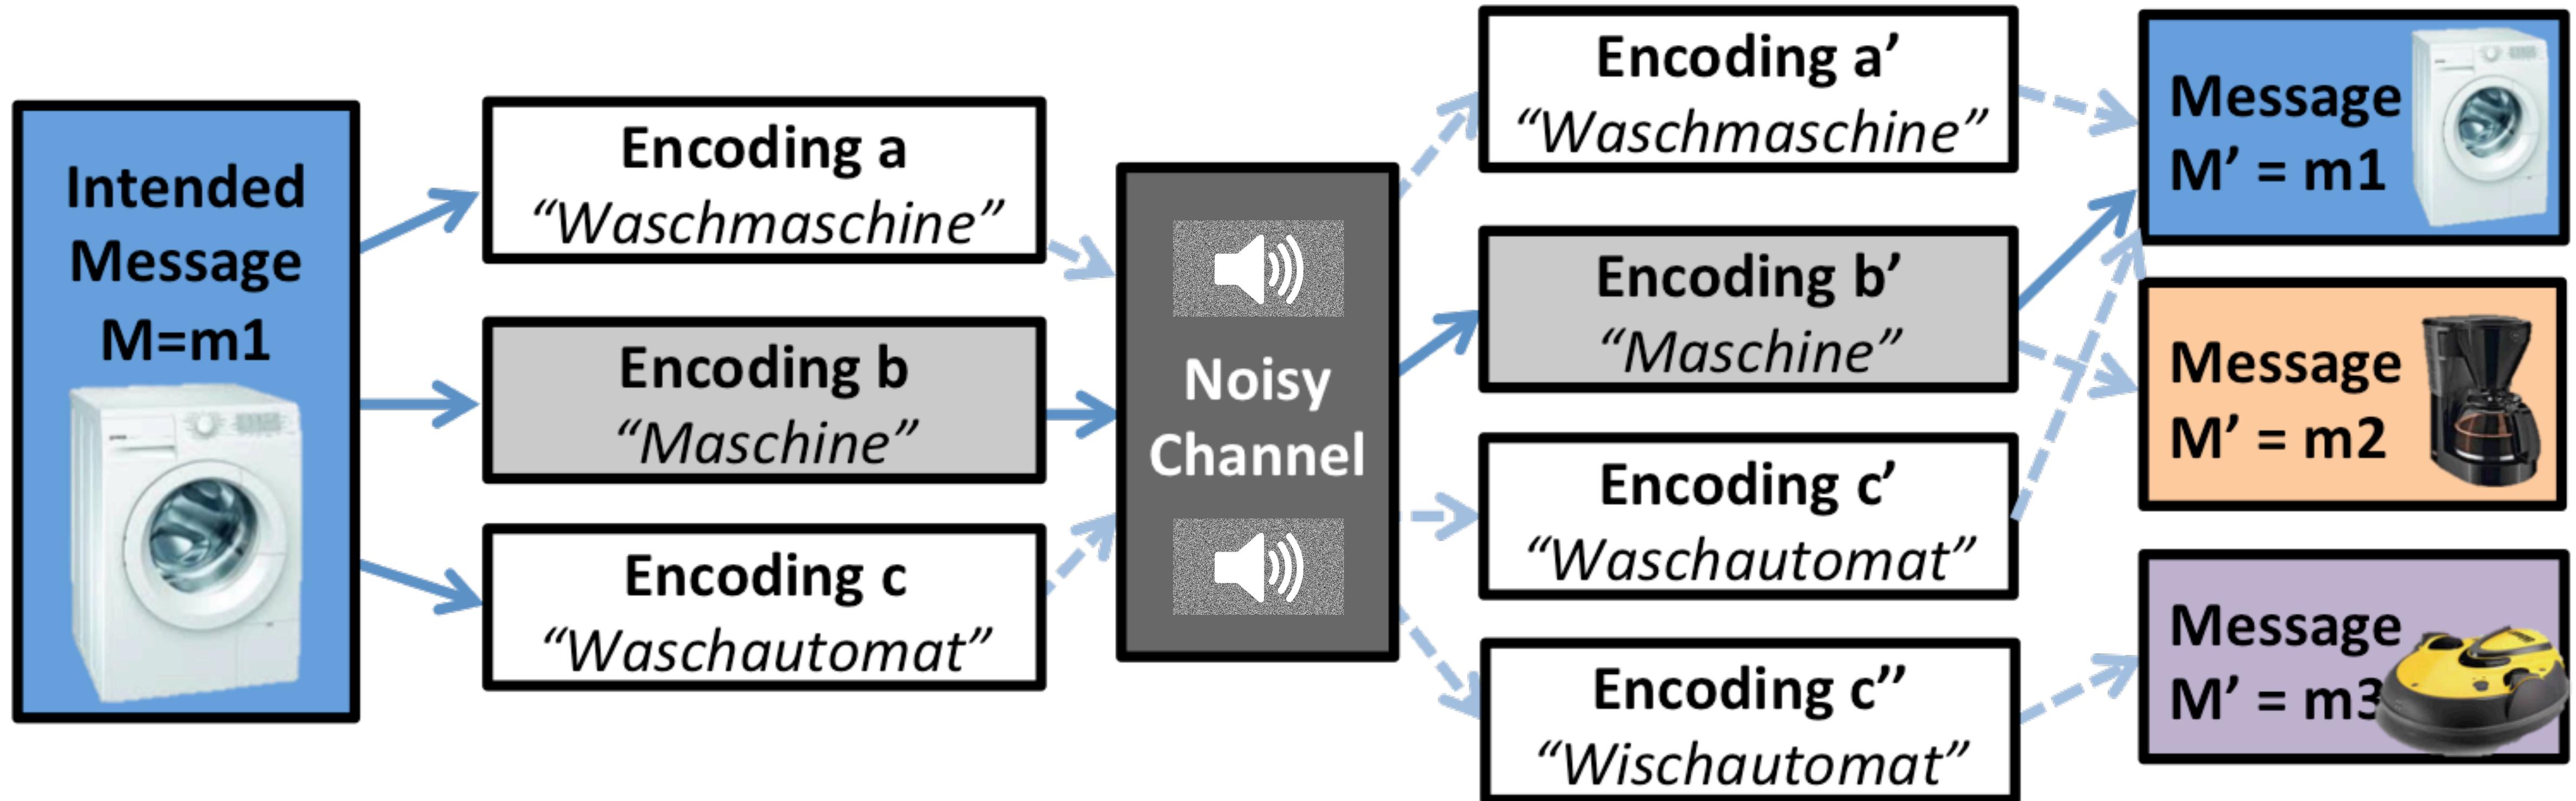
Vera Demberg, Sep 2023

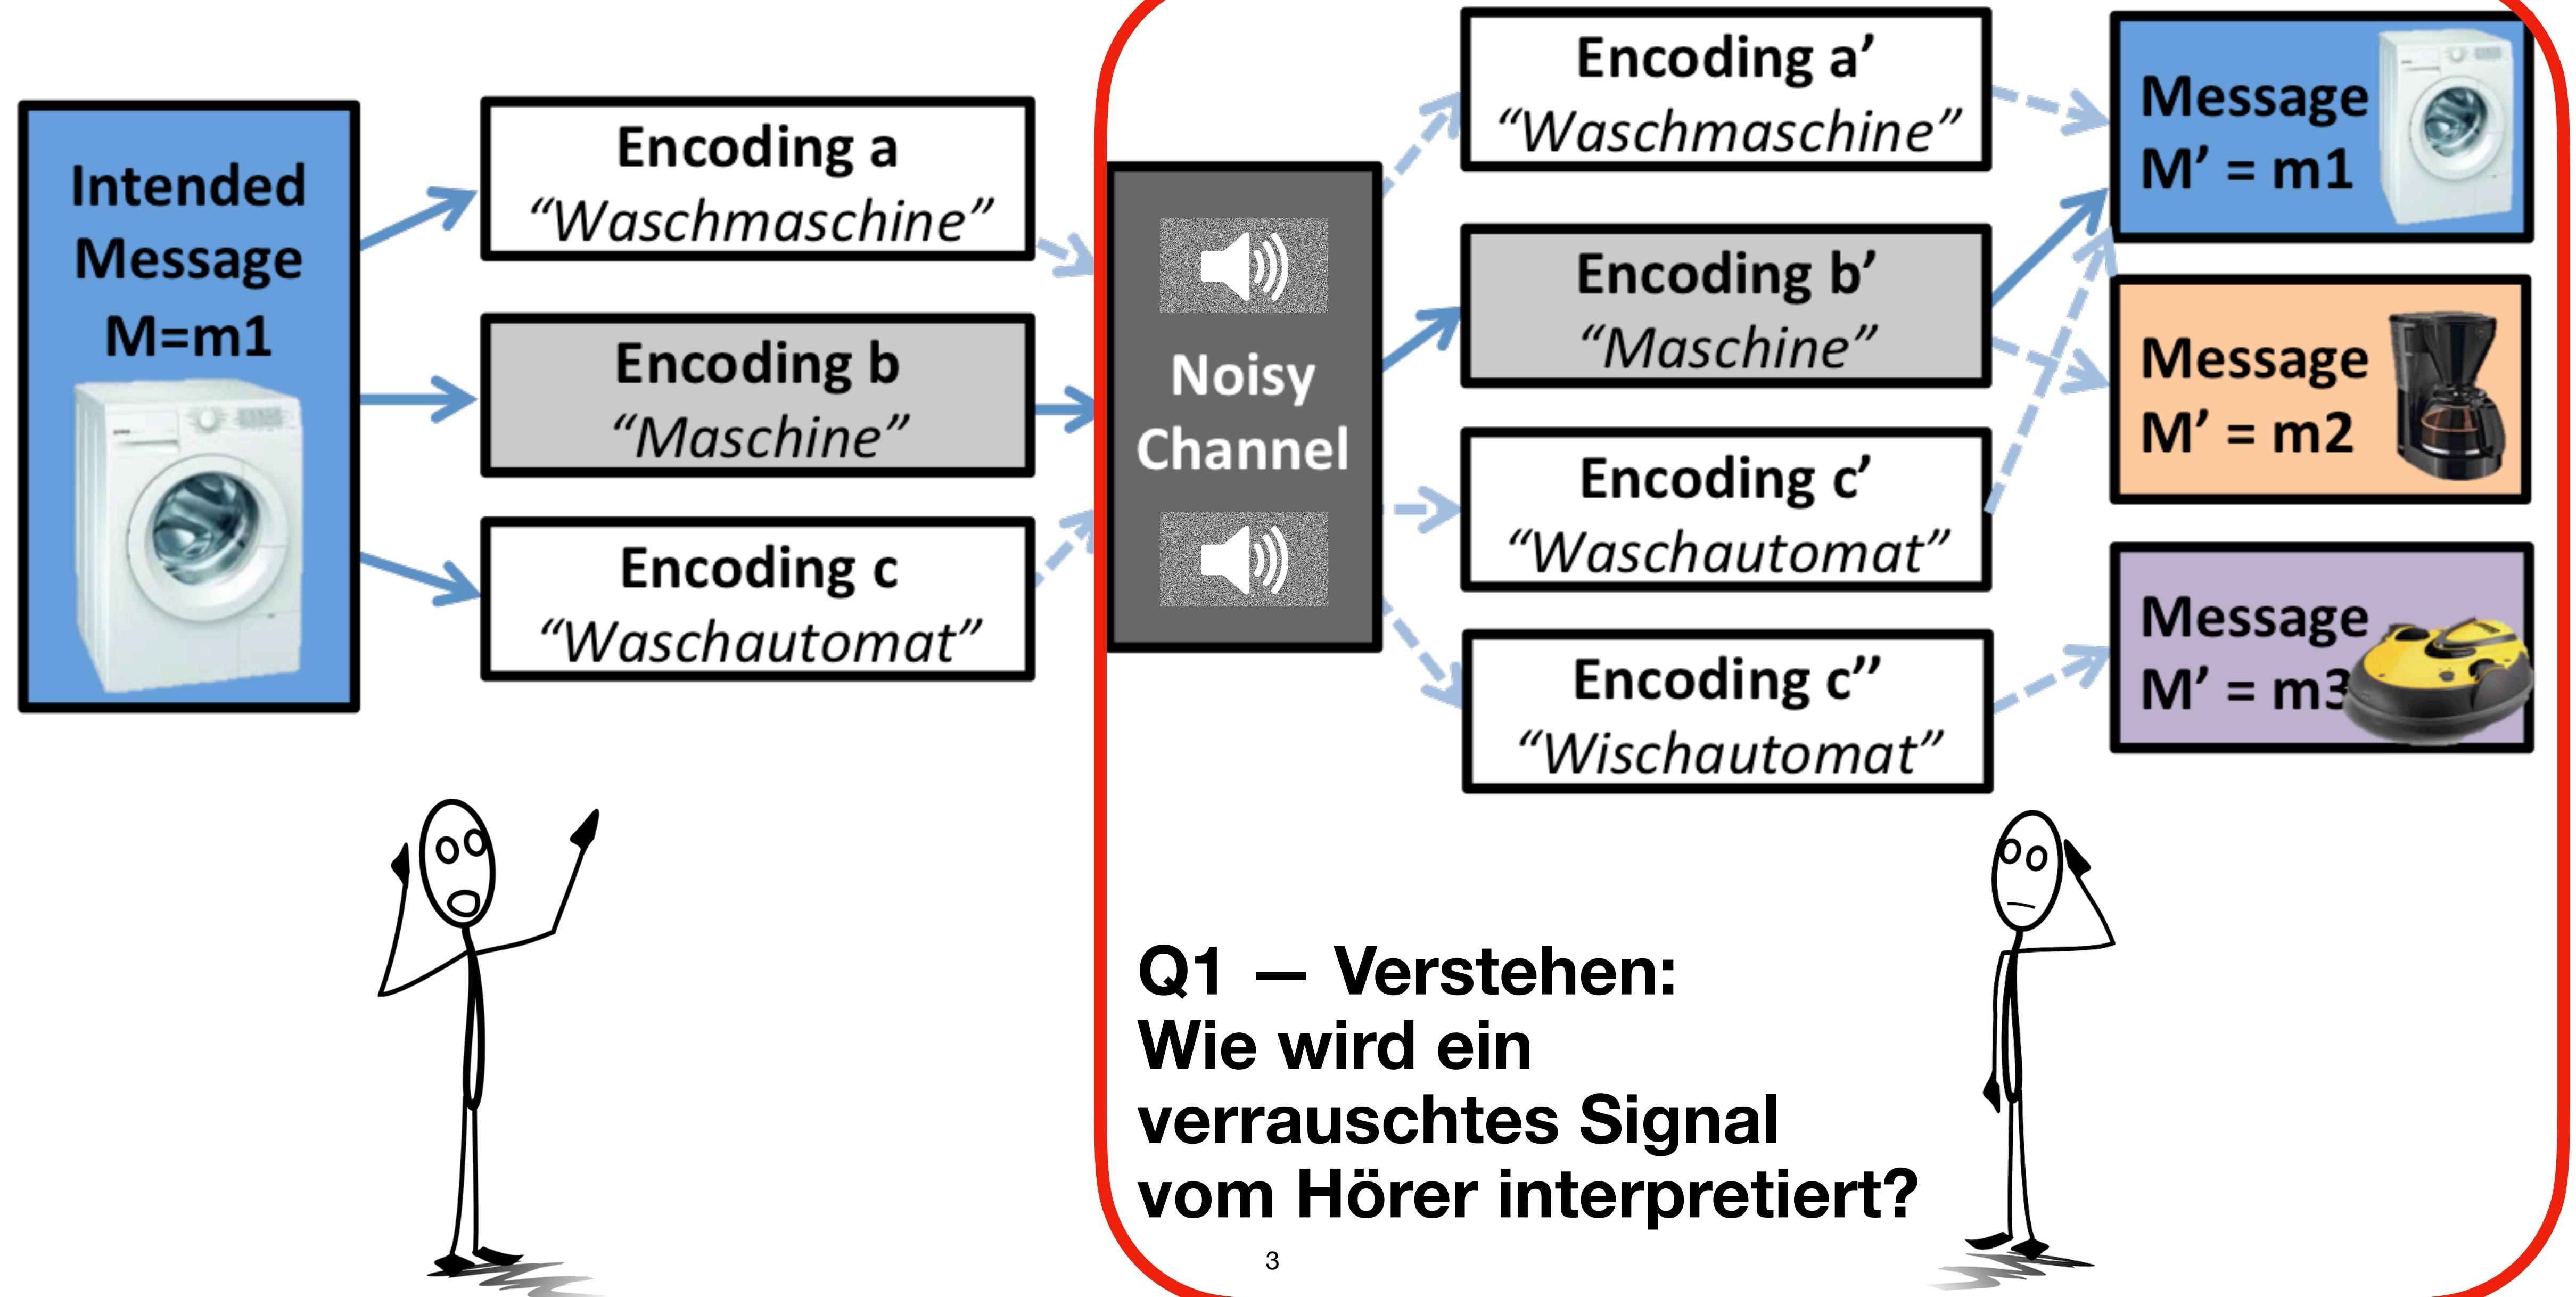


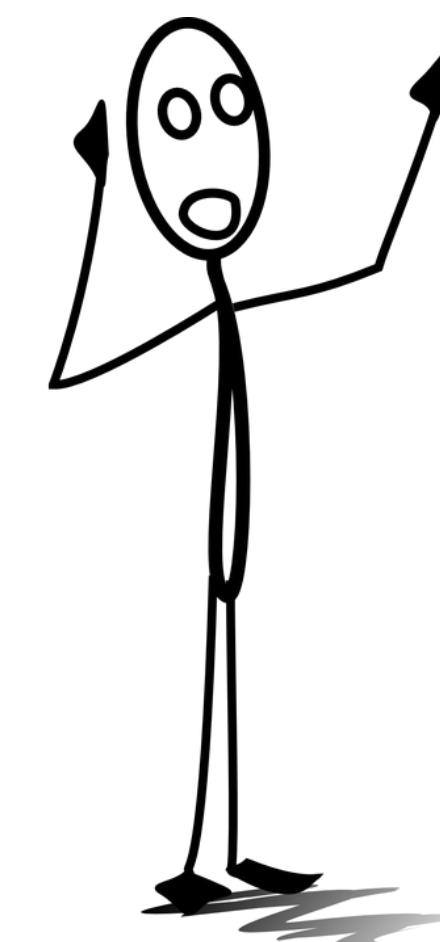
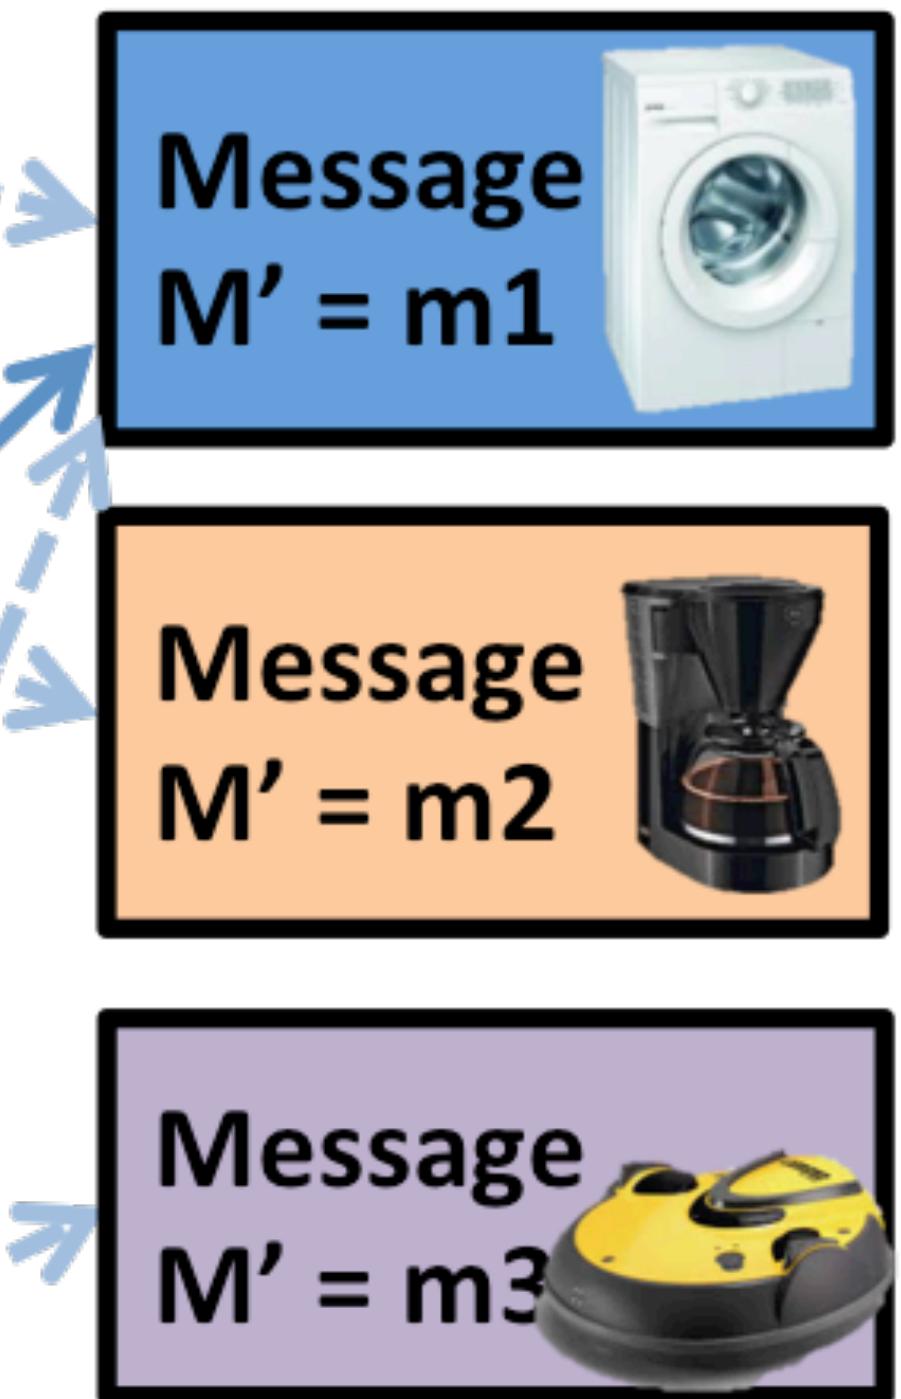
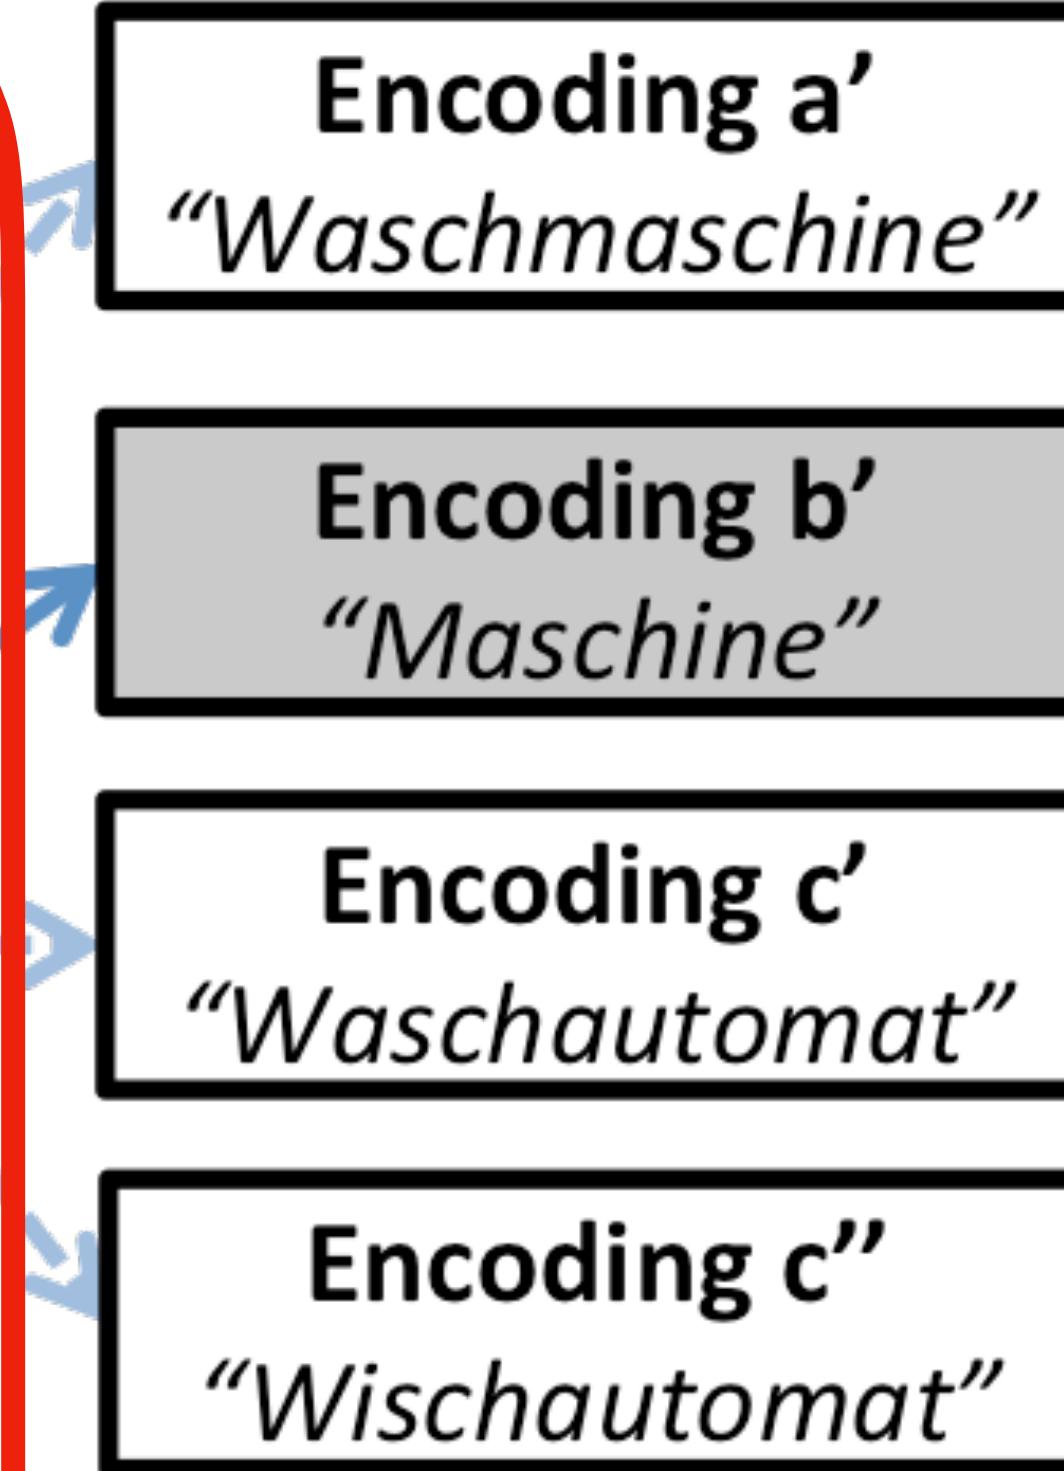
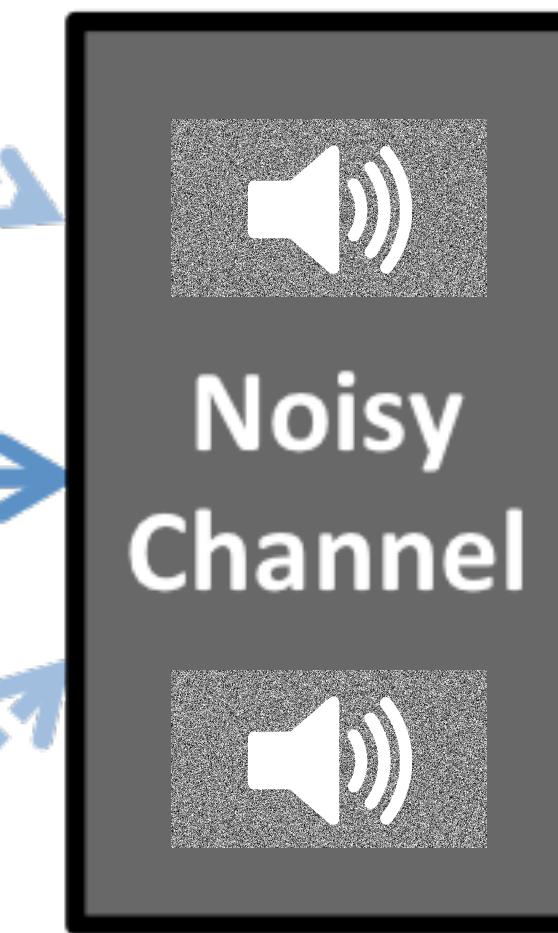
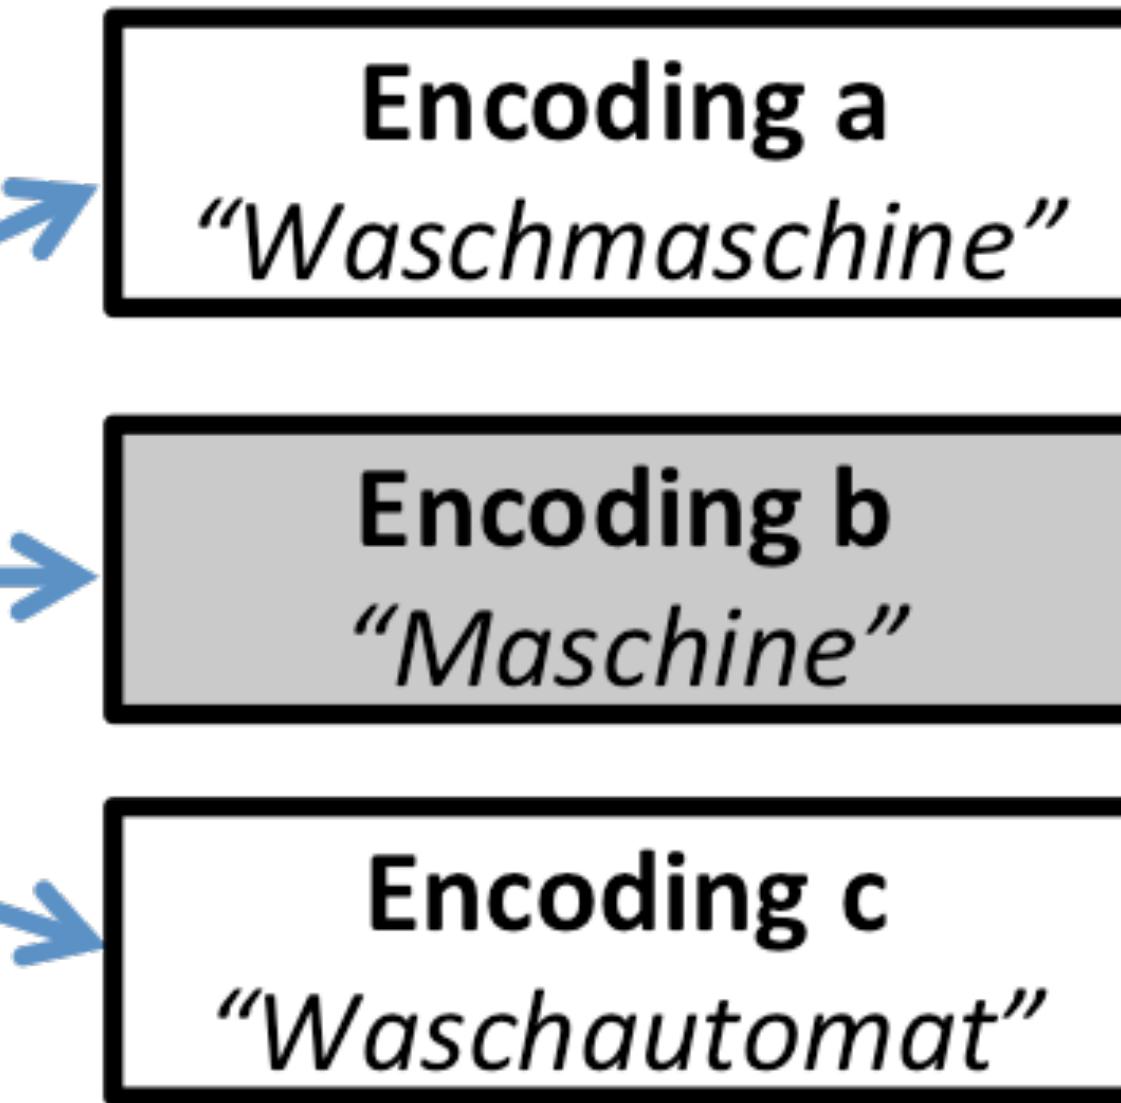
UNIVERSITÄT
DES
SAARLANDES



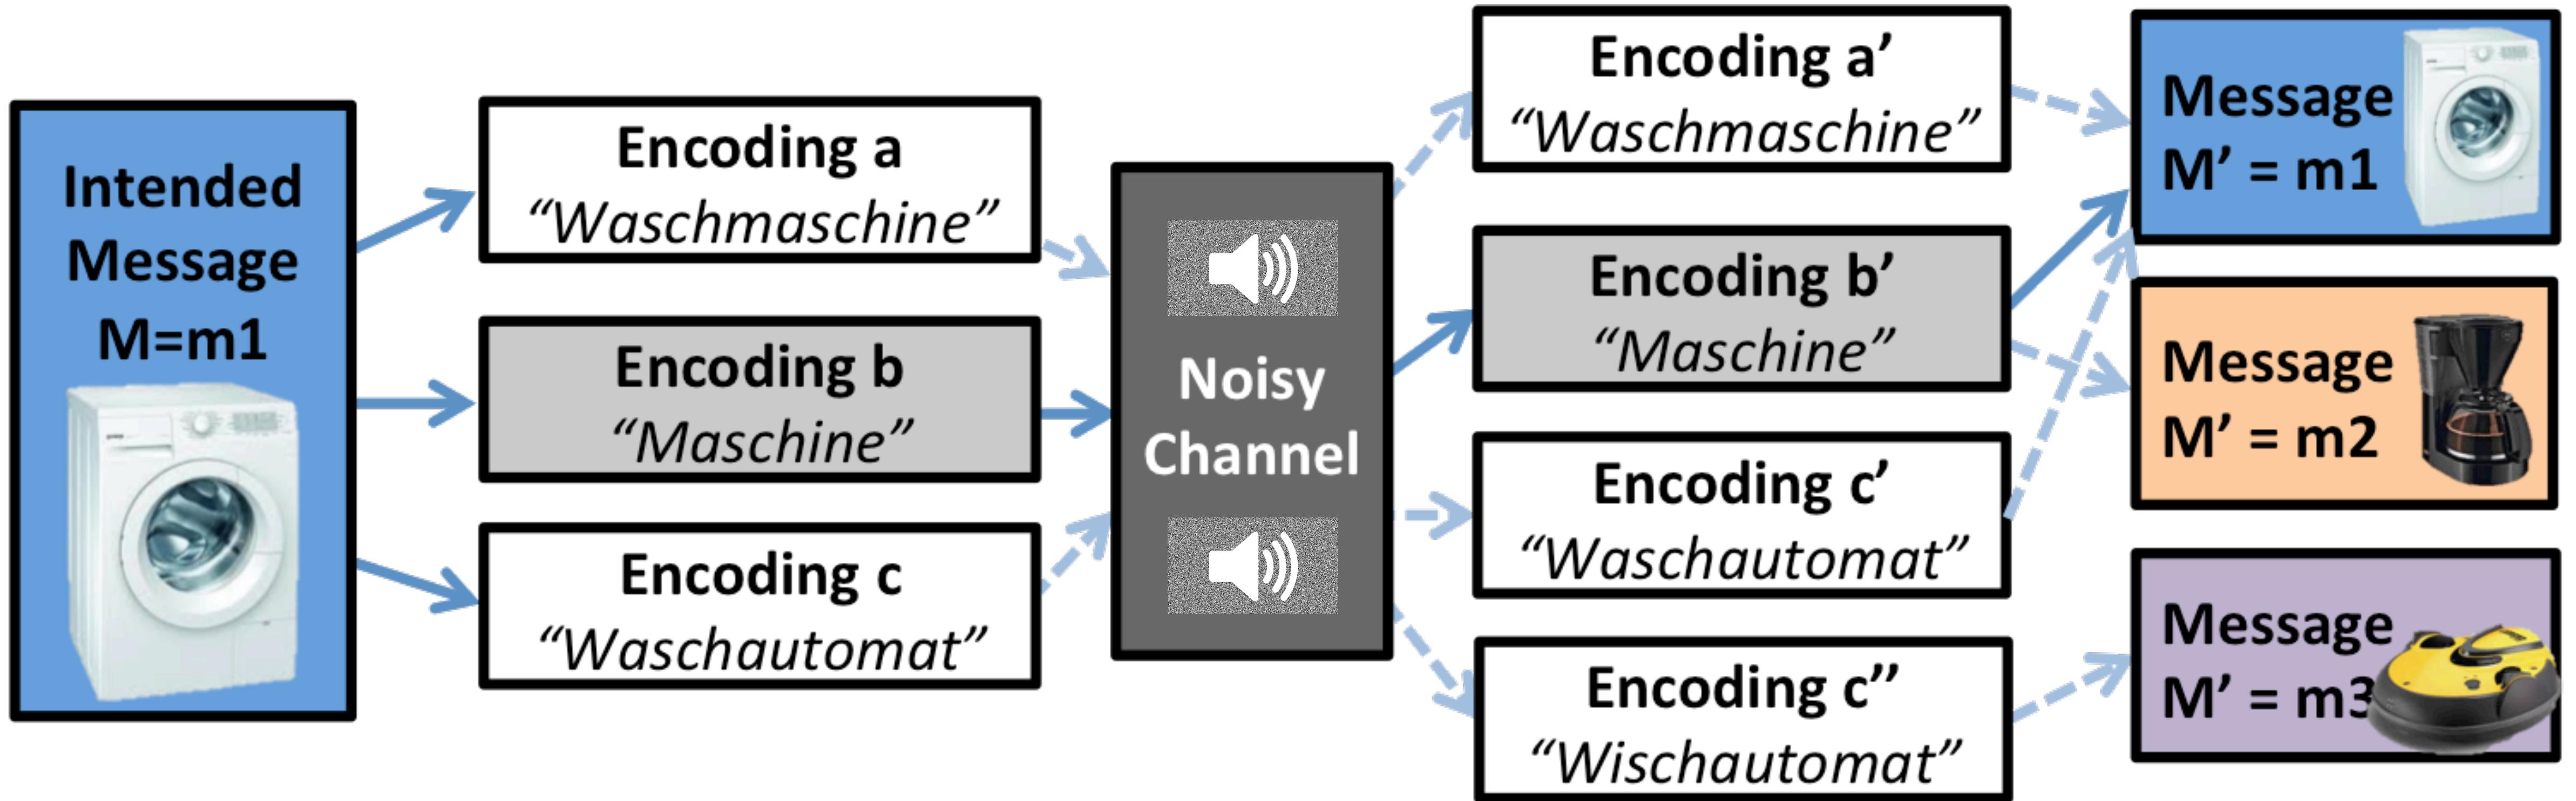
Noisy Channel Model als Modell für Kommunikation







Q2 – Production:
Wie sollte die Nachricht
kodiert (formuliert)
werden?



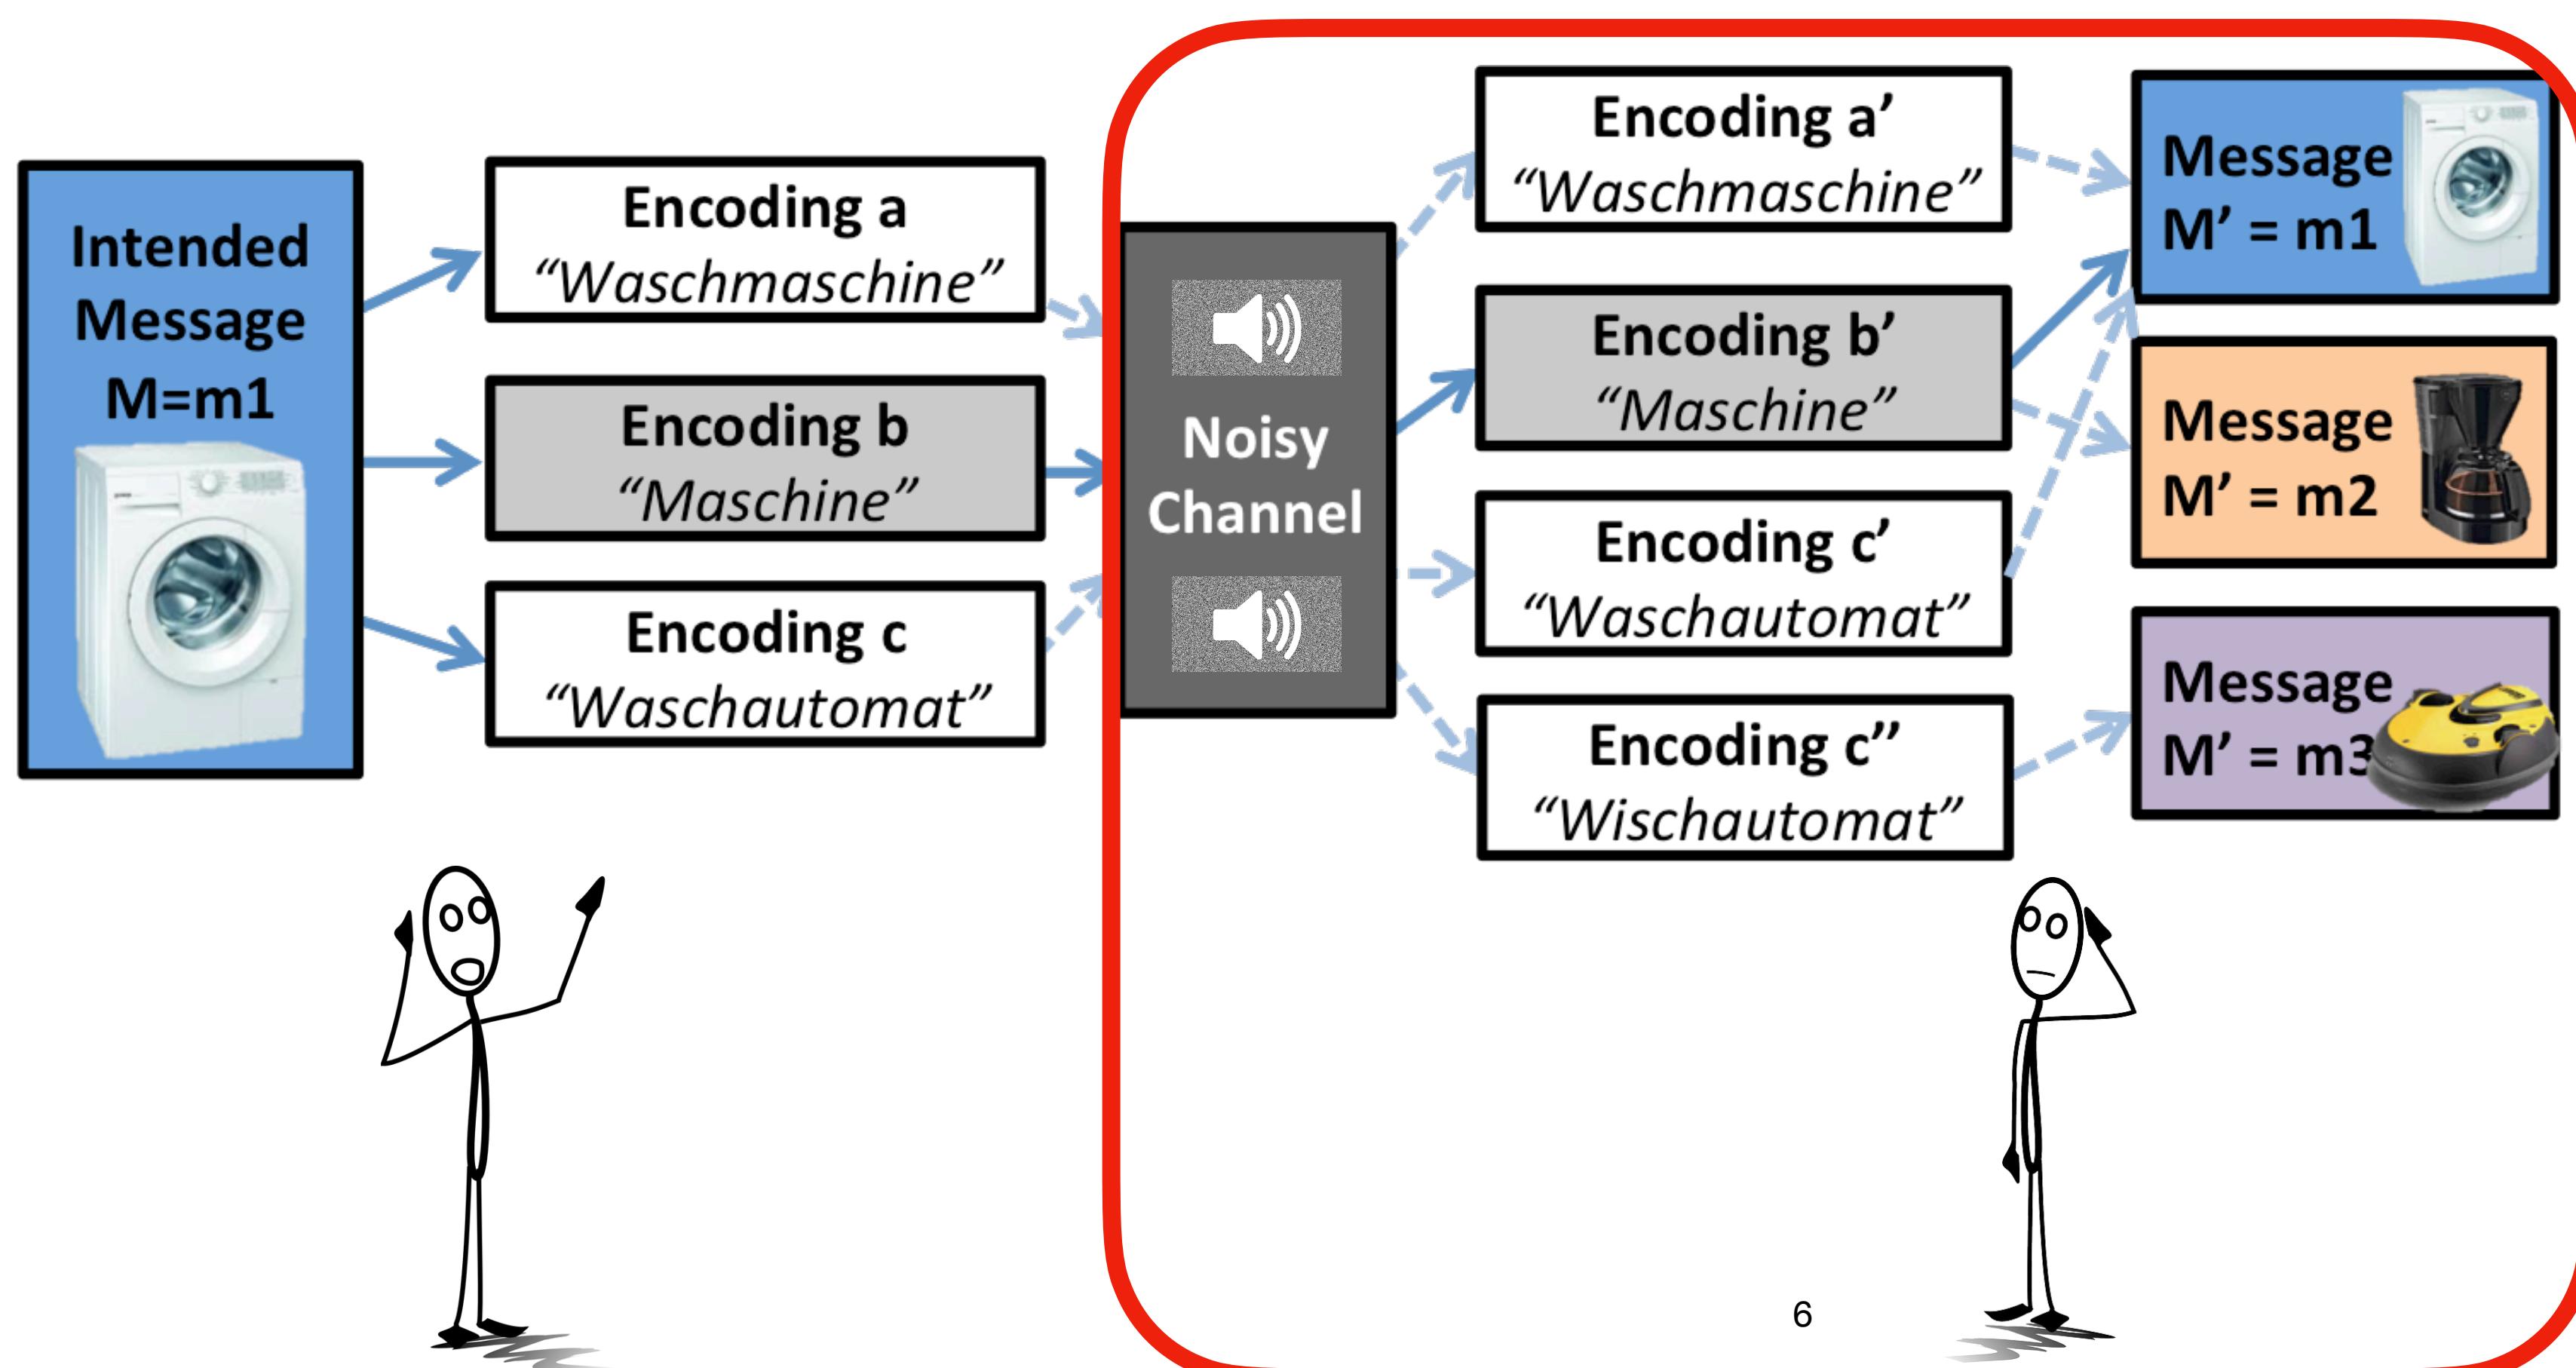
Q3 – Modellierung:

Das Noisy Channel model ist ein quantitatives Modell – für jedes Wort kann eine genaue Wahrscheinlichkeit der korrekten Übertragung berechnet werden.

Wie schätzen wir diese Wahrscheinlichkeiten am besten ab?

Verstehen

Q1 – Wie wird ein verrauschtes Signal vom Hörer interpretiert?



Model formalization:
understanding the meaning M' depends on the **(top-down) probability of M'** and the **(bottom-up) probability of the signal b'** given message M' :

$$P(M'|b') \sim P(b'|M') * P(M')$$

acoustic model
language model

Sprachmodell

Wie berechnet man die Wahrscheinlichkeit einer Nachricht?

- abhängige Wahrscheinlichkeit eines Worts gegeben den Kontext:

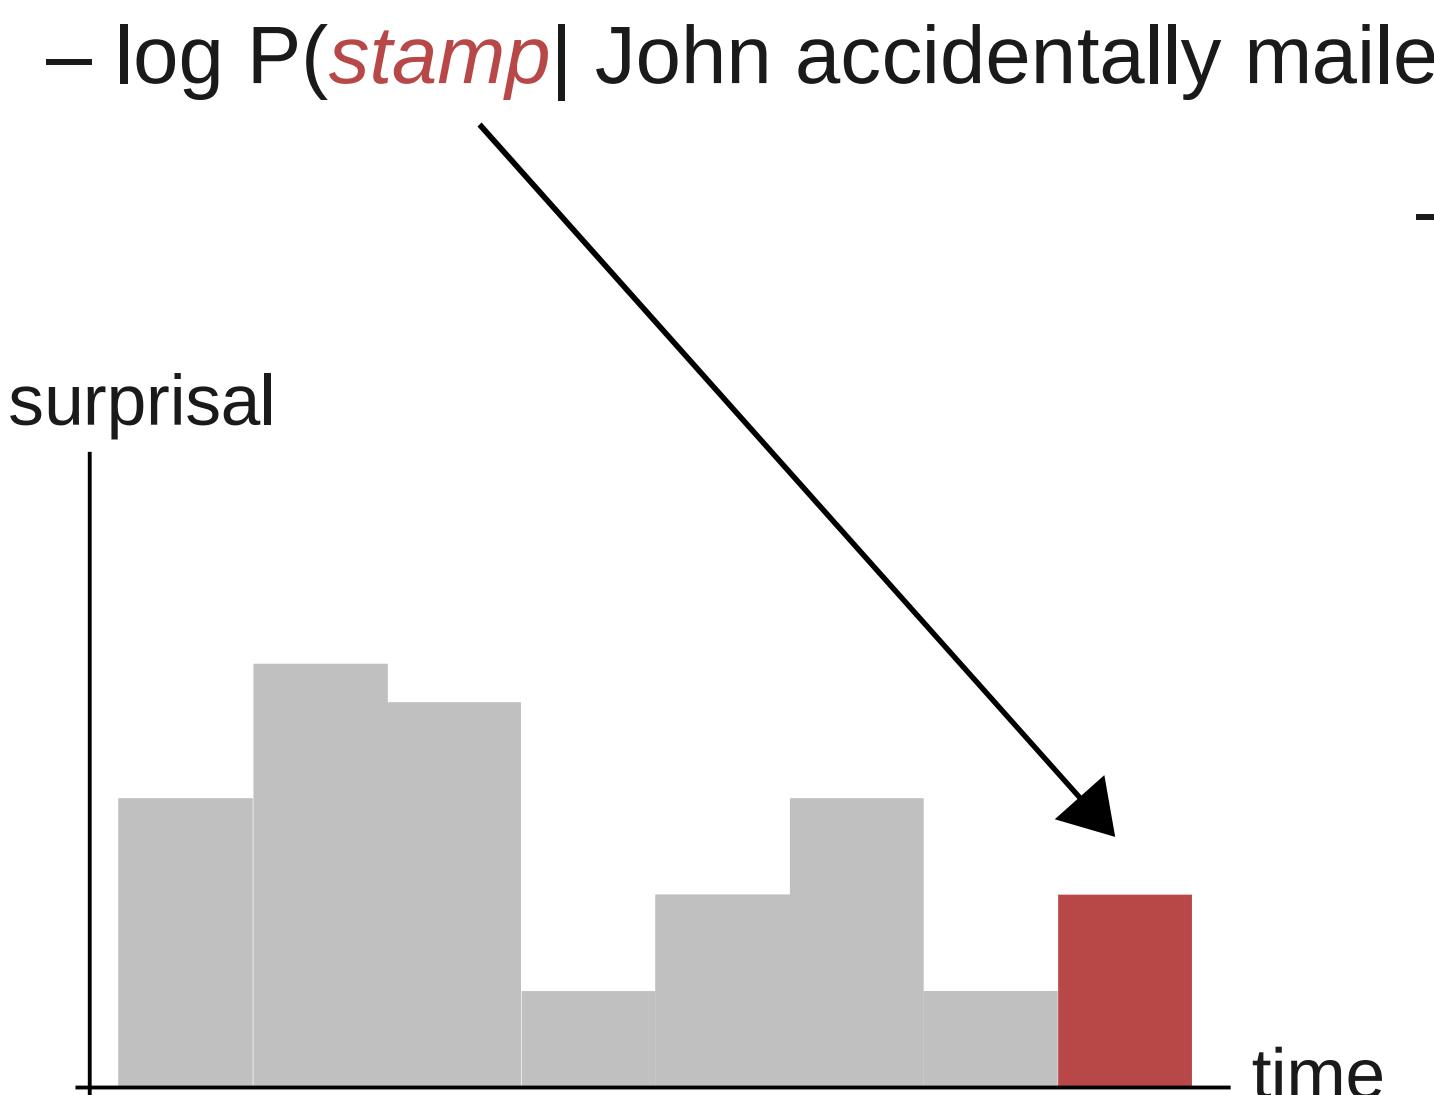
$P(\text{Waschmaschine} \mid \text{Wir haben so viel dreckige Wäsche. Gibt es hier eine})$

- wird typischerweise durch Befragung von Menschen (cloze probability) oder durch Abschätzung aus einem Sprachmodell erhoben.
- diese Wahrscheinlichkeit hat eine hohe Bedeutung in der Psycholinguistik:
Die negative log Wahrscheinlichkeit proportional ist zu messbaren Verarbeitungsschwierigkeit beim Sprachverstehen
(e.g., Hale, 2001; Levy 2008; Demberg & Keller, 2008)

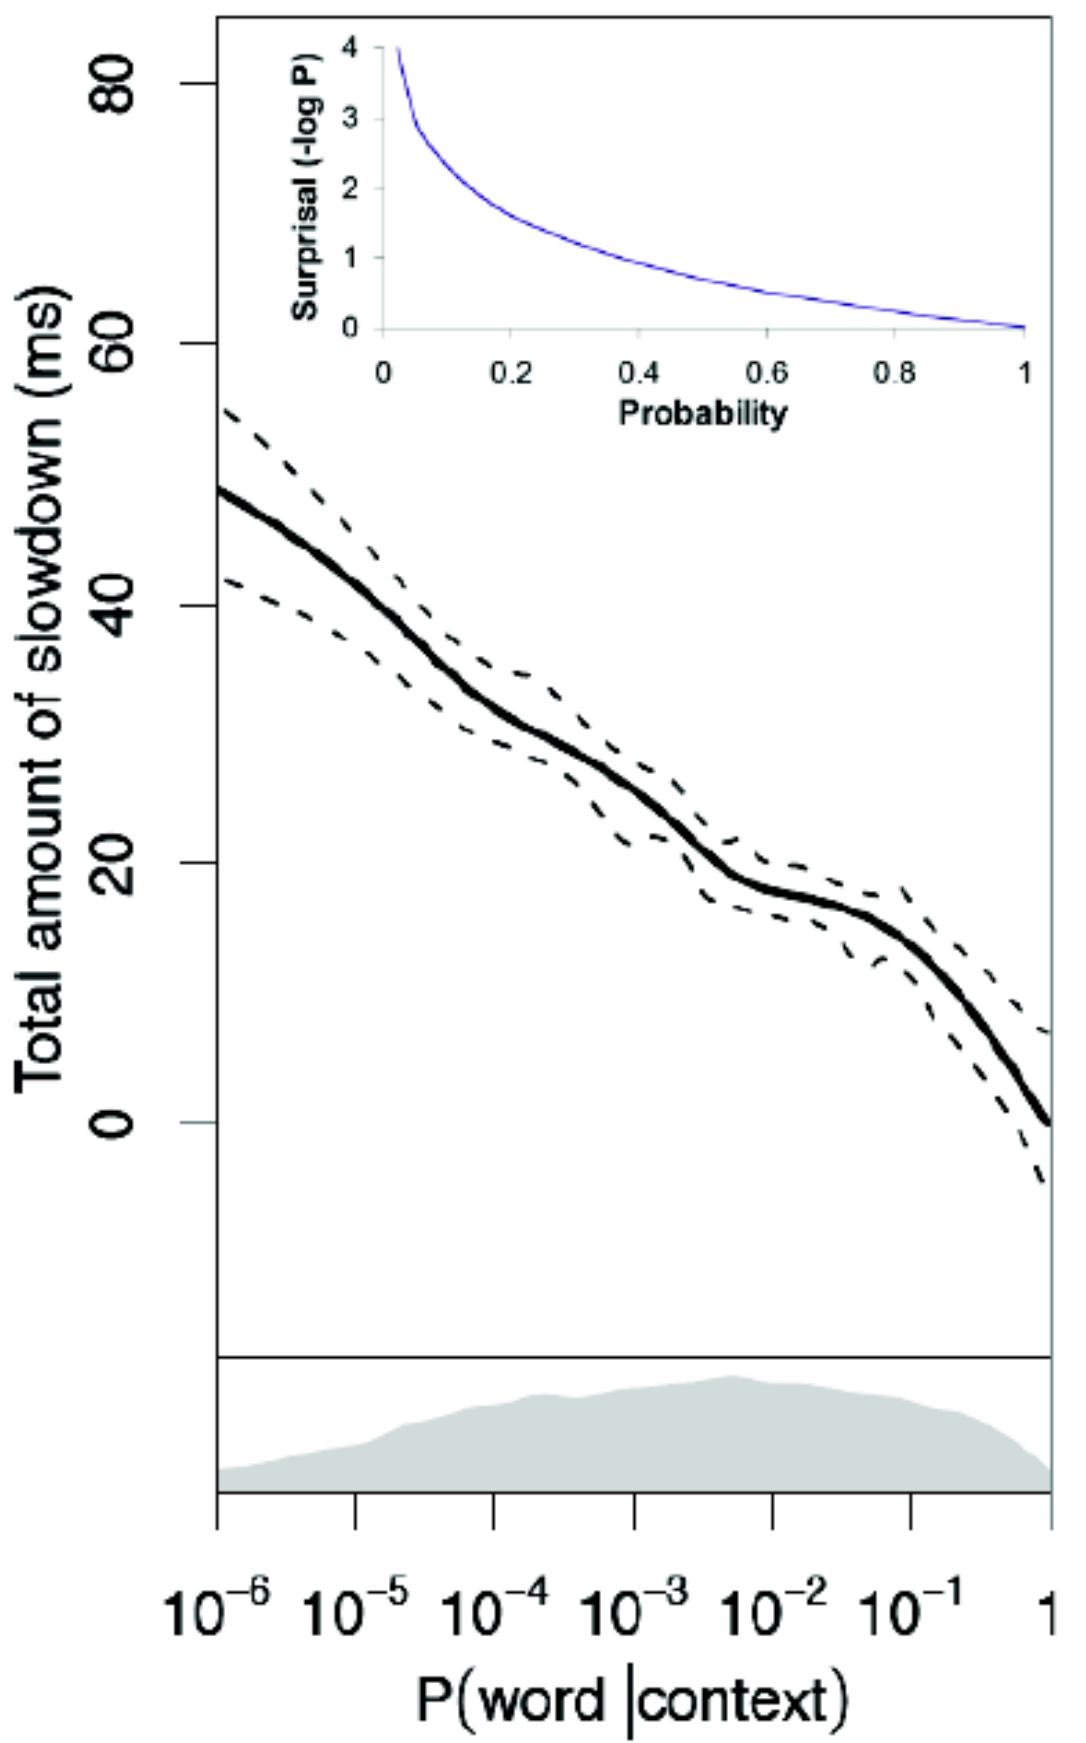
$$\text{surprisal (word)} = - \log P(w|\text{context})$$

Eye-tracking

Surprisal



$$\text{surprisal (word)} = -\log P(w|\text{context})$$

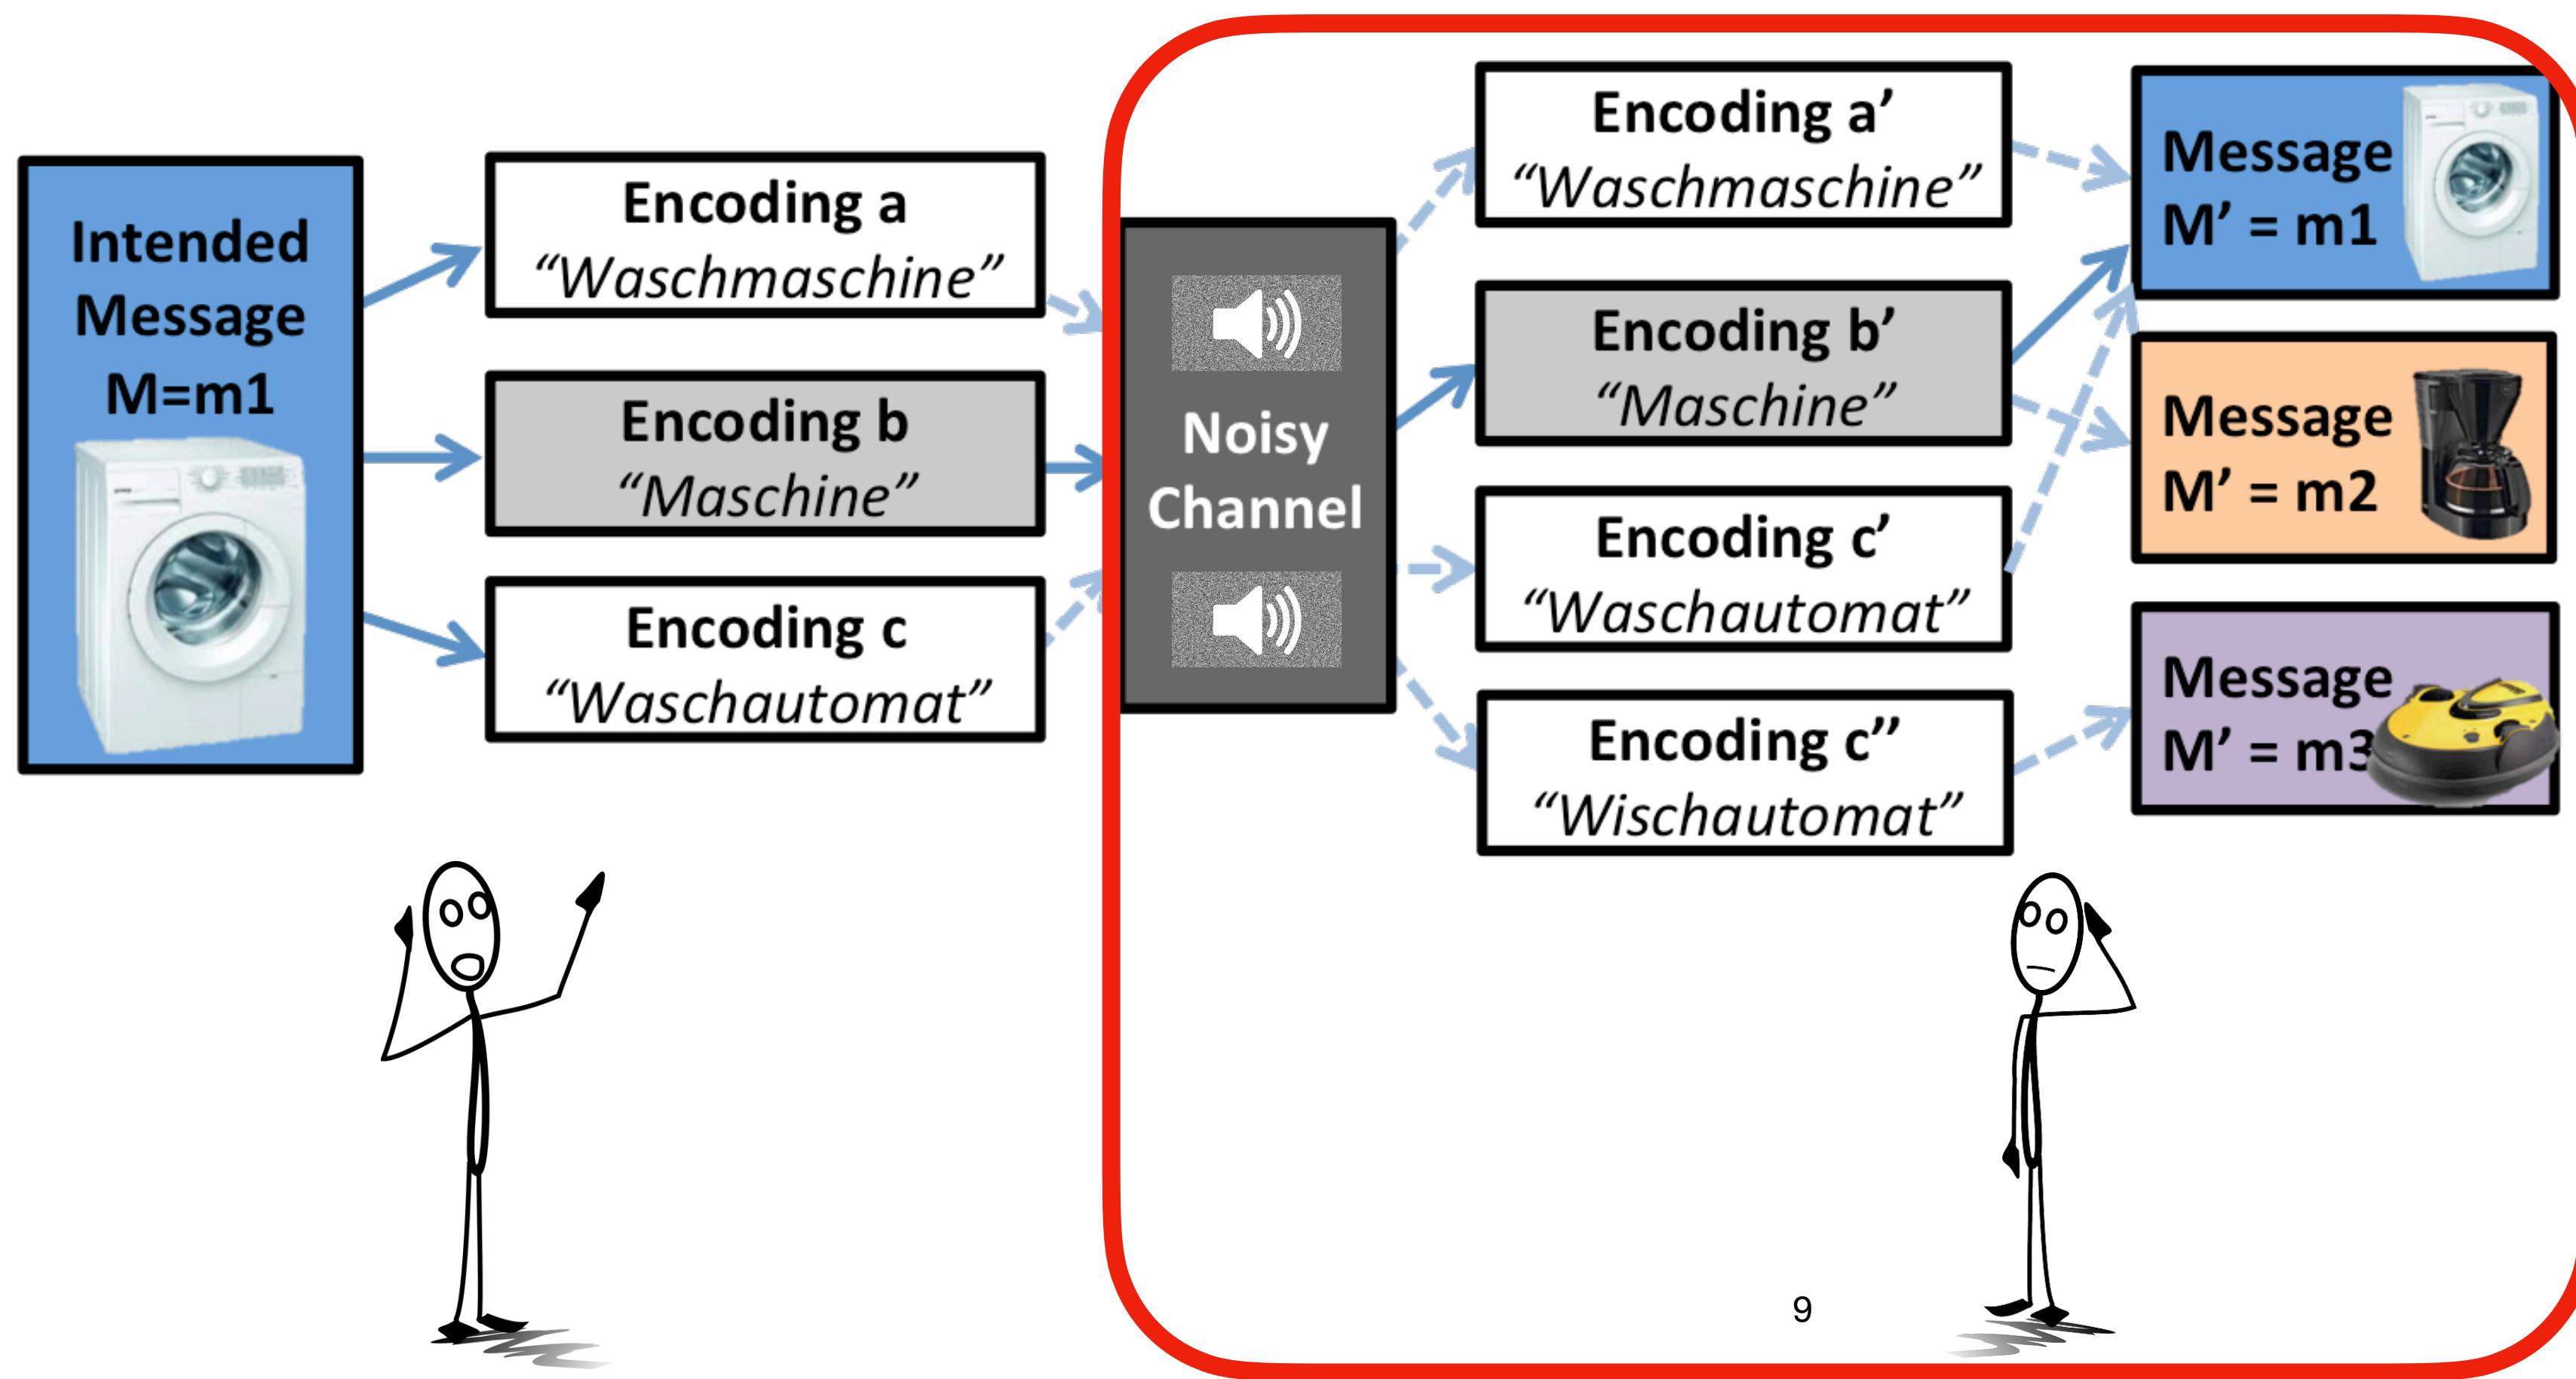


(from Smith & Levy 2013)

- Surprisal erlaubt uns die Information, die durch ein Wort übertragen wird, zu quantifizieren.
- Surprisal korreliert gut mit Lesezeiten oder ERP Amplituden.

Verstehen

Q1 – Wie wird ein verrauschtes Signal vom Hörer interpretiert?



Heute möchte ich aber auf die Kombination der Informationen aus dem Sprachmodell und dem akustischen Modell eingehen.

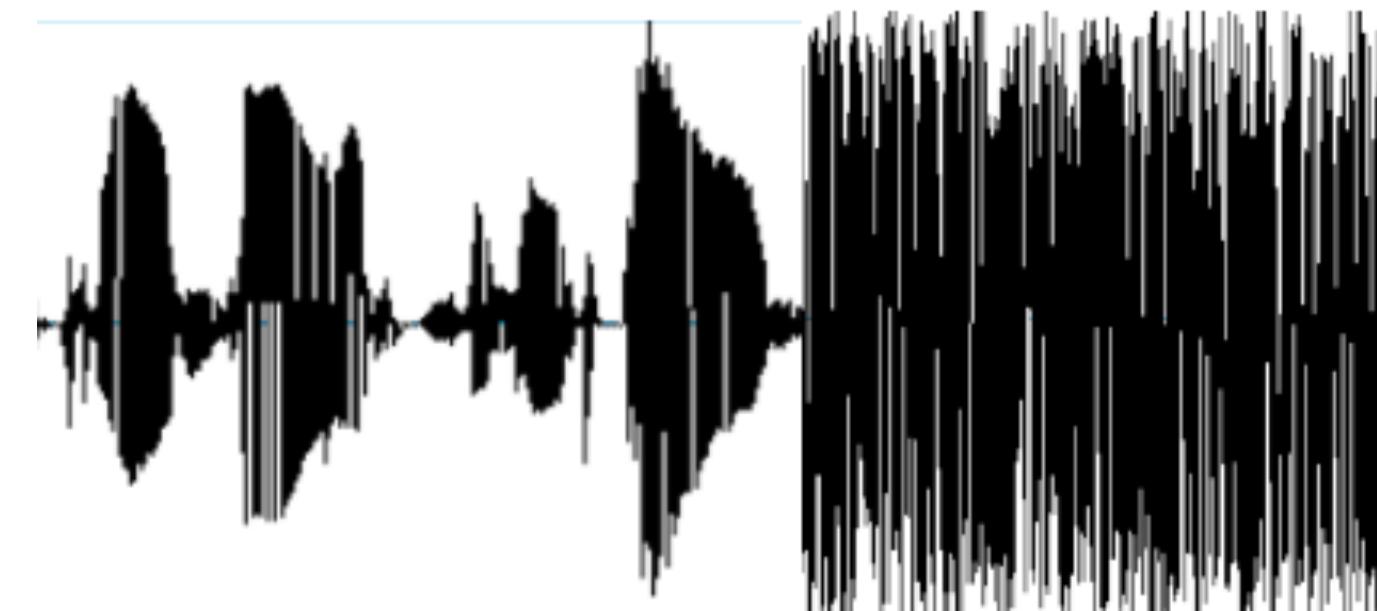
$$P(M'|b') \sim P(b'|M') * P(M')$$

acoustic model
language model

Verstehen gesprochener Sprache

- Rauschen kann das akustische Sprachsignal stören (Brungard, 2001; Cooke, 2009)

- Energetic masking:



- verschiedene Laute werden unterschiedlich stark durch verschiedene Rauschquellen (z.B. Postersession vs. Flugzeuggeräusch) beeinträchtigt.



Experimentelles Design

- Sprachverstehen mit / ohne Störgeräusch
 - **Babble** noise and **white** noise at -5 dB SNR
- kritische Minimalpaare von Wörtern, z.B. “Liebe” / “Liege”
 - **Vowel** pairs, **plosive** pairs, **fricative** pairs
- Einbettung in Sätze, die das kritische Wort erwartbar machen (low surprisal) vs. wo es überraschend ist (high surprisal)

Low surprisal: Nach vier Jahren heiratete Paul seine große Liebe.

High surprisal: Nach vier Jahren heiratete Paul seine große Liege.

counter-balancing:

Low surprisal: Am Hotelpool gab es nur noch eine freie Liege.

High surprisal: Am Hotelpool gab es nur noch eine freie Liebe.

} minimal pair

Analyse



High surprisal item: Am Hotelpool gab es nur noch eine freie Liebe.

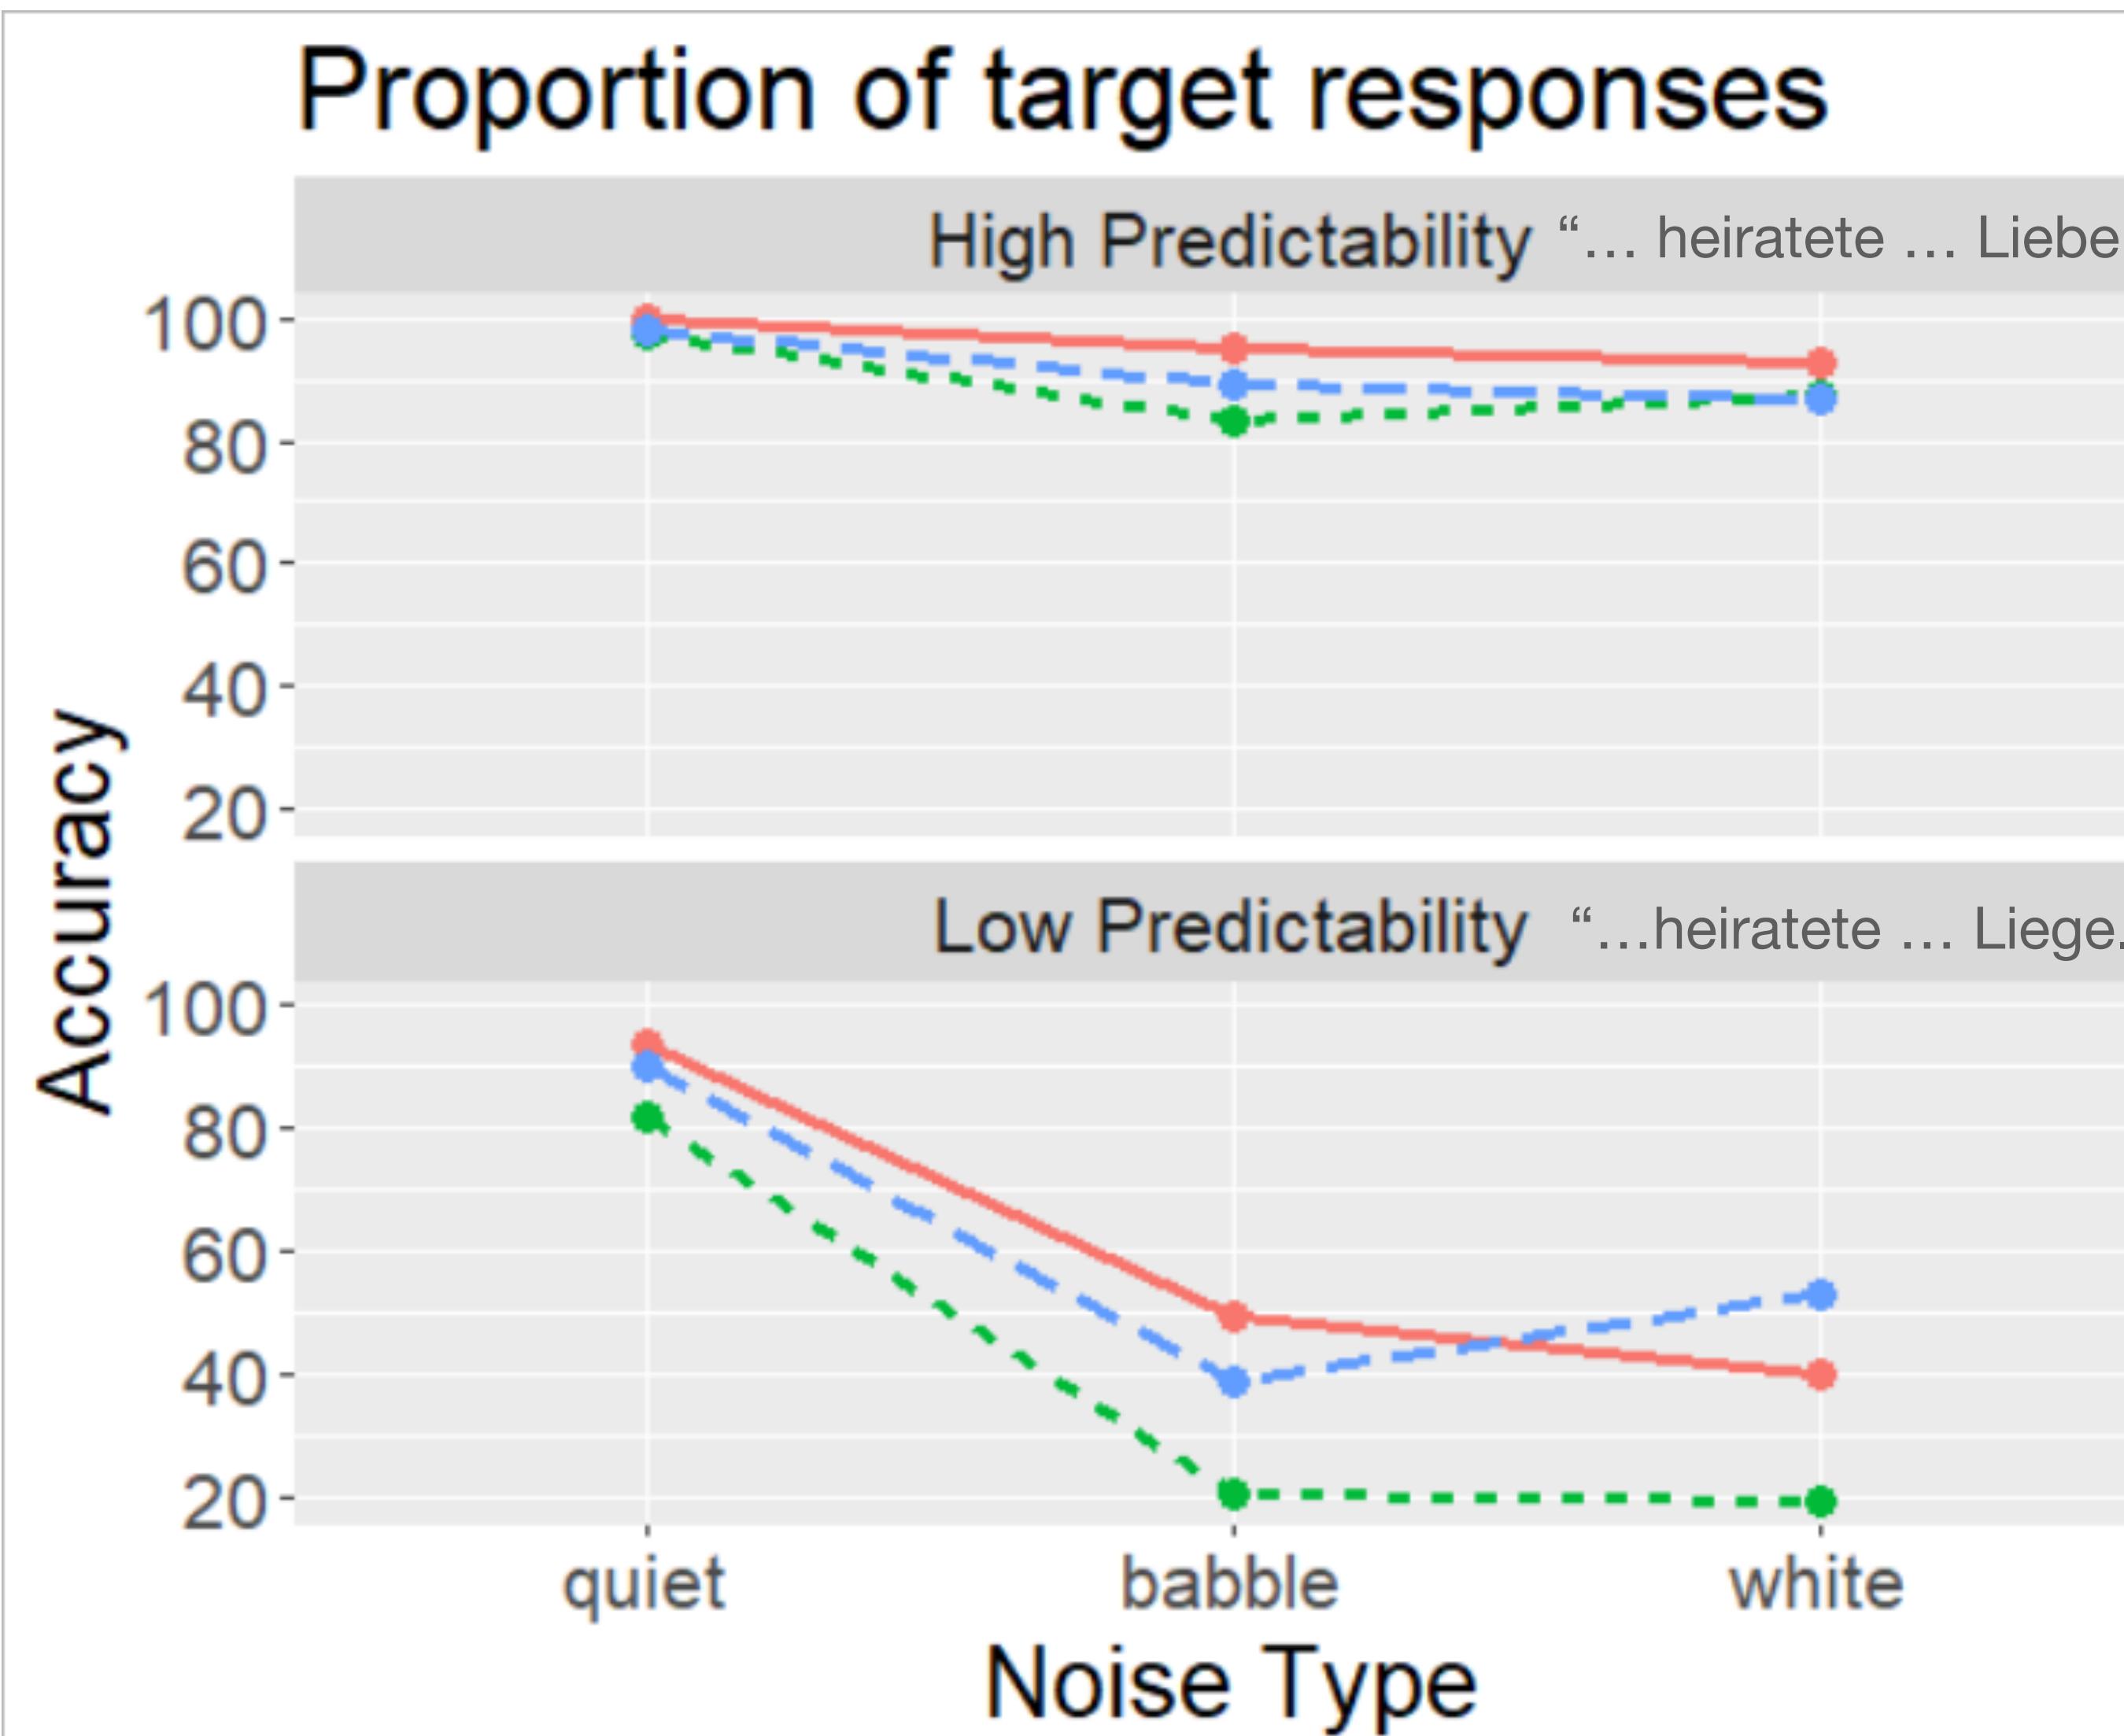
- Antworten wurden annotiert als:
 - **Target:** *Liebe*
 - **Distractor:** *Liege*
 - **Wrong:** *anything else*

(Analyse hier beschränkt sich auf Akkurateit in Bezug auf target.)

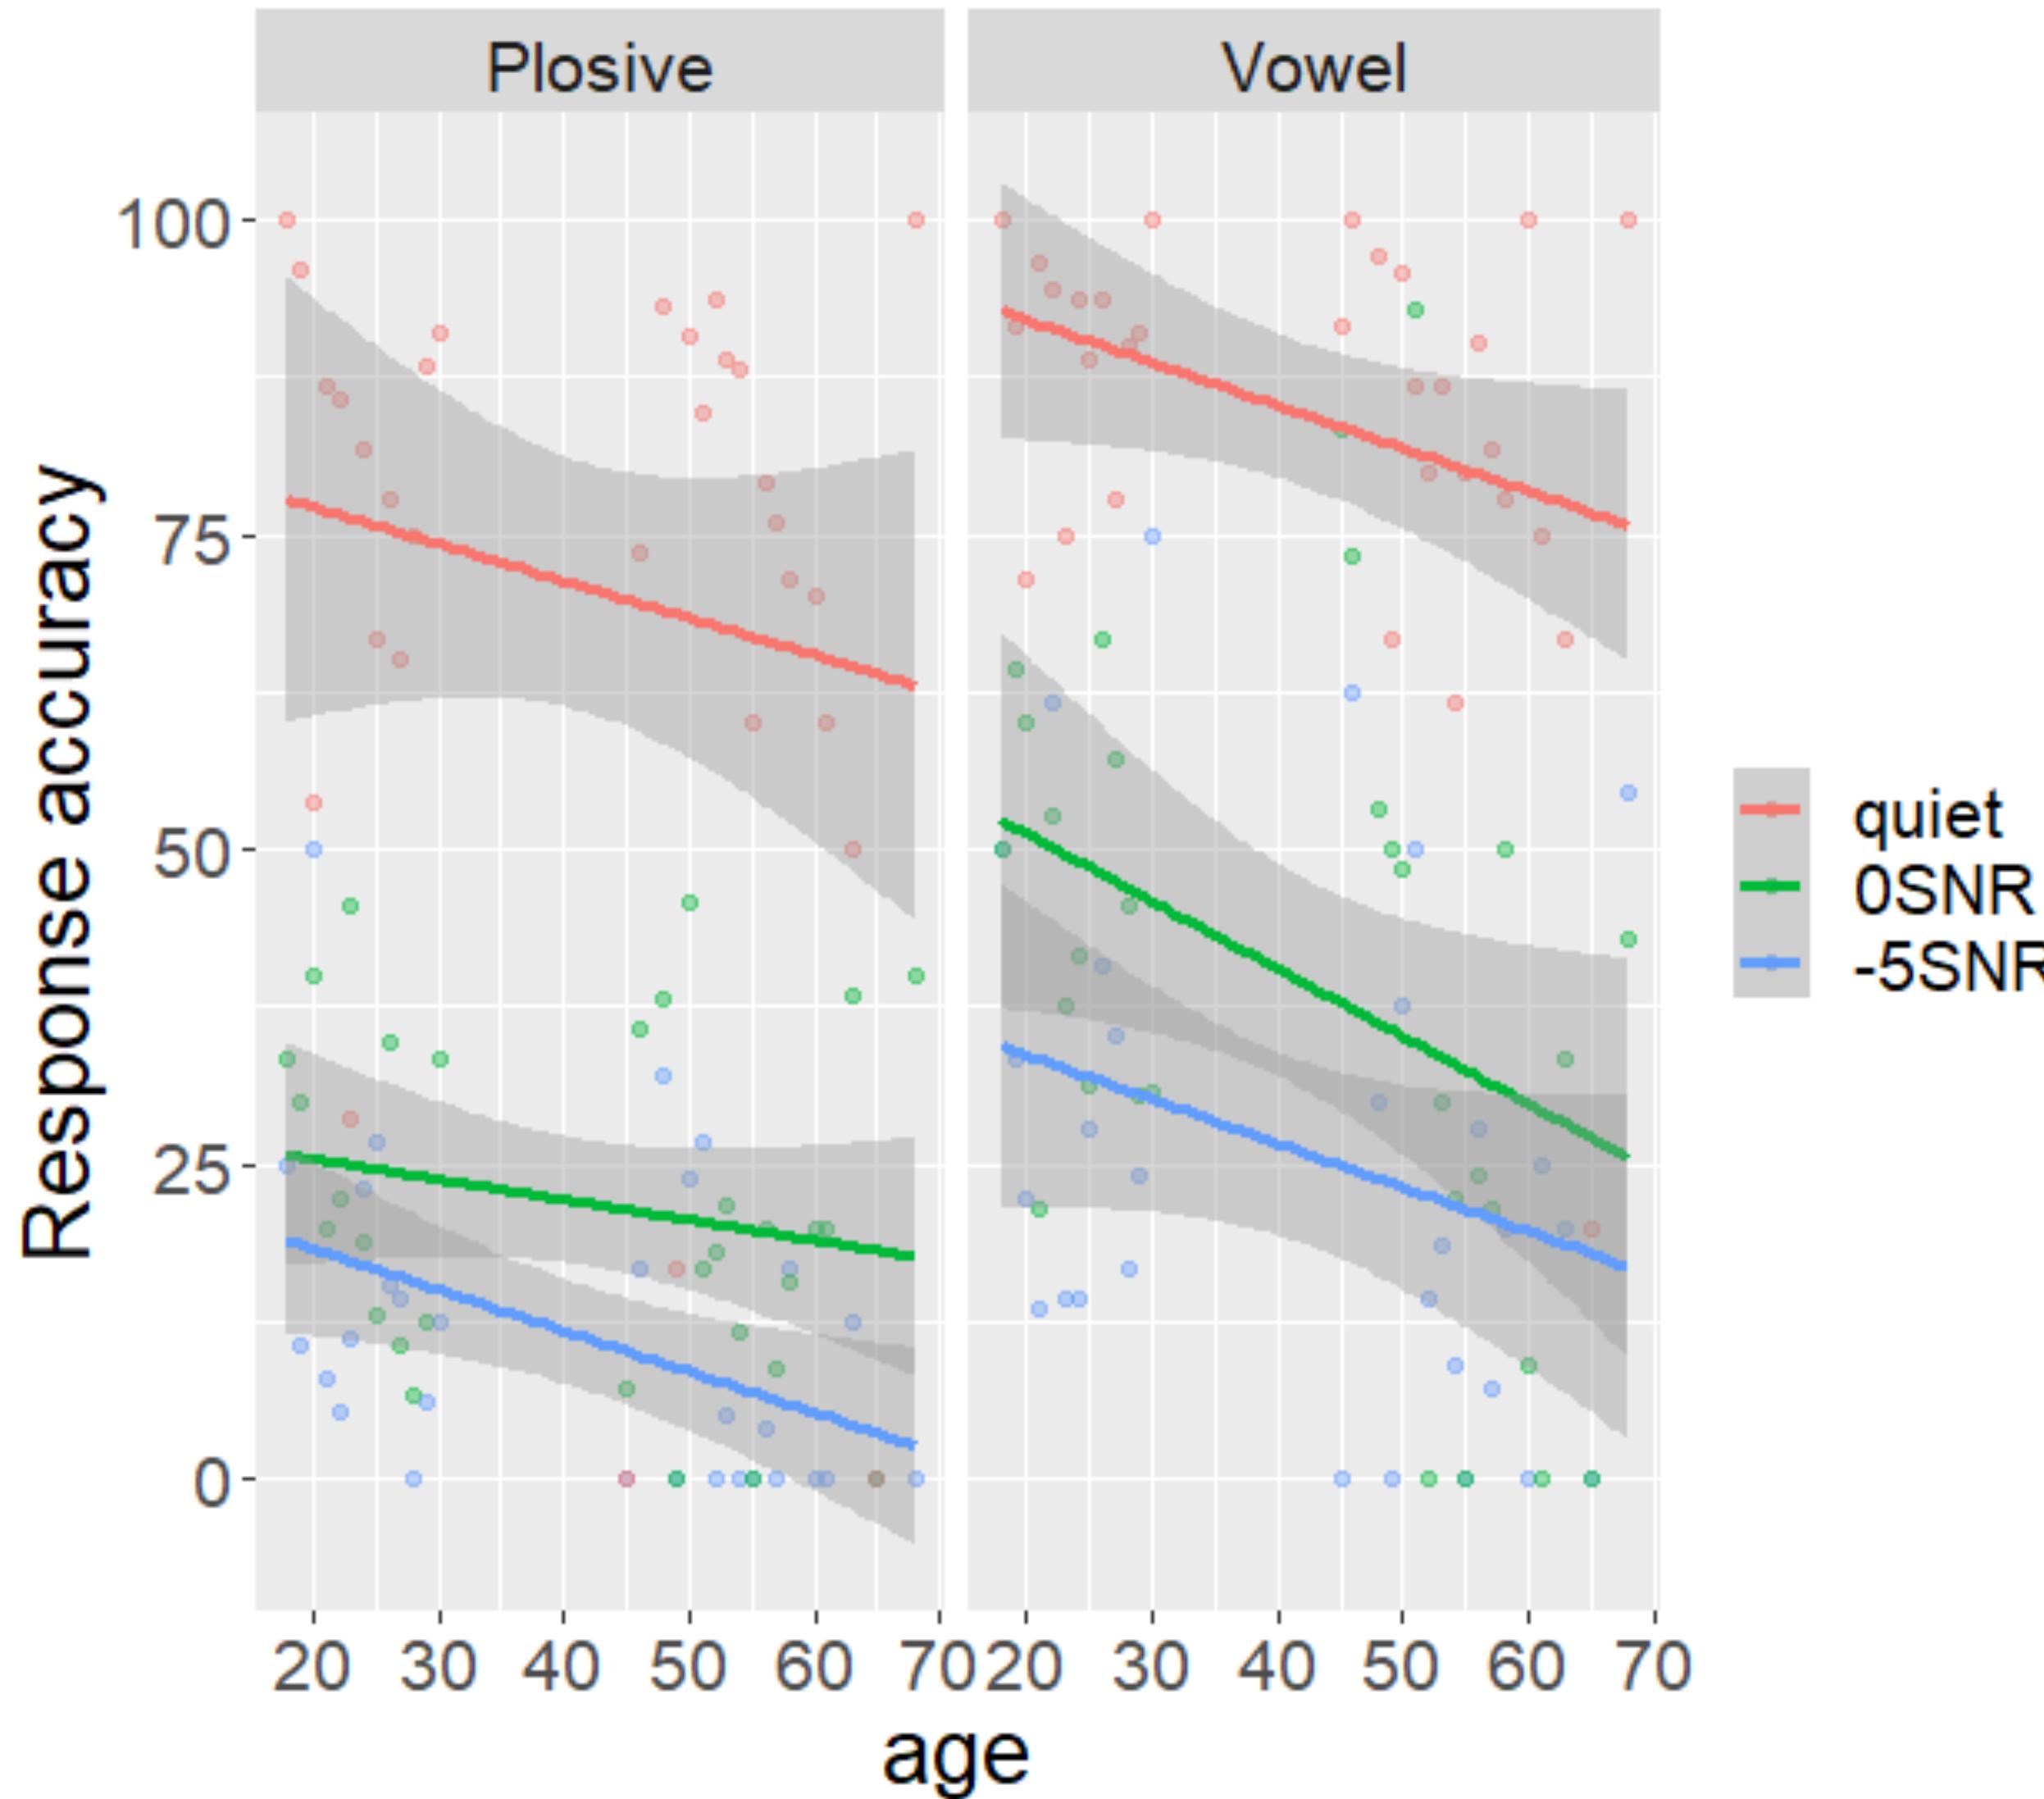
Ergebnisse



Ergebnisse



Ergebnisse (replication with wider age range)



- Im Alter verschlechtert sich das Hörvermögen. Daher ist das Sprachsignal für ältere Erwachsene weniger "verlässlich".
- konsistente Ergebnisse: Plosive sind schwieriger als Vokale.
- **Ältere Erwachsene** geben häufiger an, das Wort, das inhaltlich passt, aber nicht im Signal vorhanden war, gehört zu haben.
=> konsistent mit noisy channel model



Zusammenfassung Sprachverstehen

- Ergebnisse sind konsistent mit Noisy Channel Model:
 - das Rauschen beeinflusst, wie sehr sich Hörer auf das Signal verlassen.
 - Alter (Hörvermögen) beeinflusst, wie sehr sich Hörer auf das Signal verlassen
- Trade-off zwischen Kontexterwartung und Signal als rationale Kombination der beiden Wahrscheinlichkeiten.

praktische Anwendbarkeit

- Dialogsysteme könnten in lauten Umgebungen ihre Formulierungen so wählen, dass die Nachricht trotz Rauschen leichter verstanden werden kann.
- z.B. durch Wahl von Synonym oder alternativer syntaktischer Formulierung.

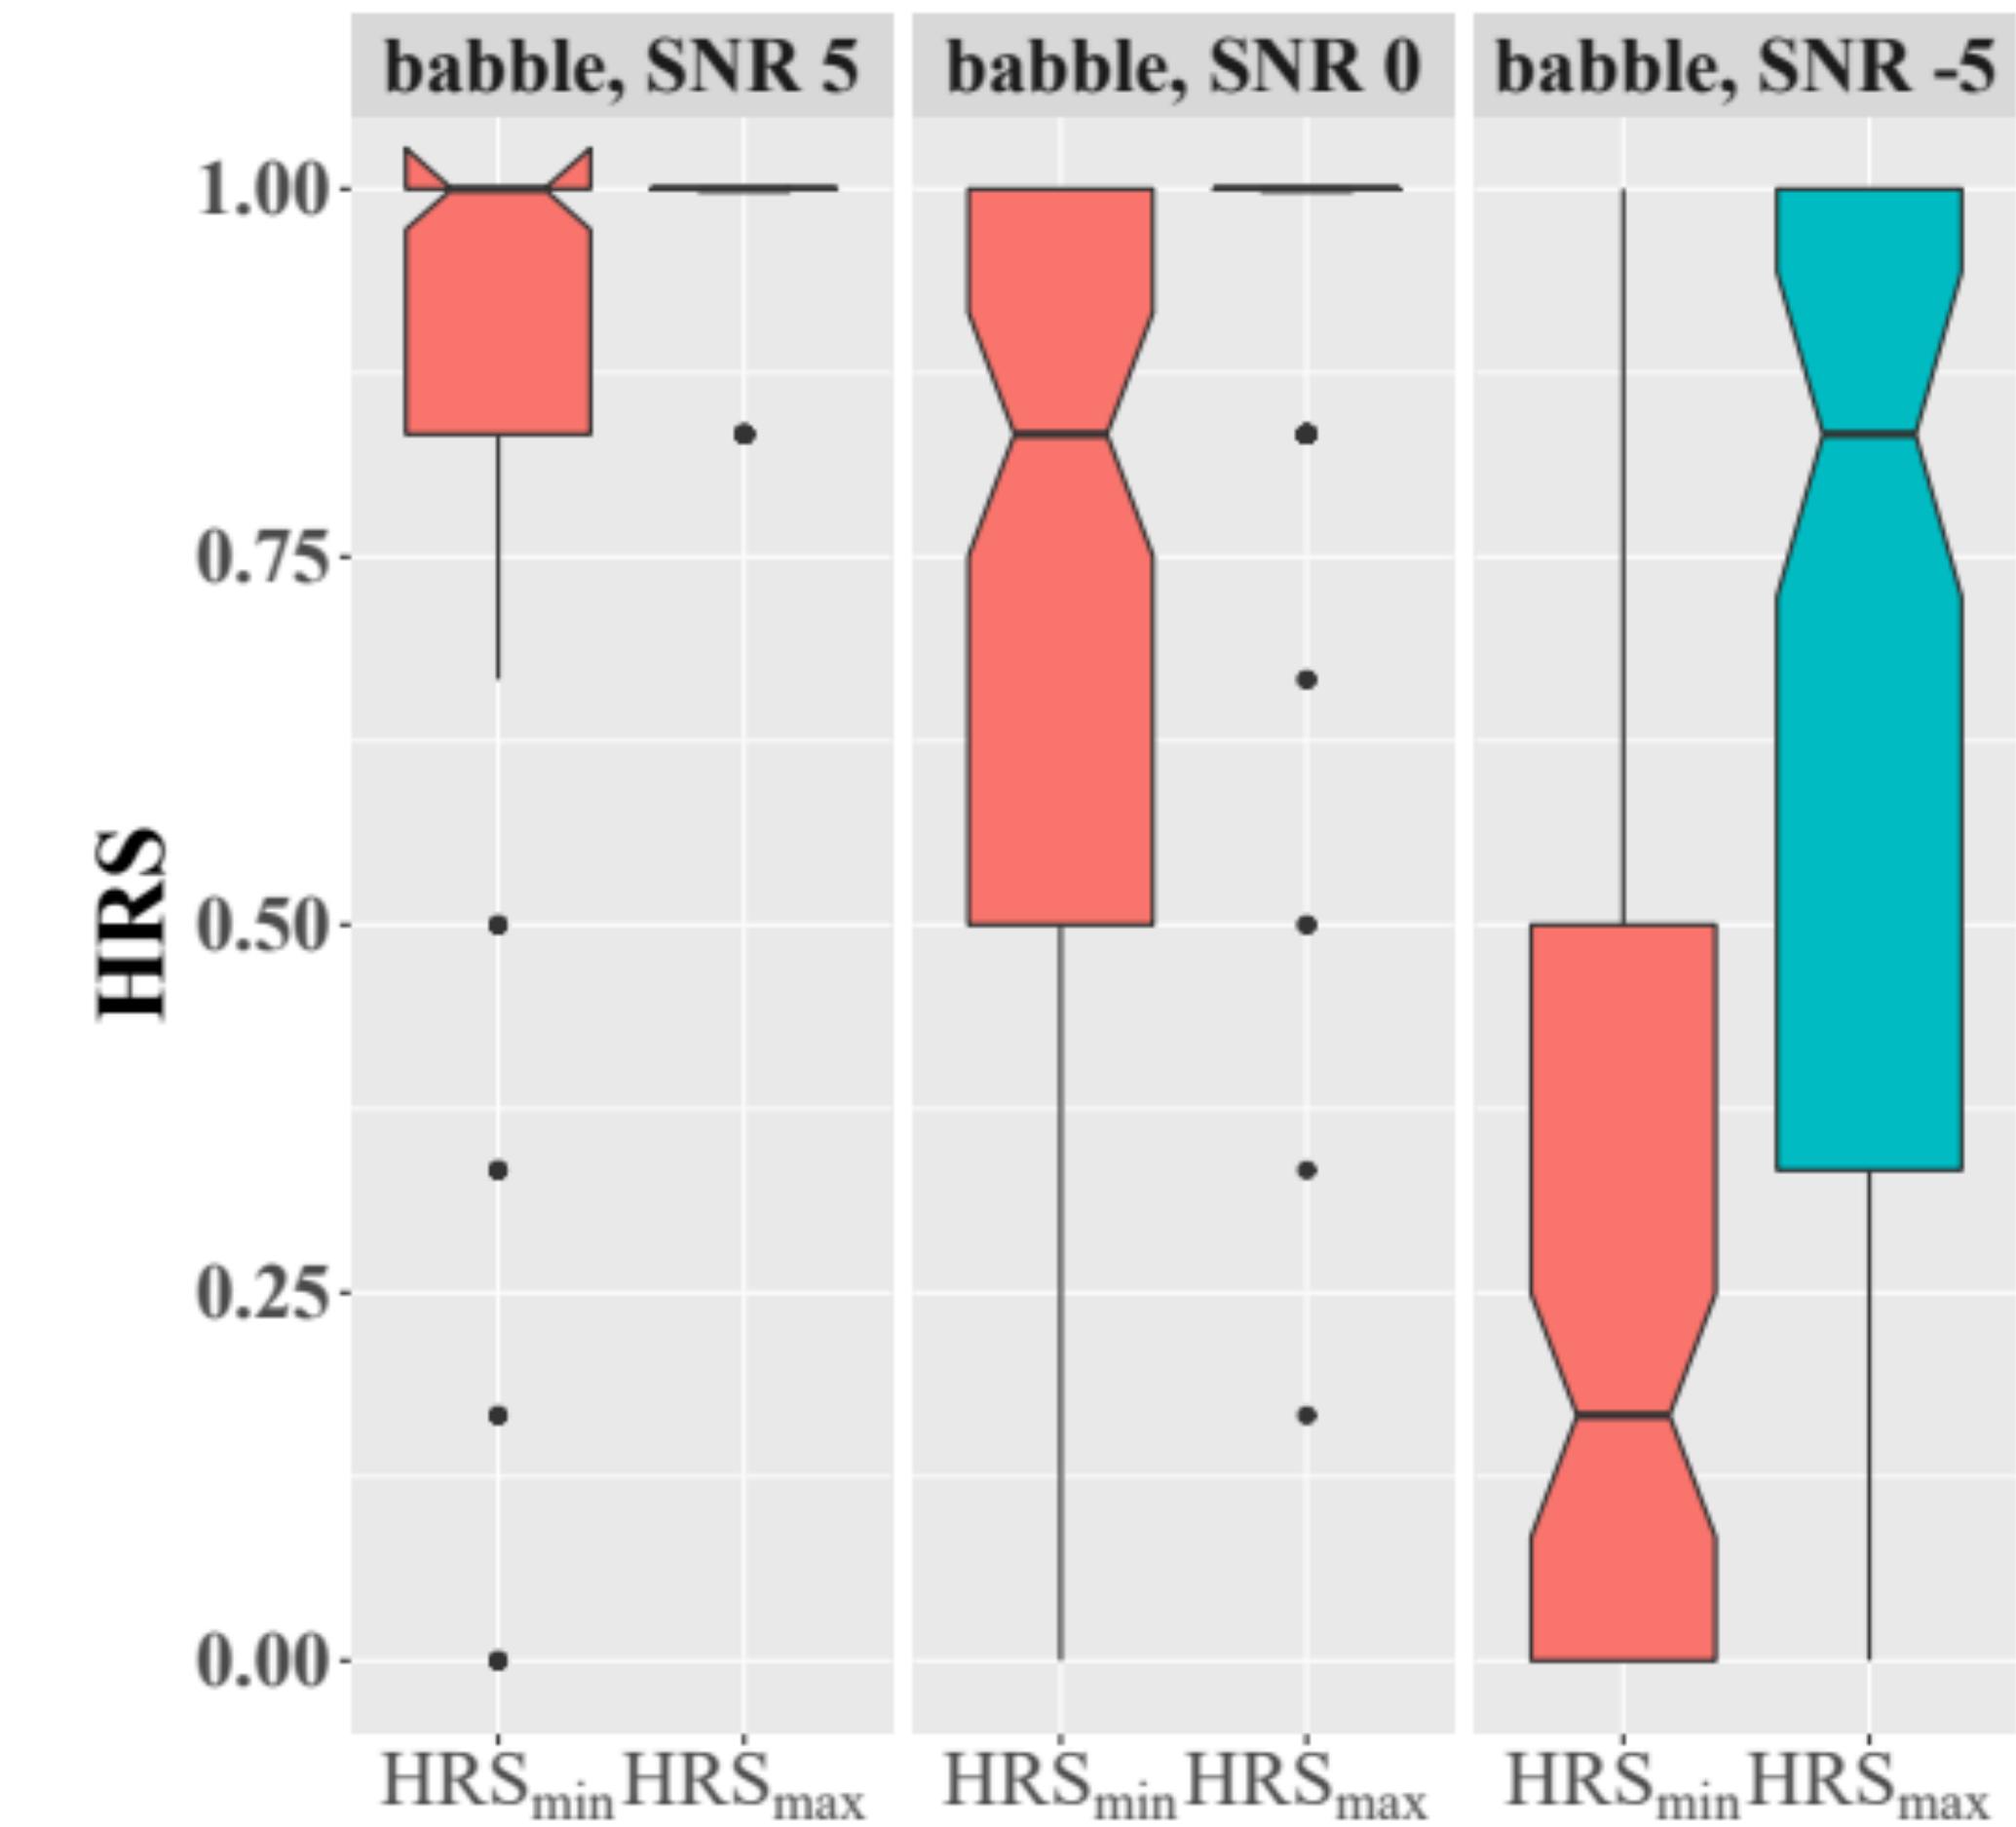


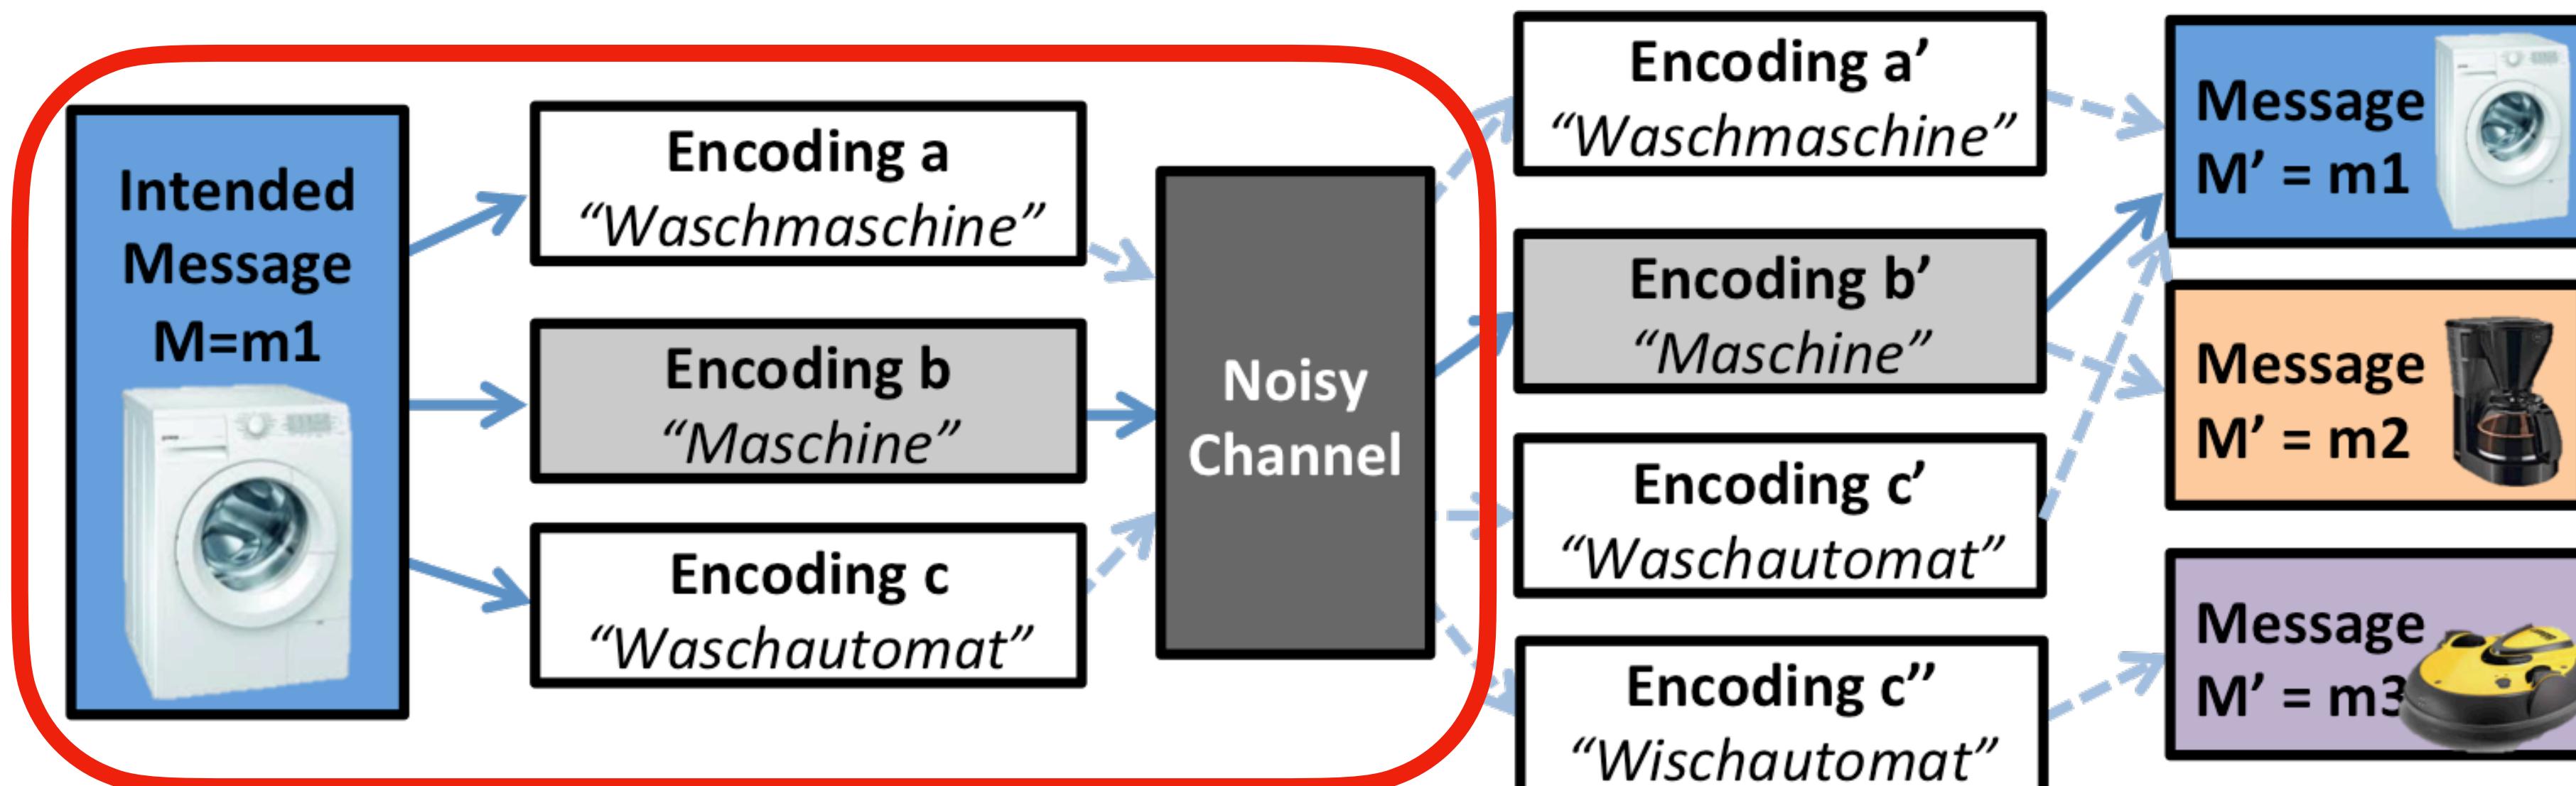
Figure 2: *Distinction between less intelligible and more intelligible synonyms, when they were presented with context under different listening environments.*

Chingacham, Demberg and Klakow, 2021
Interspeech best paper award



Sprachproduktion

optimale Auswahl der Formulierung



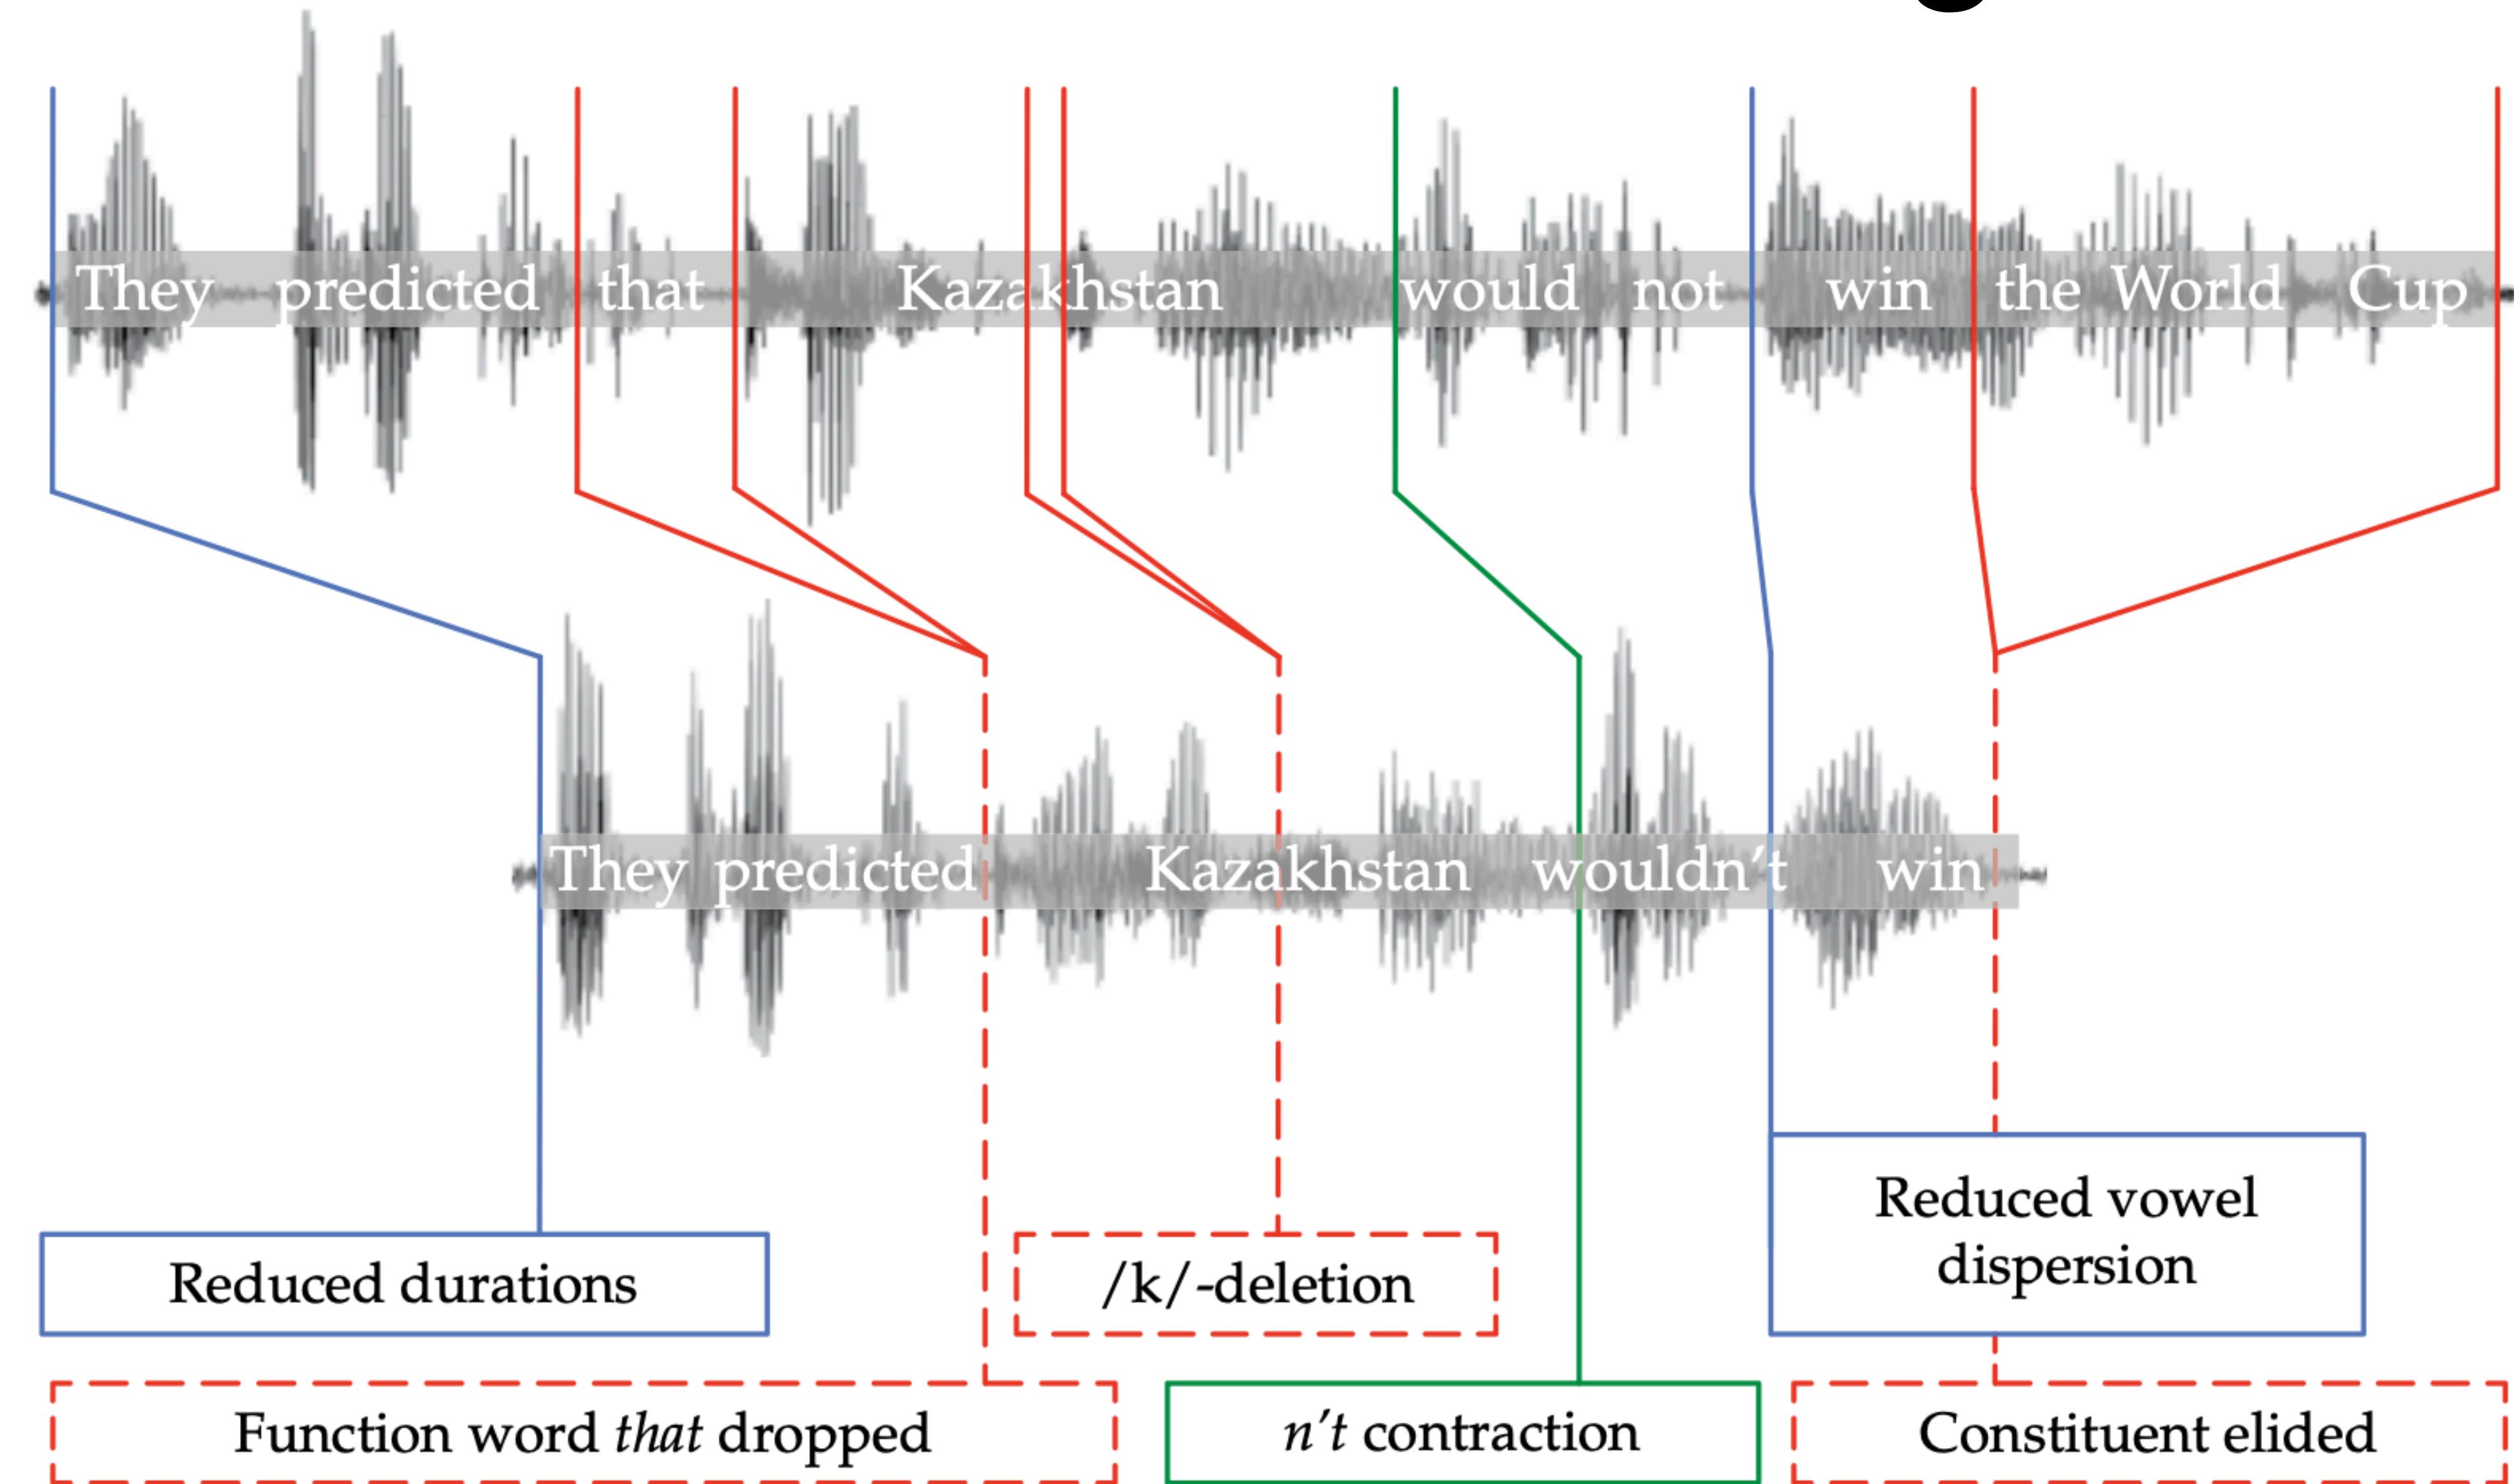
Konstanz im sprachlichen Informationsfluss (Fenk & Fenk-Oczlon, 1980)

Smooth signal redundancy hypothesis (Aylett and Turk, 2004)

Uniform information density hypothesis (Frank and Jaeger, 2008)

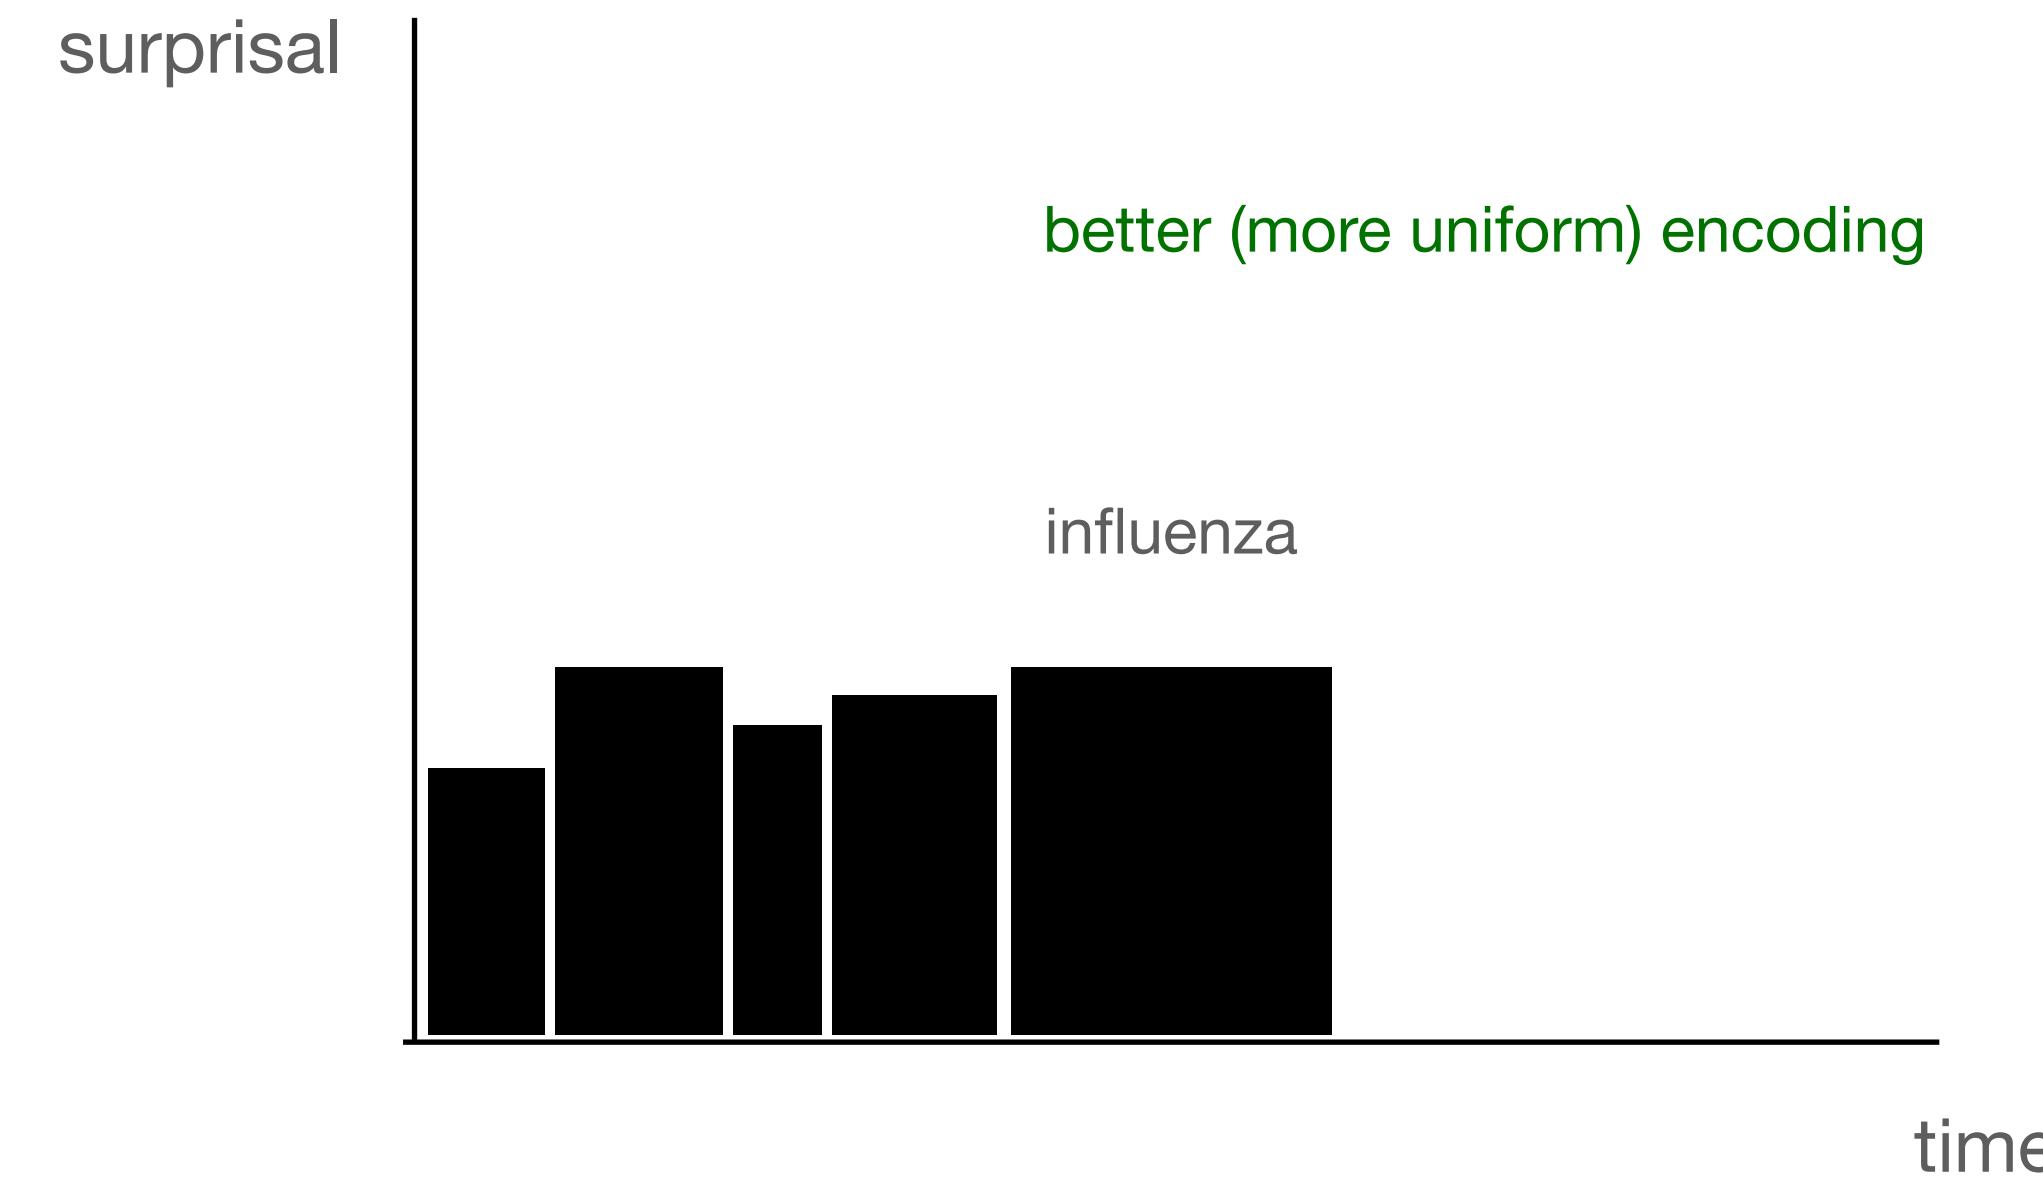
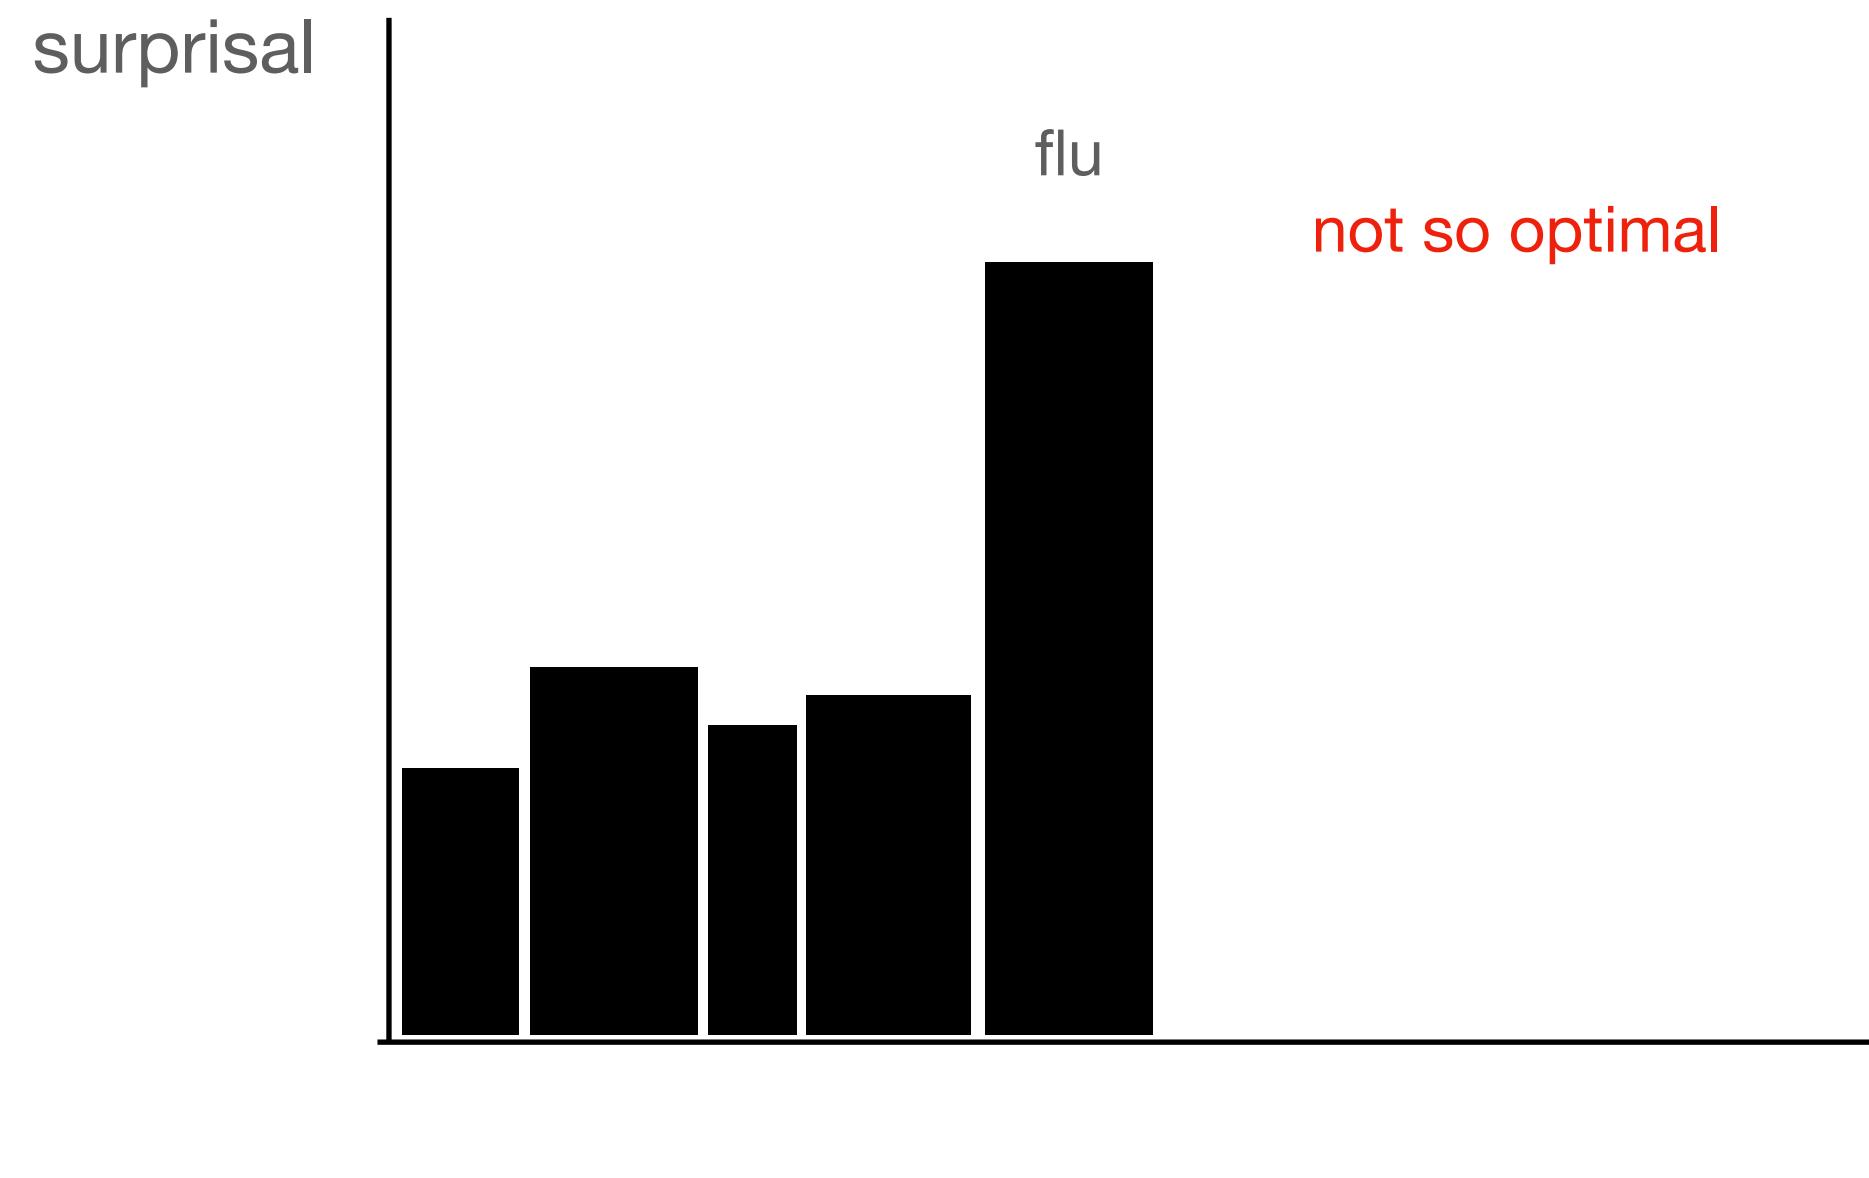
Expectancy hypothesis (Arnold 2001)

Sprecher haben viele Wahlmöglichkeiten



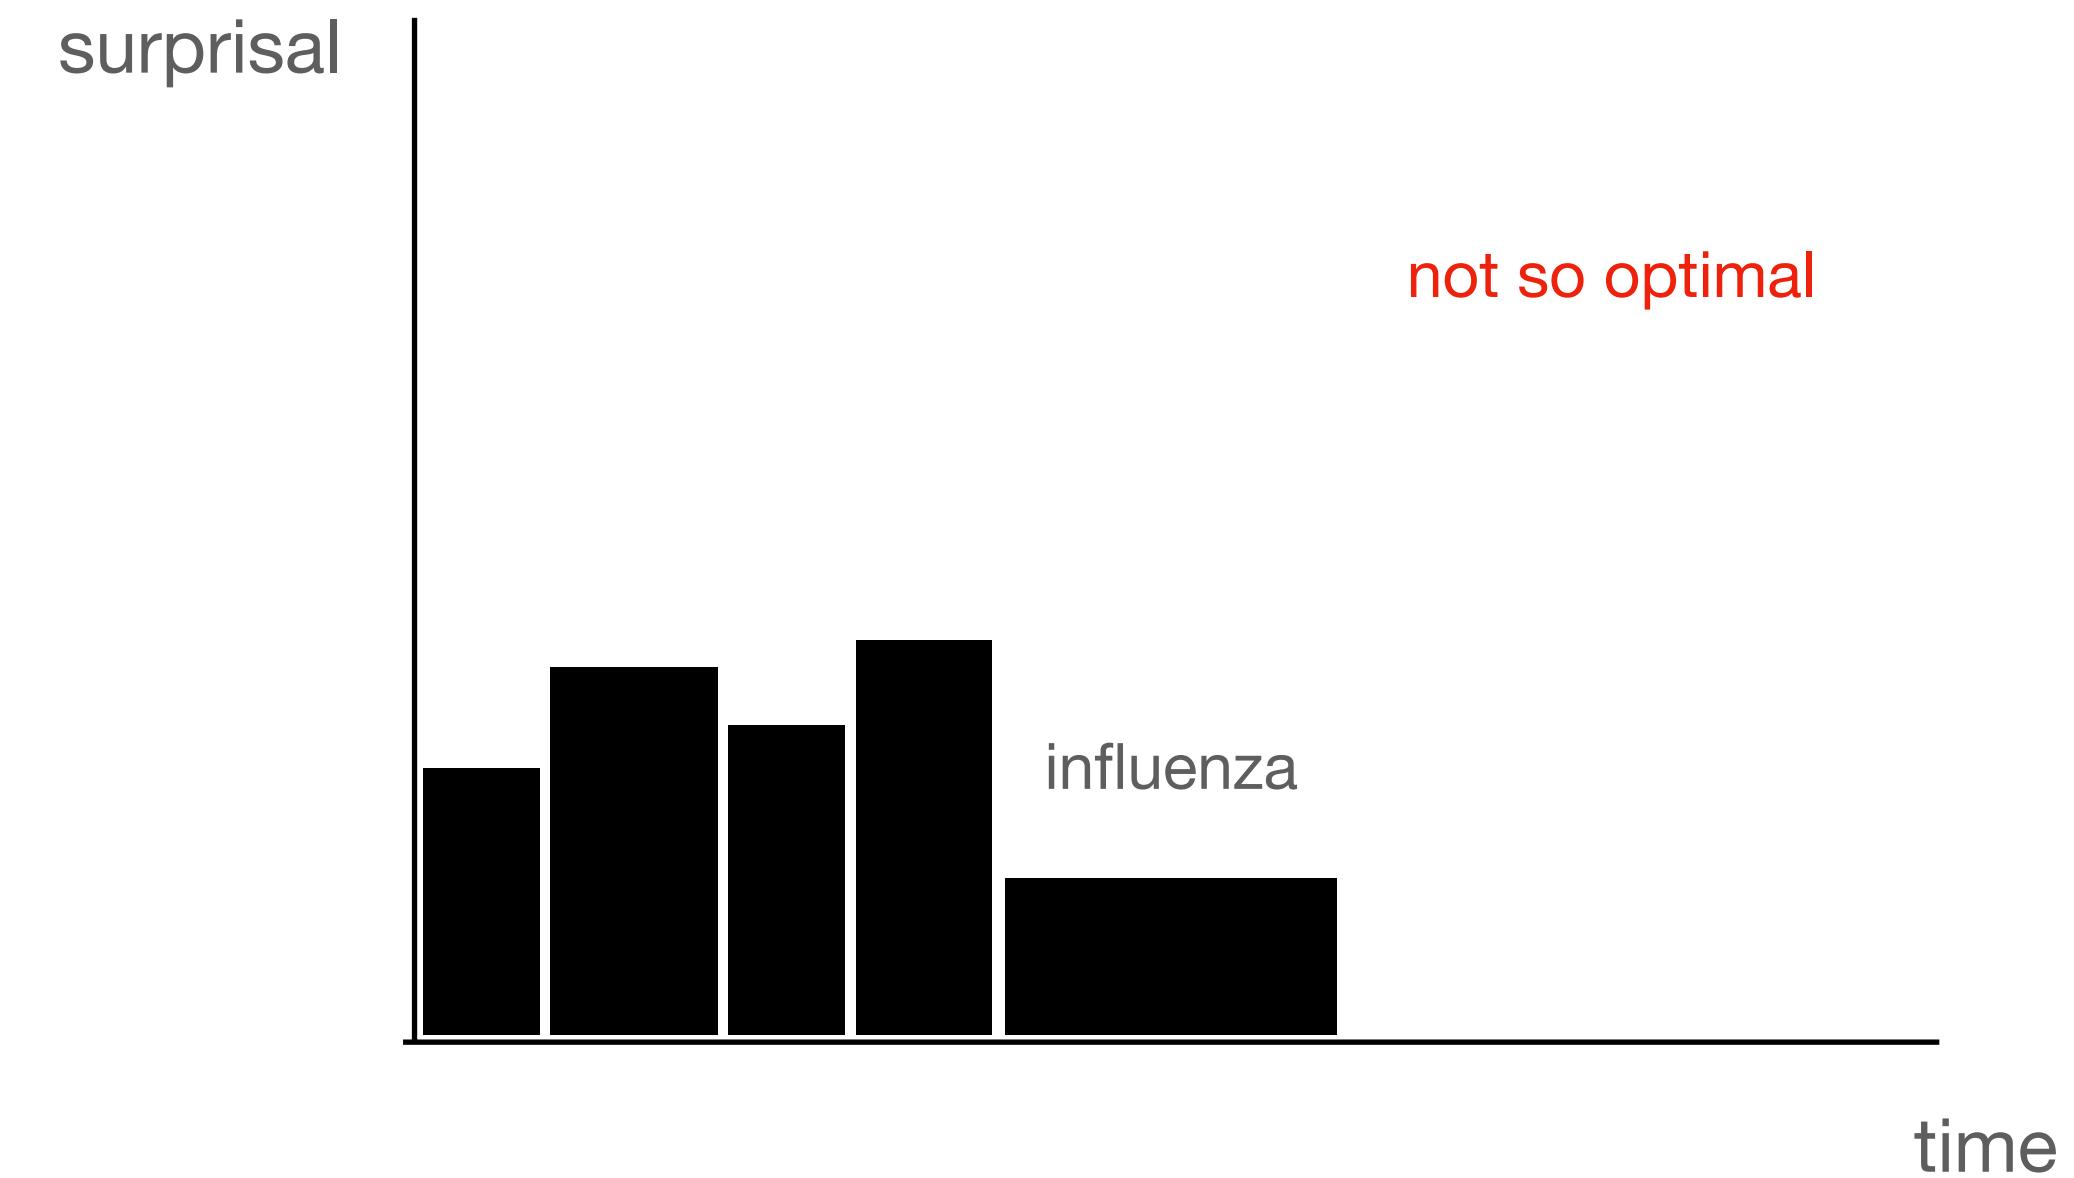
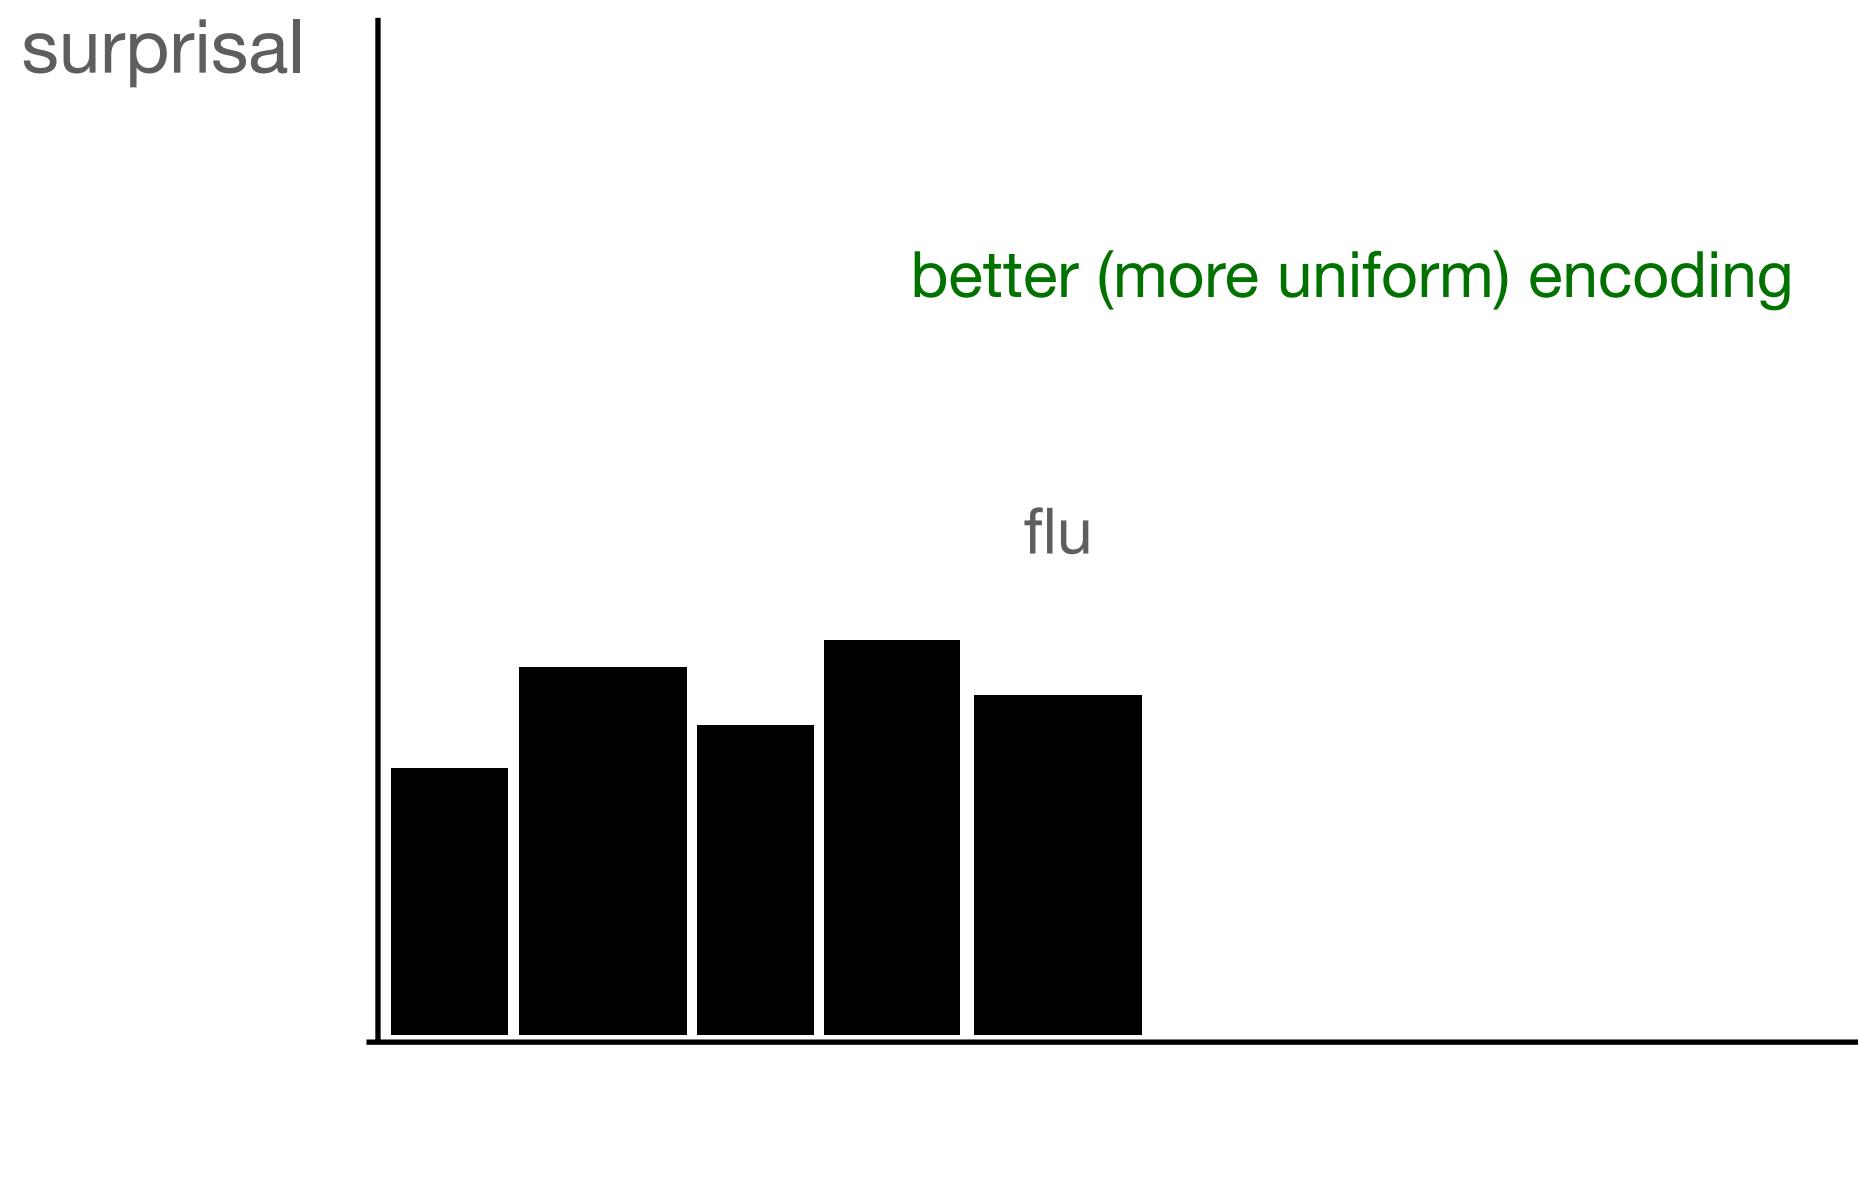
Wie kann Informationstheorie helfen, Wortwahl zu erklären?

- Hängt Wortwahl vom Informationsgehalt (surprisal) ab?
- Beispiel: wenn ich “Grippe” ausdrücken möchte, Wahl: “flu” / “influenza”



Wie kann Informationstheorie helfen, Wortwahl zu erklären?

- In einem anderen Kontext könnte “Grippe” sehr erwartbar sein.
- Optimale Wahl zwischen “flu” und “influenza” geht hier anders aus.



Empirische Überprüfung der Hypothese

- Nutzen Sprecher **längere Worte** für Bedeutungen, die **nicht vorhersagbar** sind, und **kürzere Worte** für **vorhersagbare** Bedeutungen?
- Methodologische Herausforderungen: Wortbedeutung konstant halten.

Mahowald et al. study (2013)

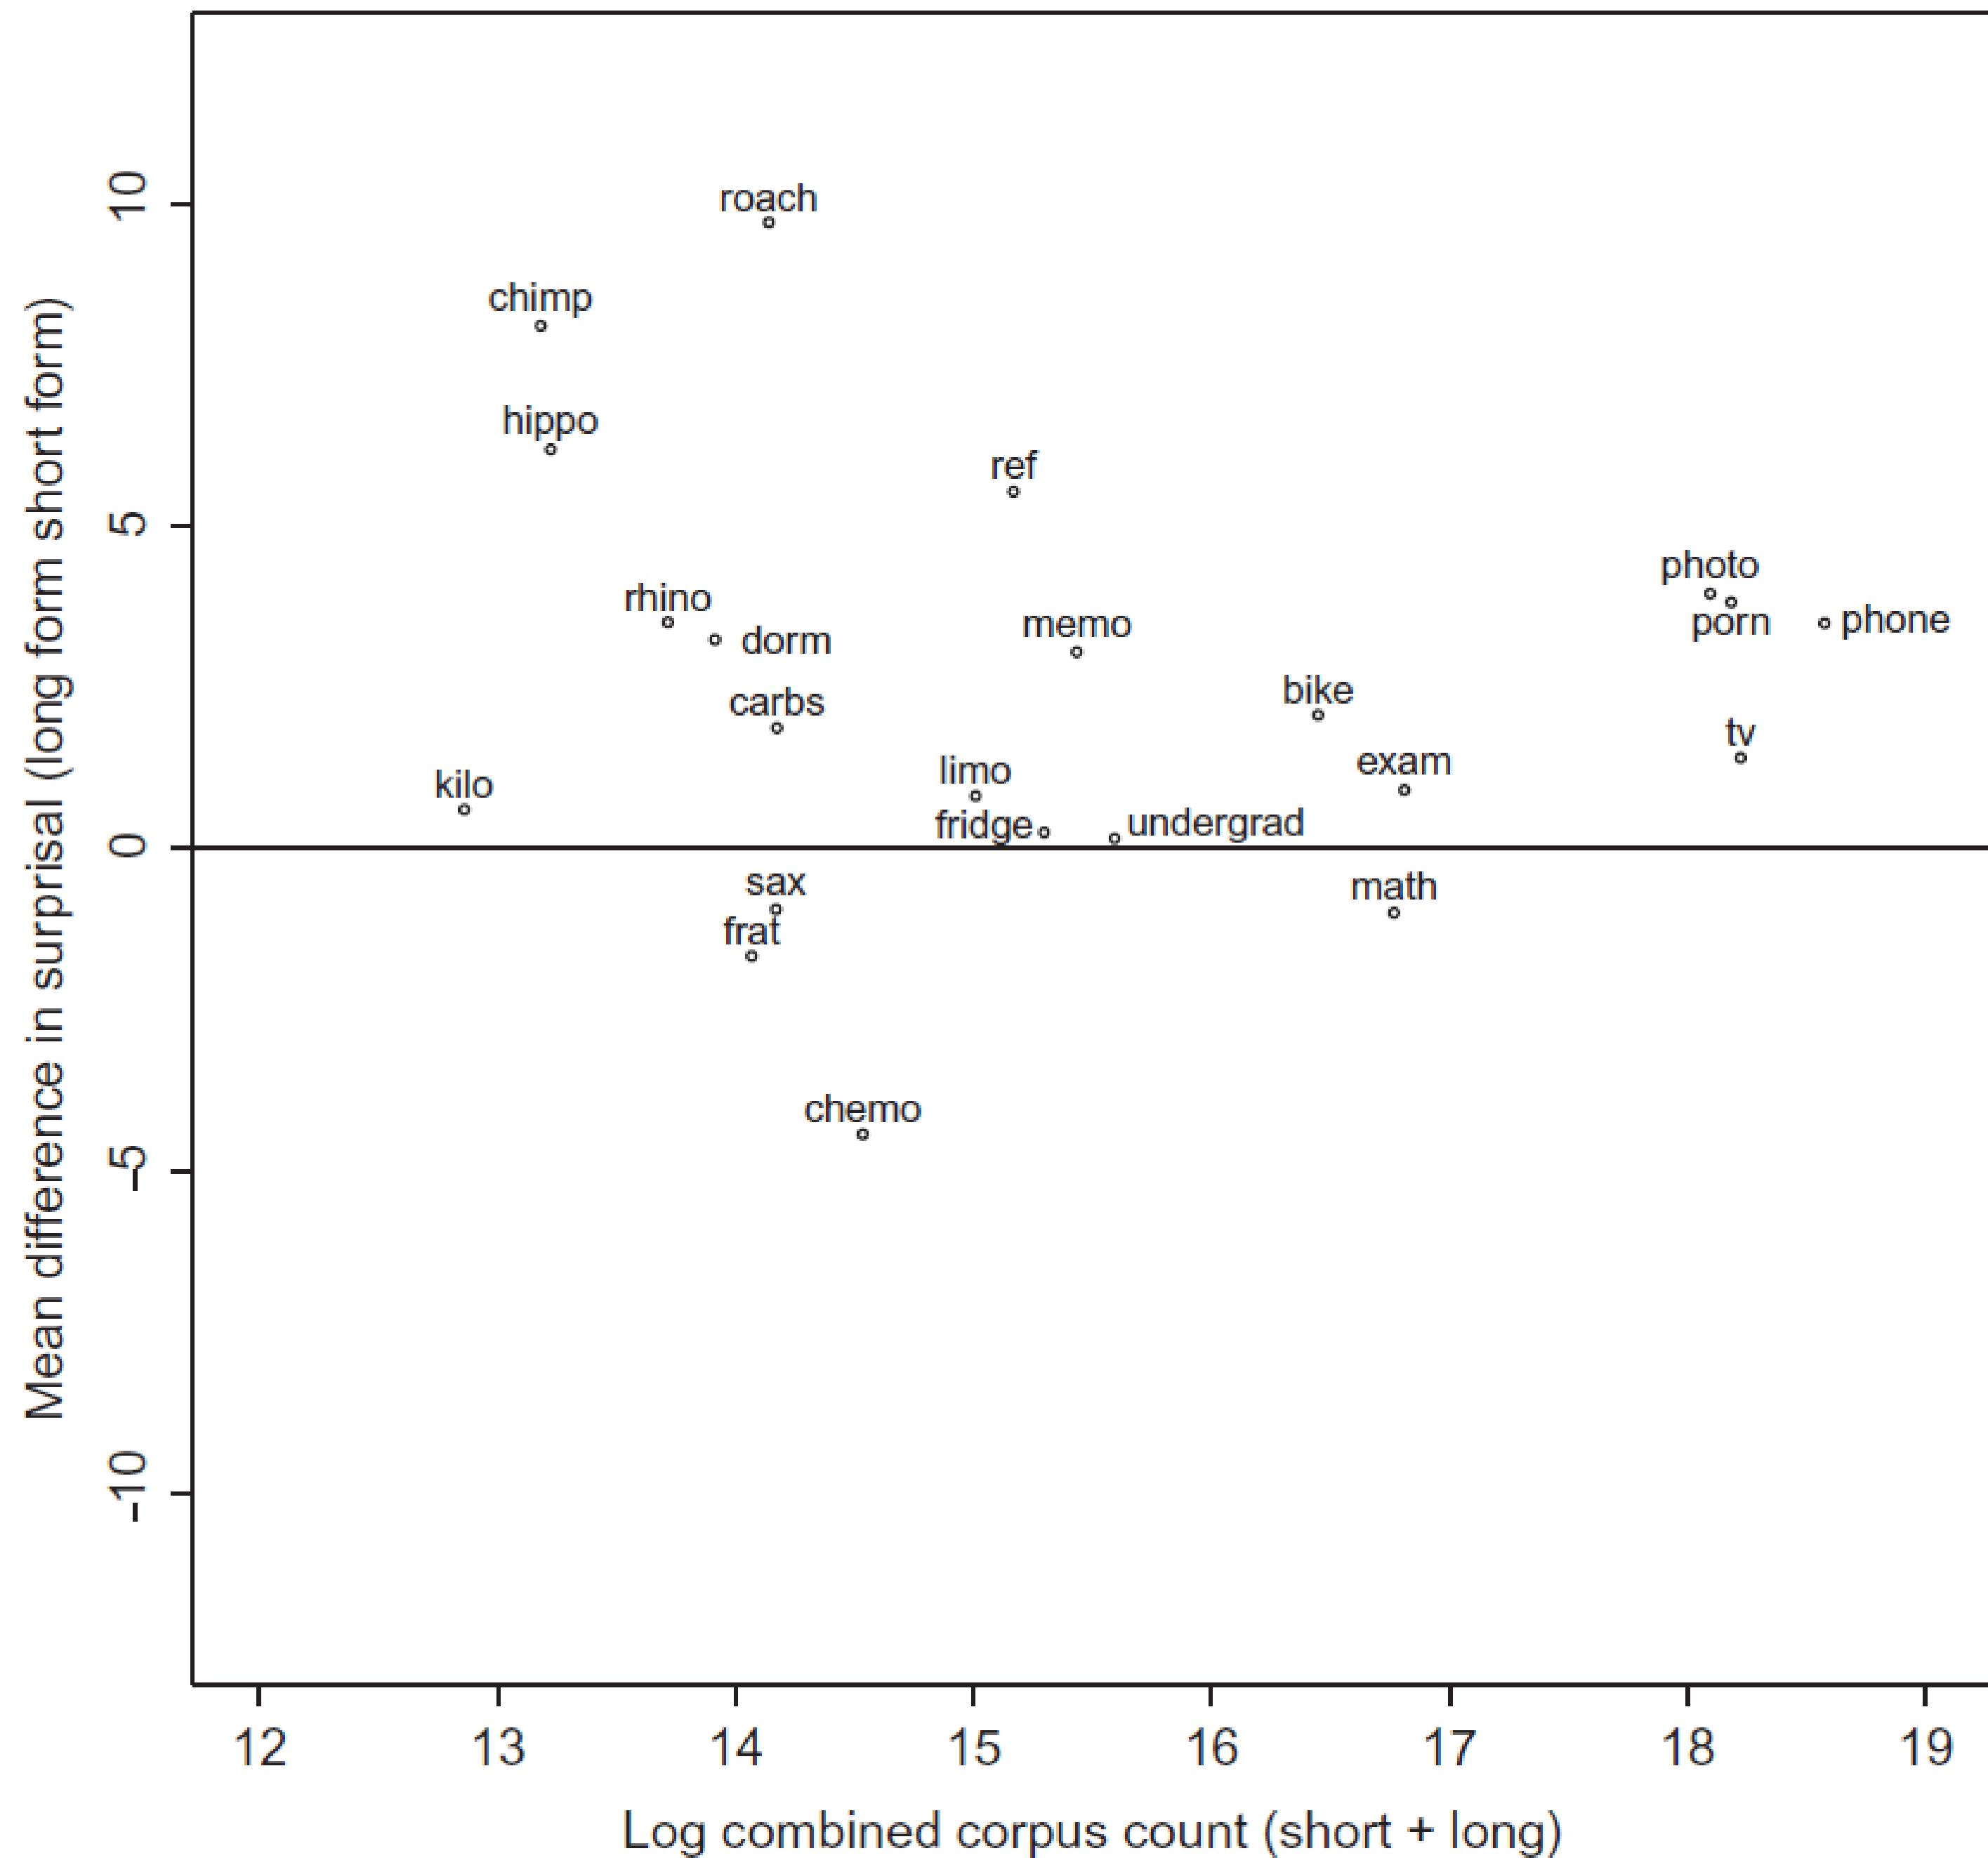
Test for correlation between length and information content while keeping the meaning constant.

chimp / chimpanzee
math / mathematics
chemo / chemotherapy

Resultate Korpusanalyse

Instanzen oberhalb der Linie
sind konsistent mit Hypothese:

kurze Form ausgewählt in
Kontexten, in denen das
Konzept vorhersagbar war.



Experiment (forced choice)

Forced choice completion test with neutral vs. predictive context:

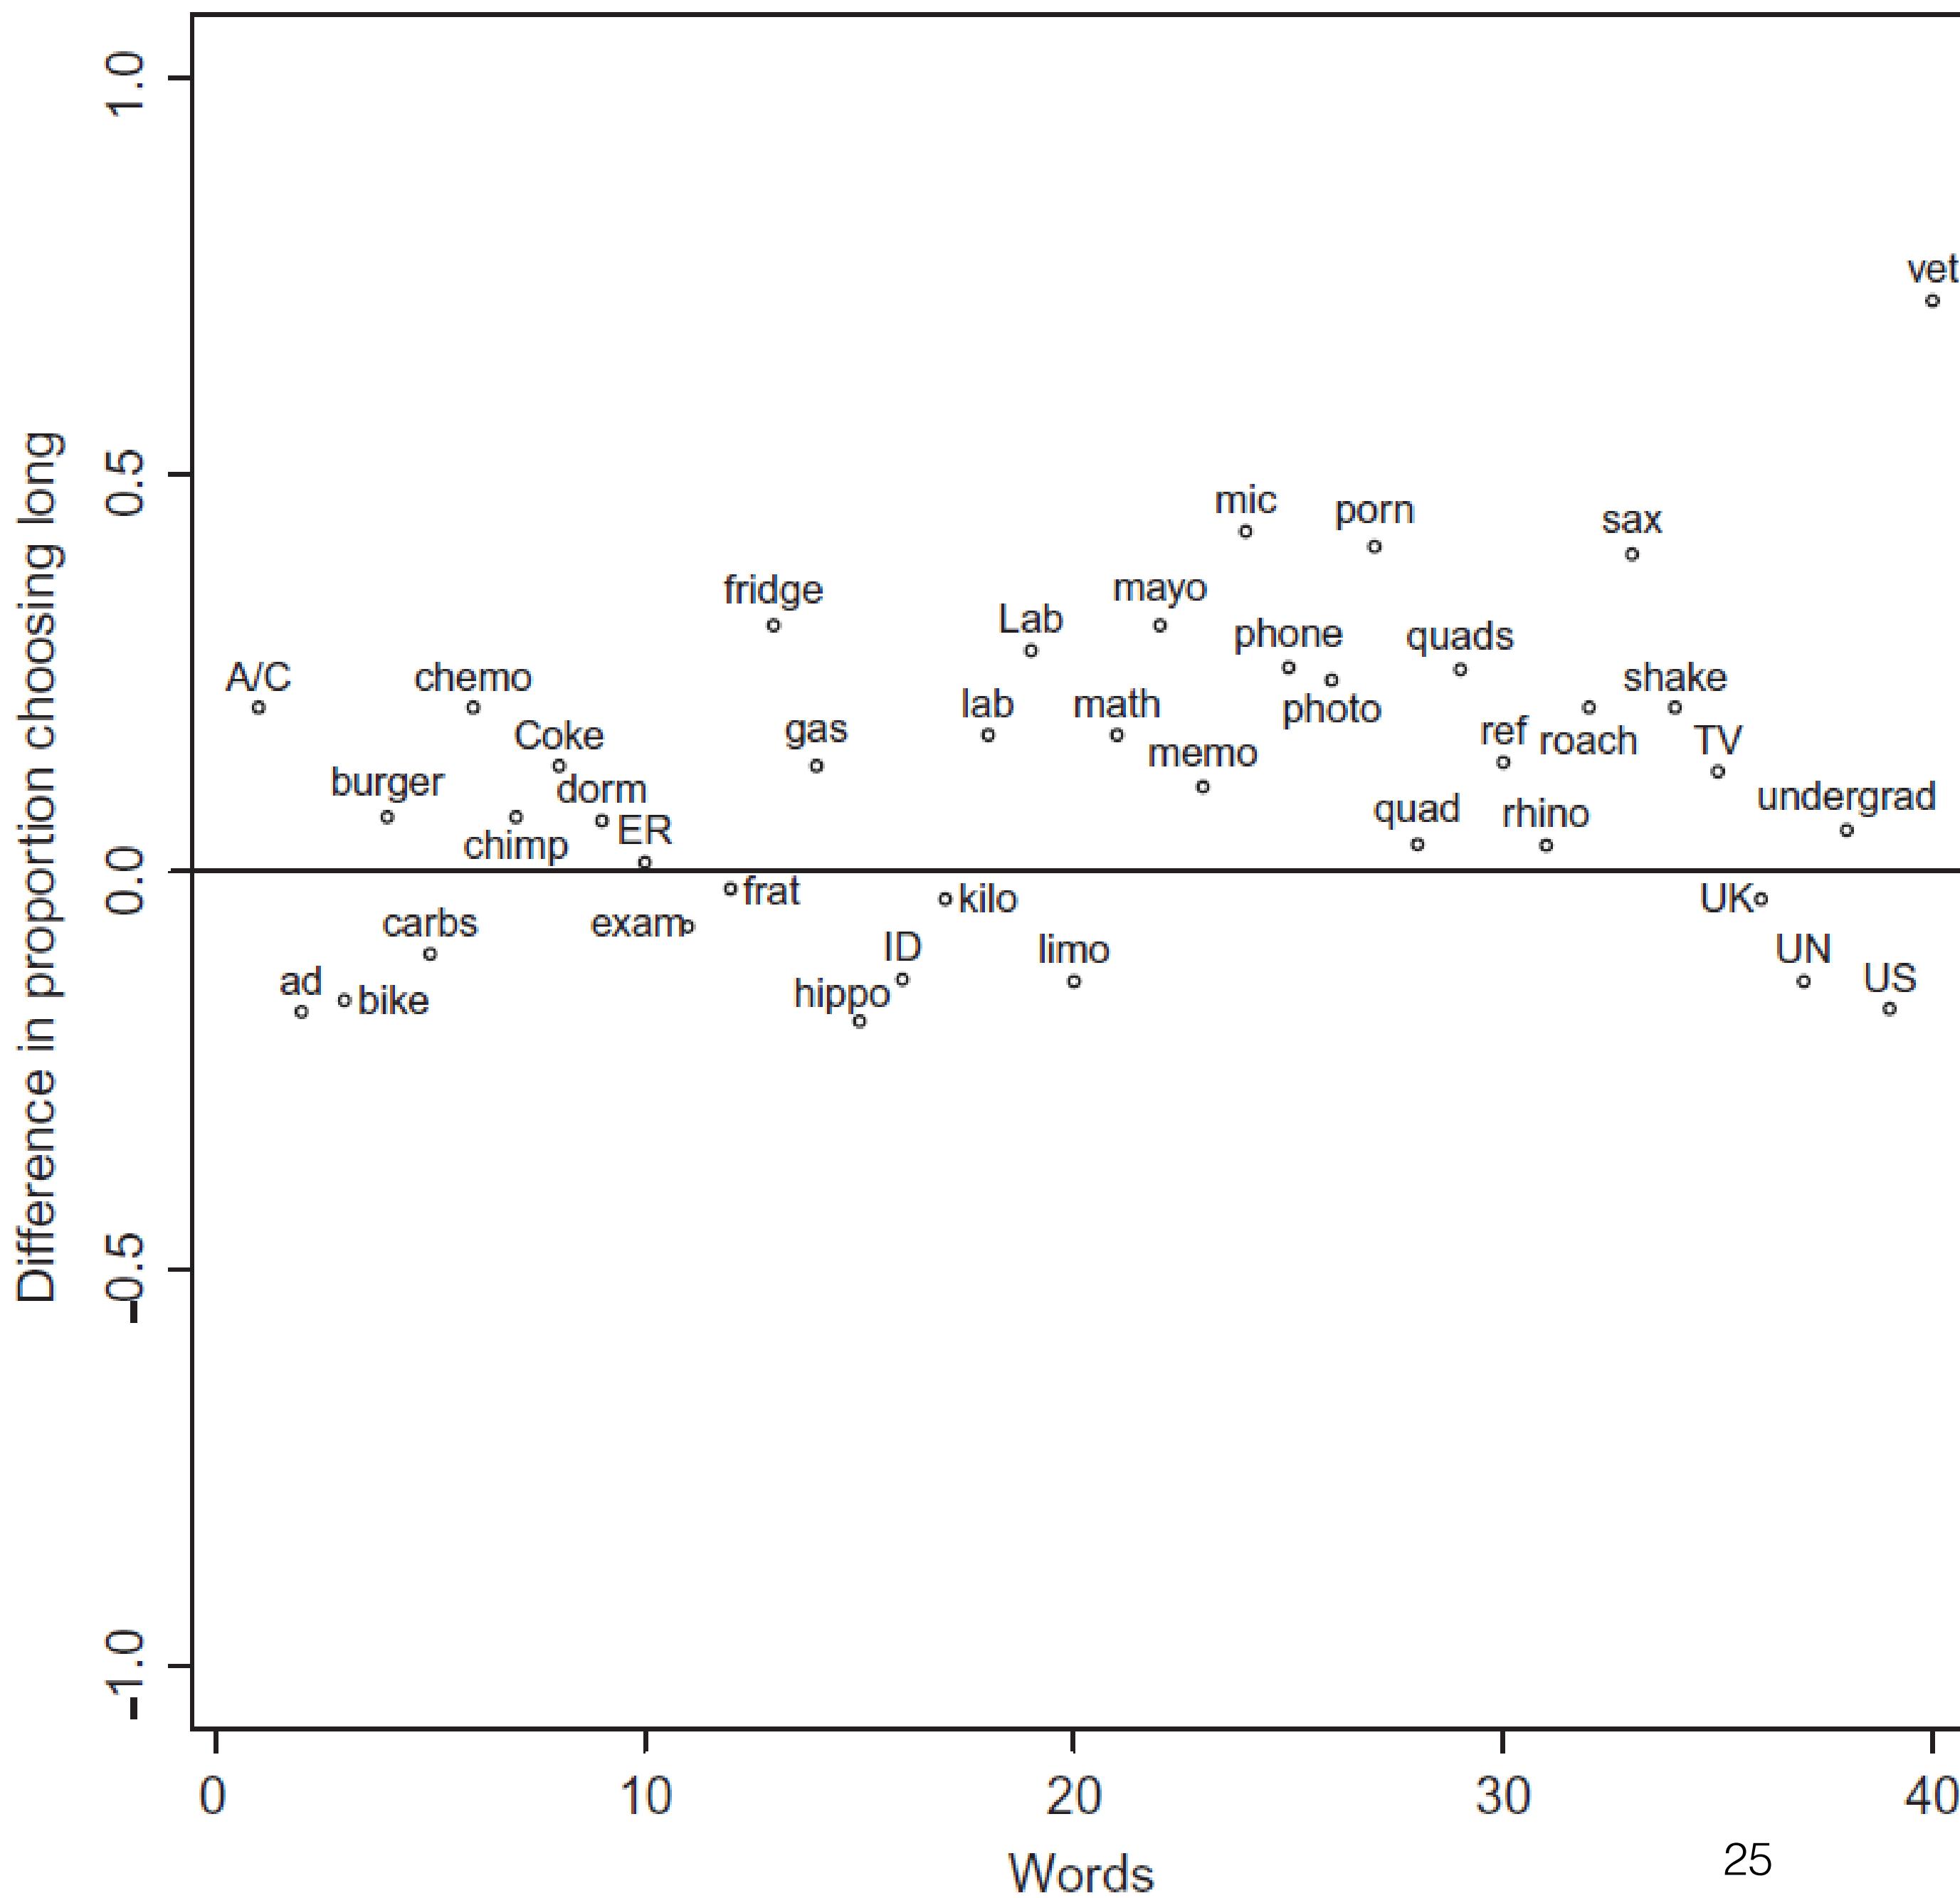
Example item: math / mathematics

Supportive: Susan was very bad at algebra, so she hated ...

Neutral: Susan introduced herself to me as someone who loved ...

(Mahowald et al., 2013)

Behavioral Results



- Experimentelle Ergebnisse konsistent mit Korpusanalyse.
- Aber *Genre* (formal / informal) könnte Ergebnisse beeinflussen.
- Kontext / Genre war kein kontrollierter Faktor.

Experiment mit kontrollierteren Kontexten



- Kompositum vs. einfaches Wort (Weinglas vs. Glas)
=> sehr häufig und produktiveres Phänomen als Abkürzungen
- Kontext vor dem kritischen Wort soll gleich gehalten werden.
- Vorhersagbarkeit manipuliert durch Vorkontext.
- 36 items, 80 Teilnehmer.

Experiment mit dt. Komposita



Predictive context:

Jeden zweiten Samstag ging Carola zur **Maniküre**.

Neutral context:

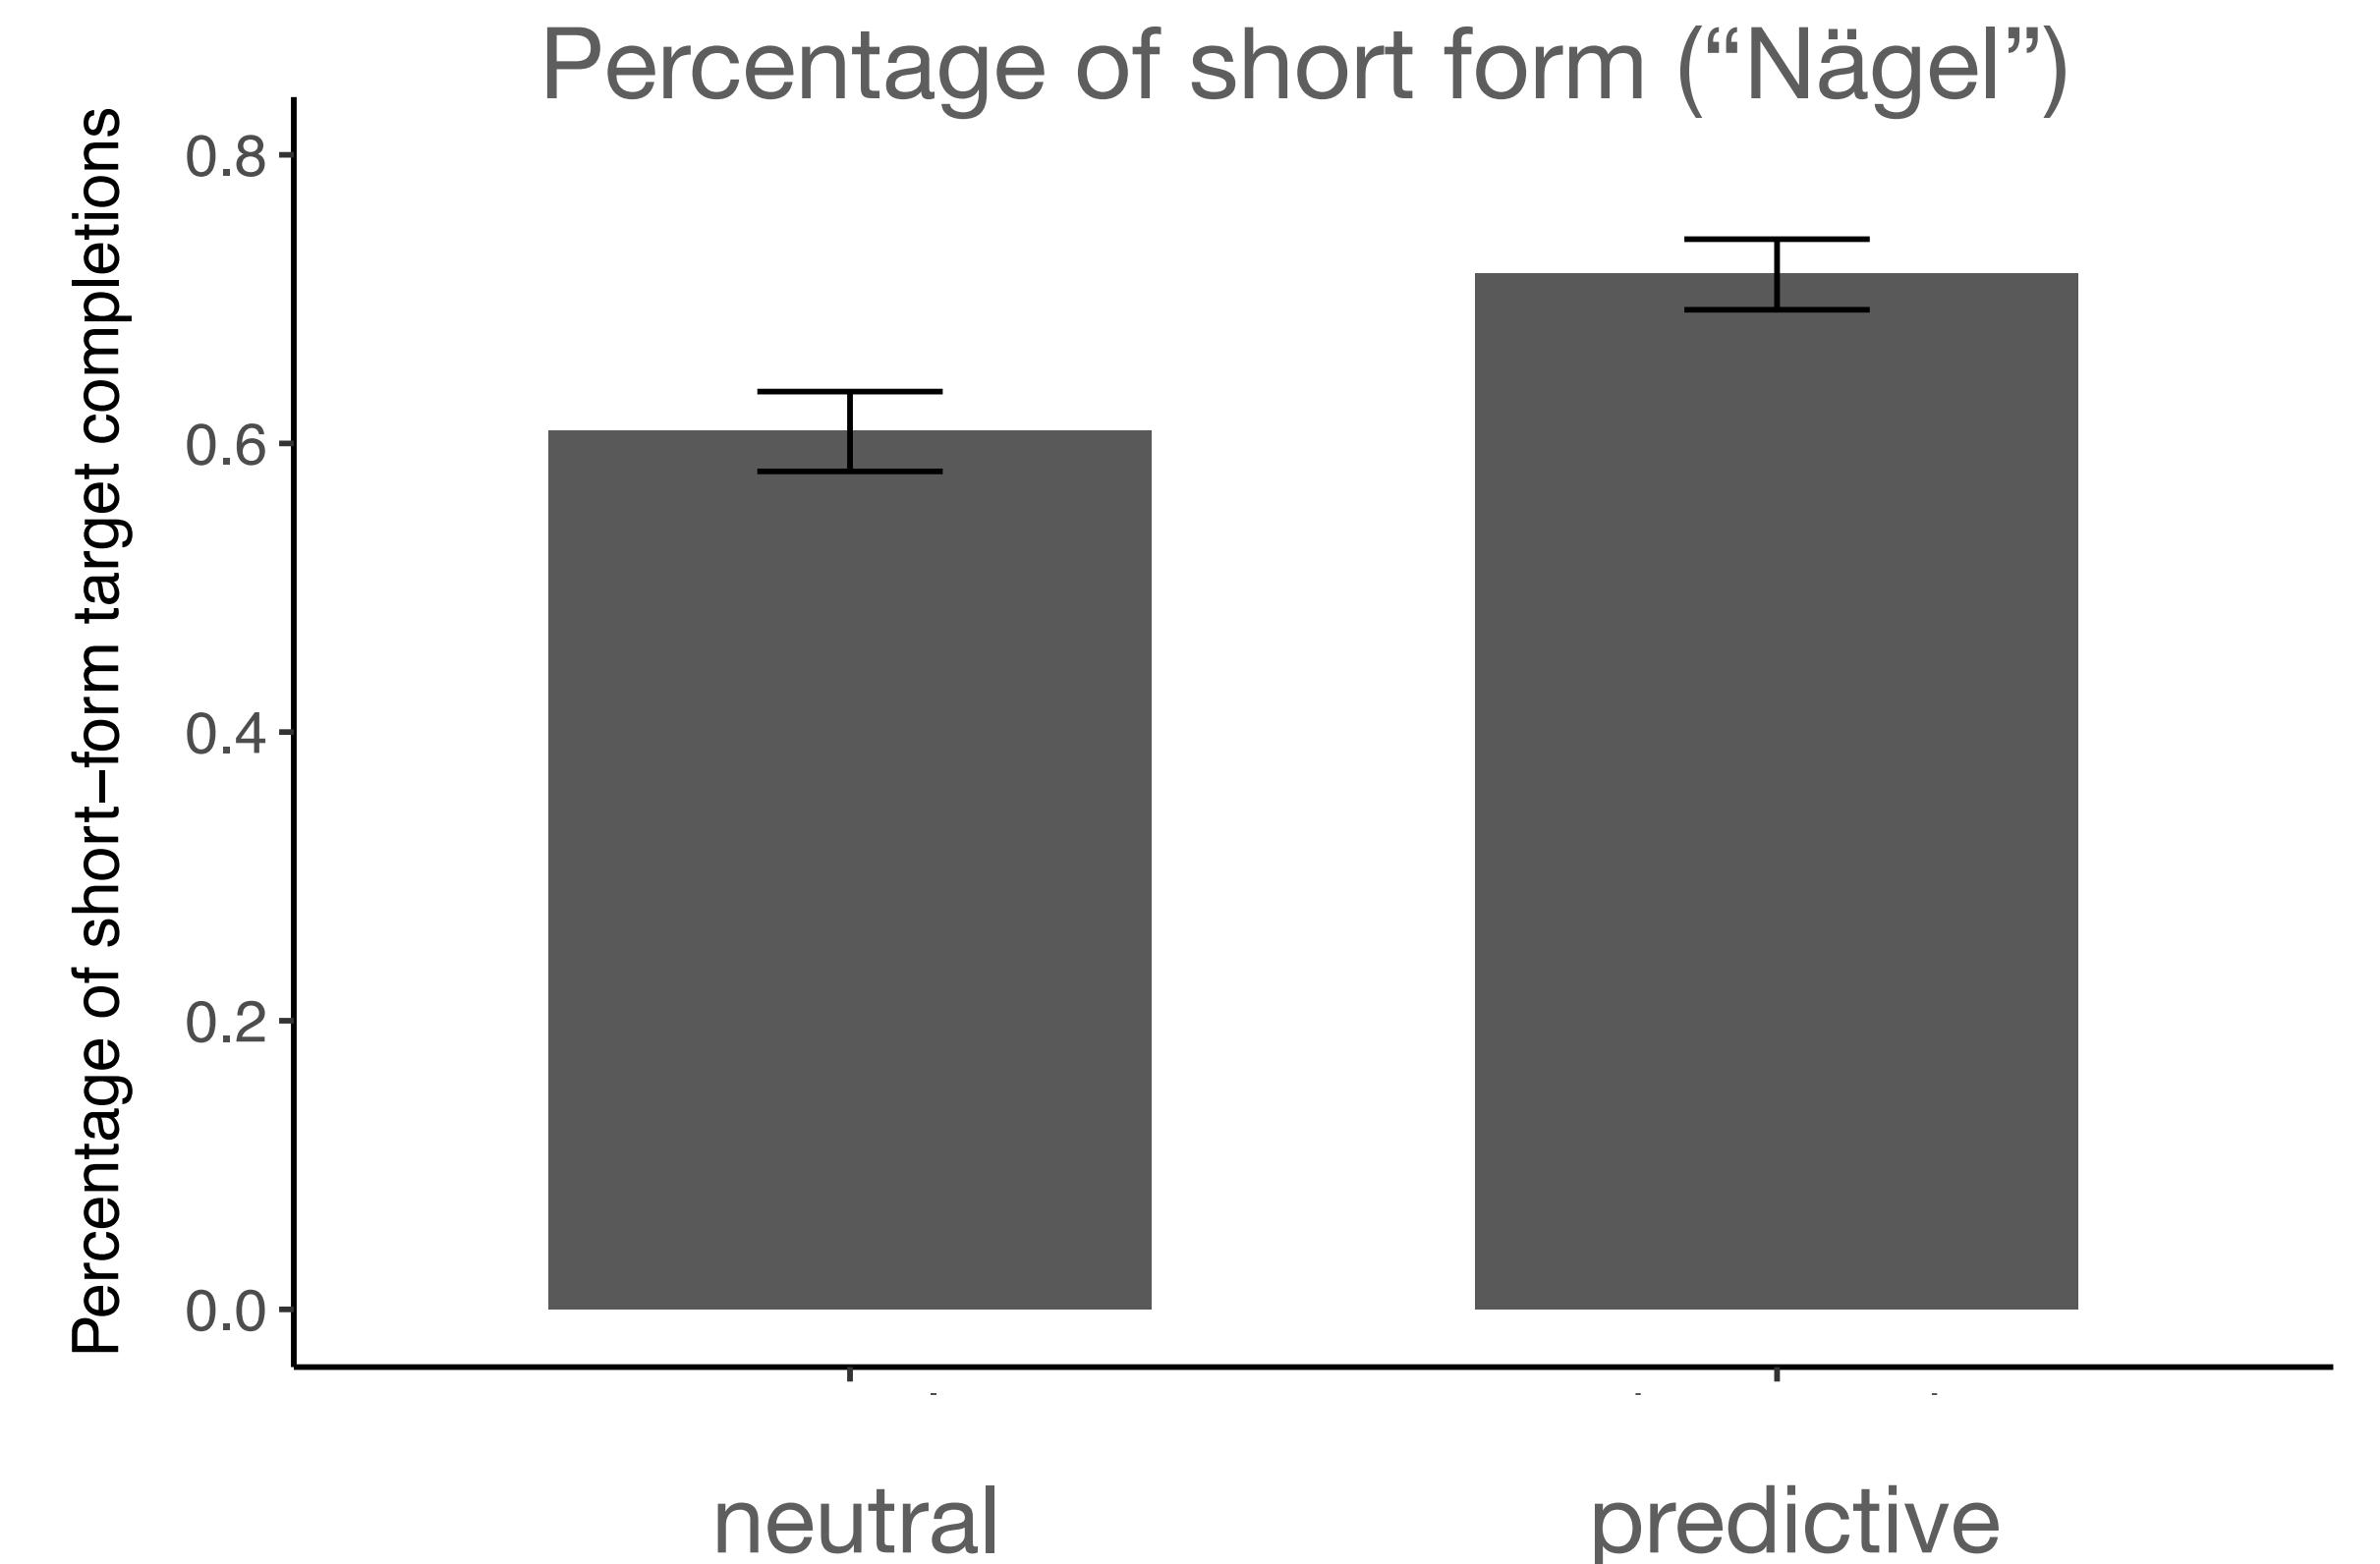
Carola war ihr Aussehen sehr wichtig.

Target:

Sie liebte es, wenn ihre **Nägel / Fingernägel** farblich auf ihr Outfit abgestimmt waren.

Ending:

Diesmal hatte sie sich für einen grellgrünen Lack entschieden.



- Kurze Formen wurden im Kontext mit höherer Erwartbarkeit präferiert ($p<0.01$).

Zusammenfassung

- Wortwahl hängt von kontextueller Erwartbarkeit des Konzepts ab.
- Experimentelle Evidenz für große Breite an Phänomenen.
- kontroverser Fall in der Literatur: Pronominalisierung

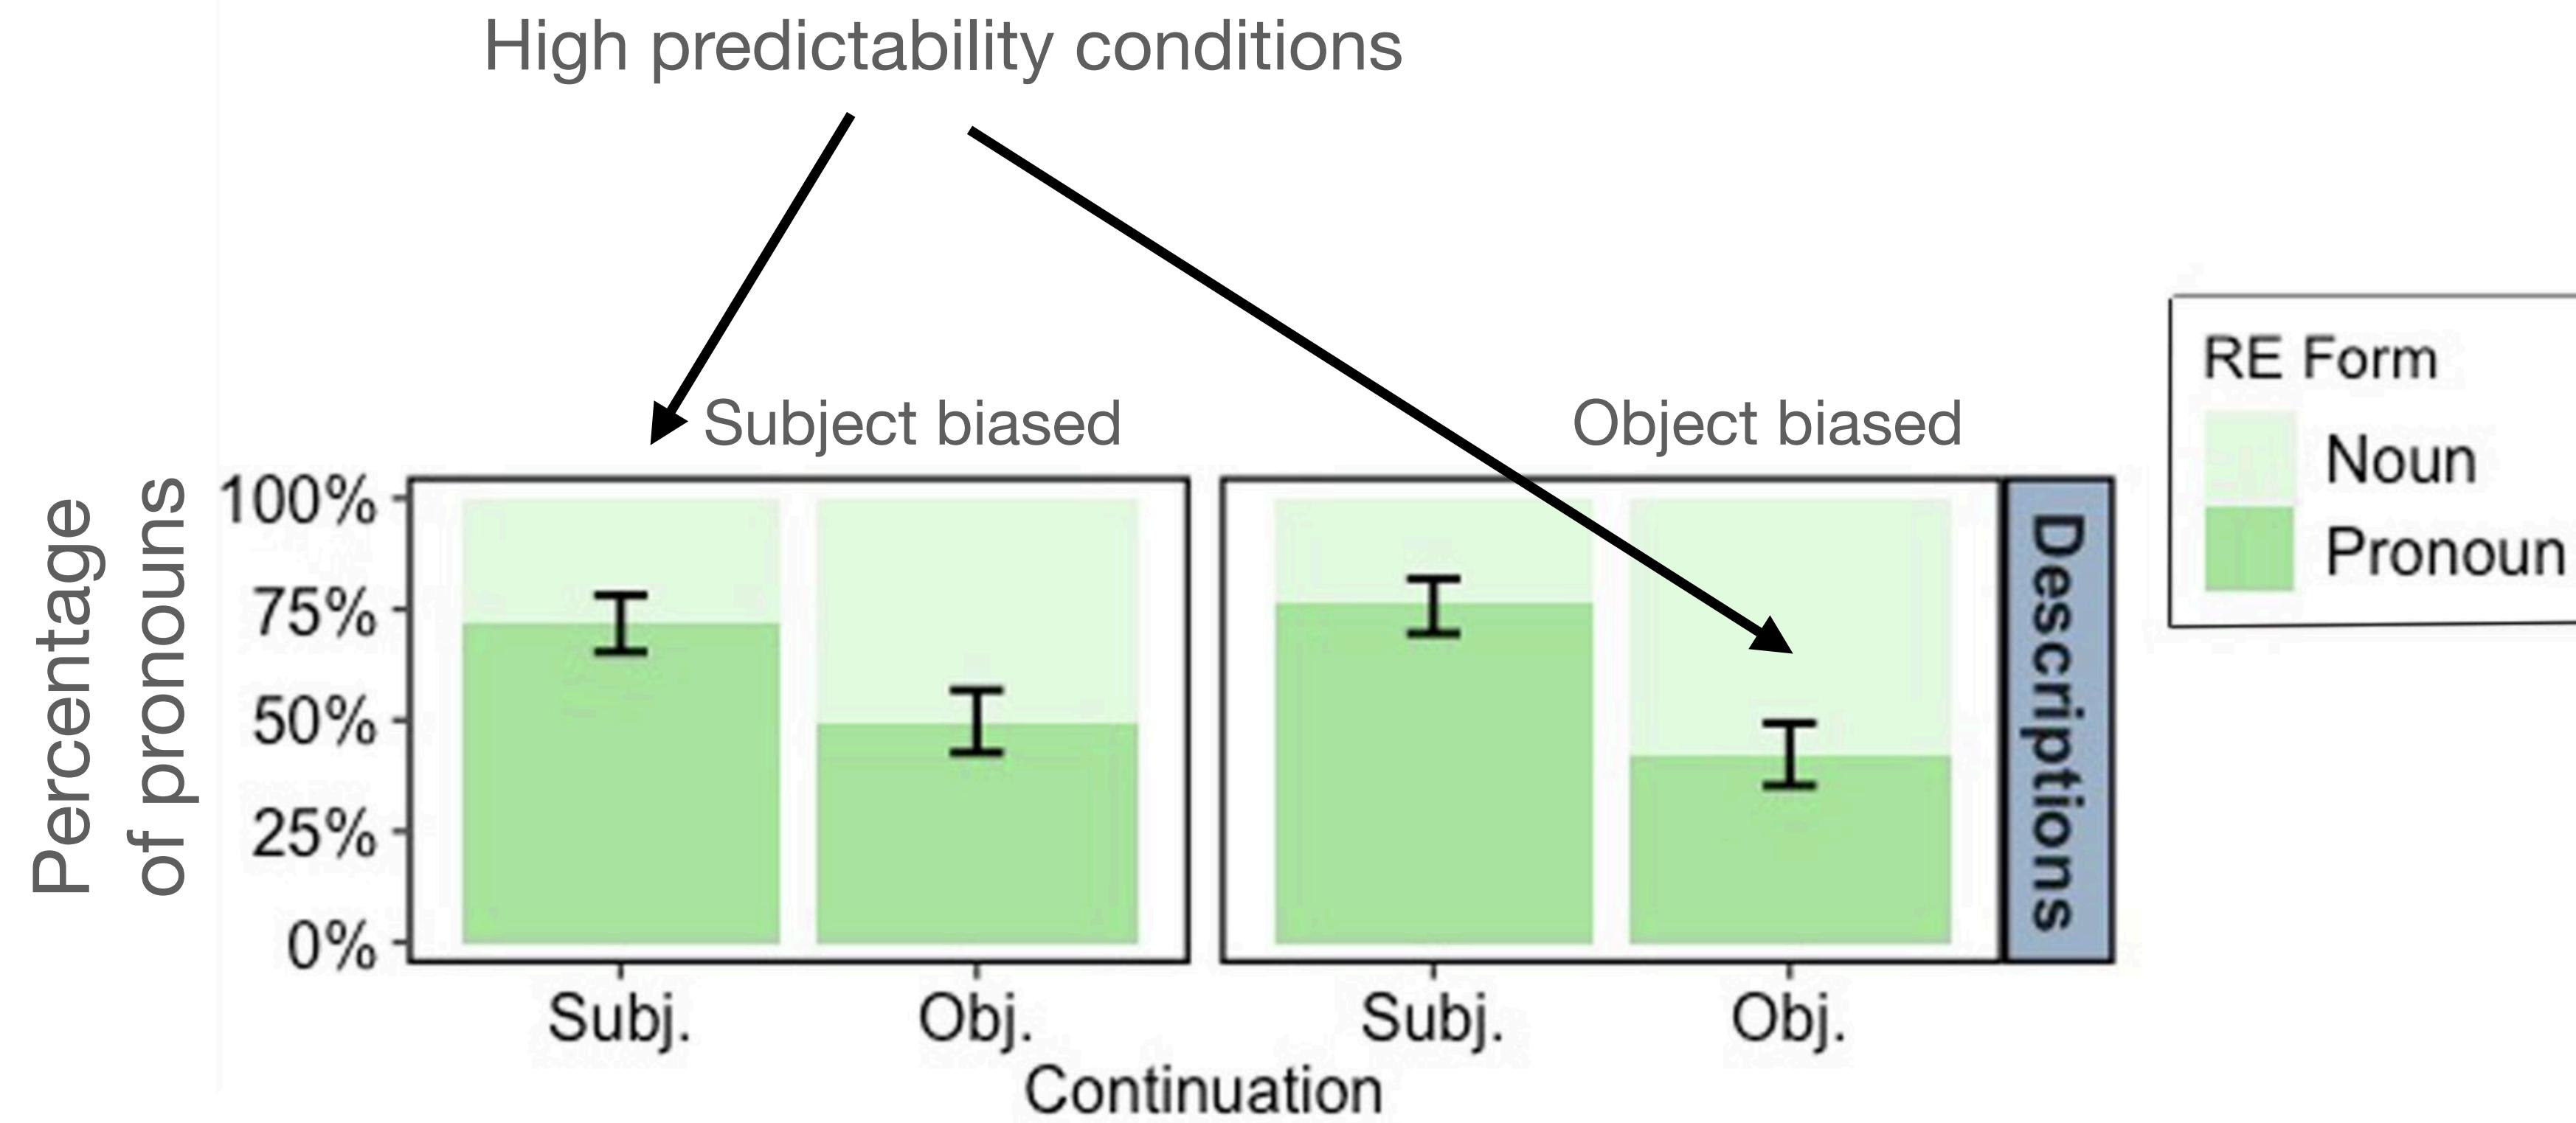
Pronominalization

- Do speakers choose a pronoun (as opposed to a name of full noun phrase) when the referent is predictable?
- Evidence on whether pronominalization follows UID predictions is highly controversial.

reference	antec.	verb	interact/	effect	
task	gender	type	context	found	
Arnold (2001)	free	different	ToP	Yes	X
Fukumura and van Gompel (2010)	constr.	different	IC	No	-
Rohde and Kehler (2014)	free	same	IC	No	-
Holler and Suckow (2016)	constr.	same	IC	No	-
Rosa and Arnold (2017)-e1,e2	constr.	both	ToP	Yes	X
Rosa and Arnold (2017)-e3	constr.	both	ToP	No	(X)
Vogels (2019)	constr.	same	ToP,IC	No	X
Weatherford and Arnold (2021)	constr.	both	IC	Yes	X
Bott and Solstad (2023)-e1	constr.	both	ToP	No	X
Bott and Solstad (2023)-e2	constr.	both	IC	No	X
Bott and Solstad (2023)-e3	constr.	both	IC,AE	No	-
Bott and Solstad (2023)-e4	constr.	both	IC	No	X

Large-scale study

- Using a traditional paradigm
("Peter admires / fascinates Paul because...")
we only found null-effects, even in highly powered studies.



=> predictability doesn't seem to make a difference!

Paradigm with contextualized stimuli



Fantasy context



This is the sorcerer. He is skilled in ancient magic.



This is the psychic. She sees the future in her crystal ball.



This is the archer. He is never without his bow and arrow.



This is the witch. She specialises in glamour spells.



This is the thief. He steals when your back is turned.



This is the healer. She knows all about potions and antidotes.

Materials:

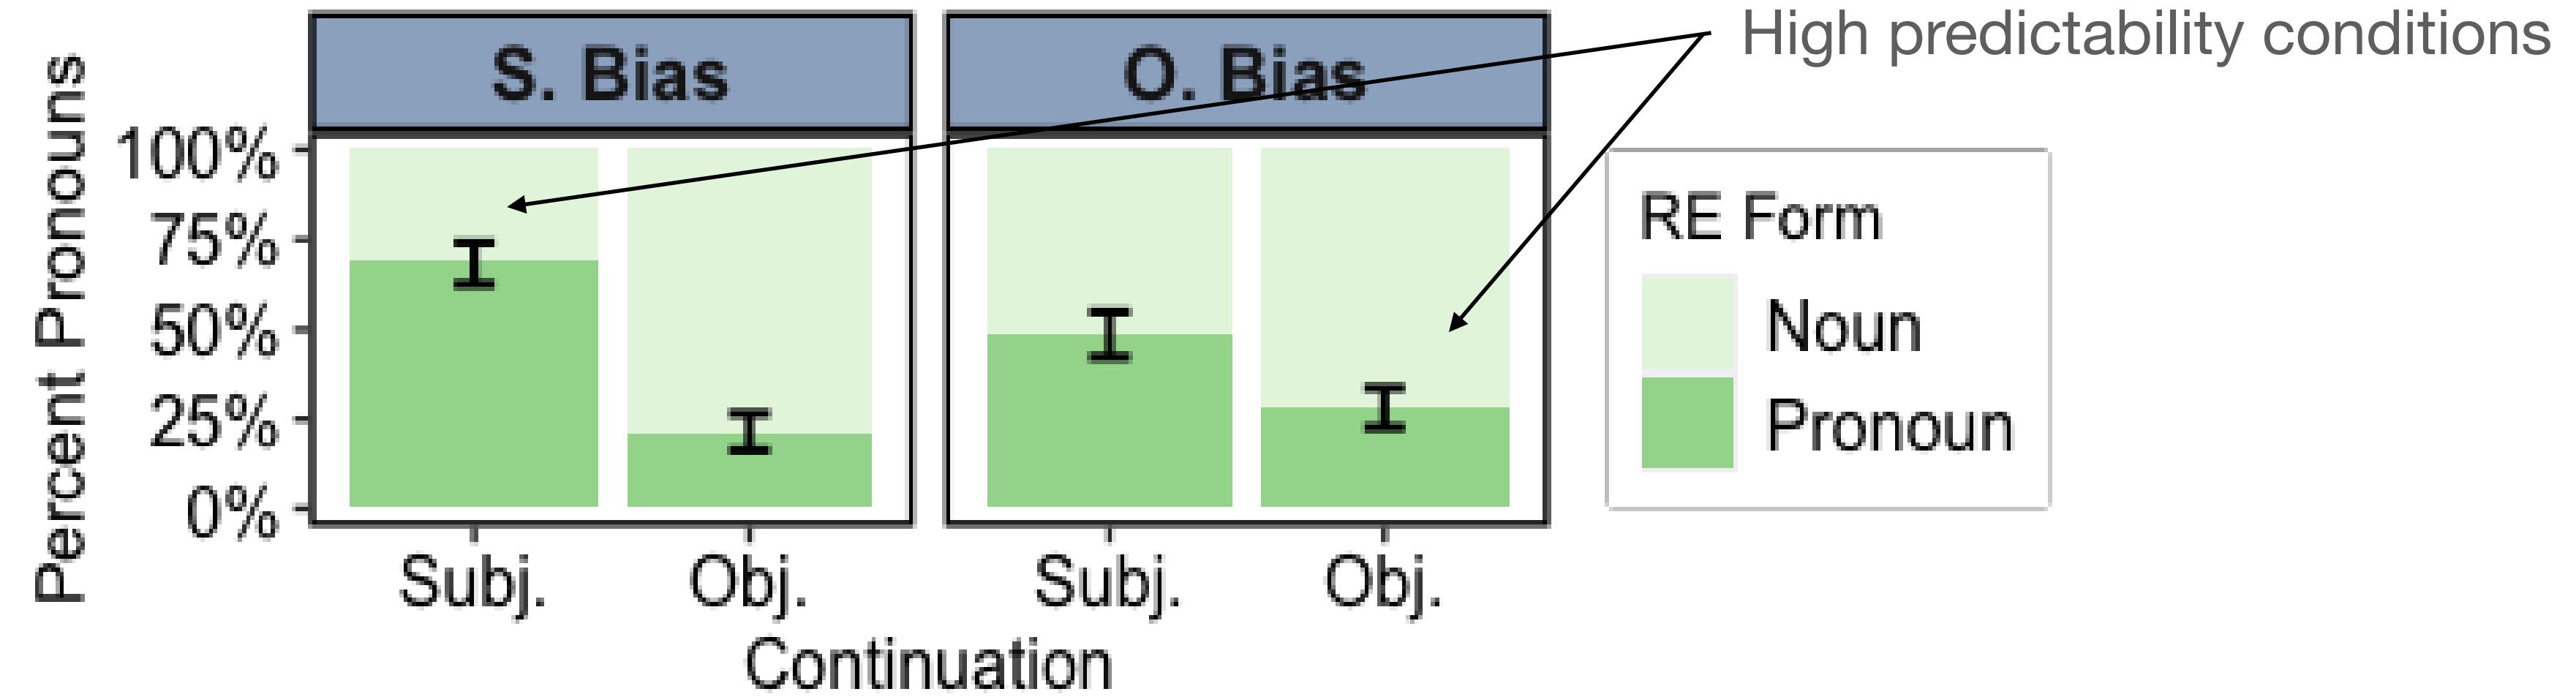
The psychic had been poisoned by venom bleeding ivy. The healer rushed over with an assortment of antidotes.

The healer sold a vial of antidote to the psychic./The psychic bought a vial of antidote from the healer.

Next, ...



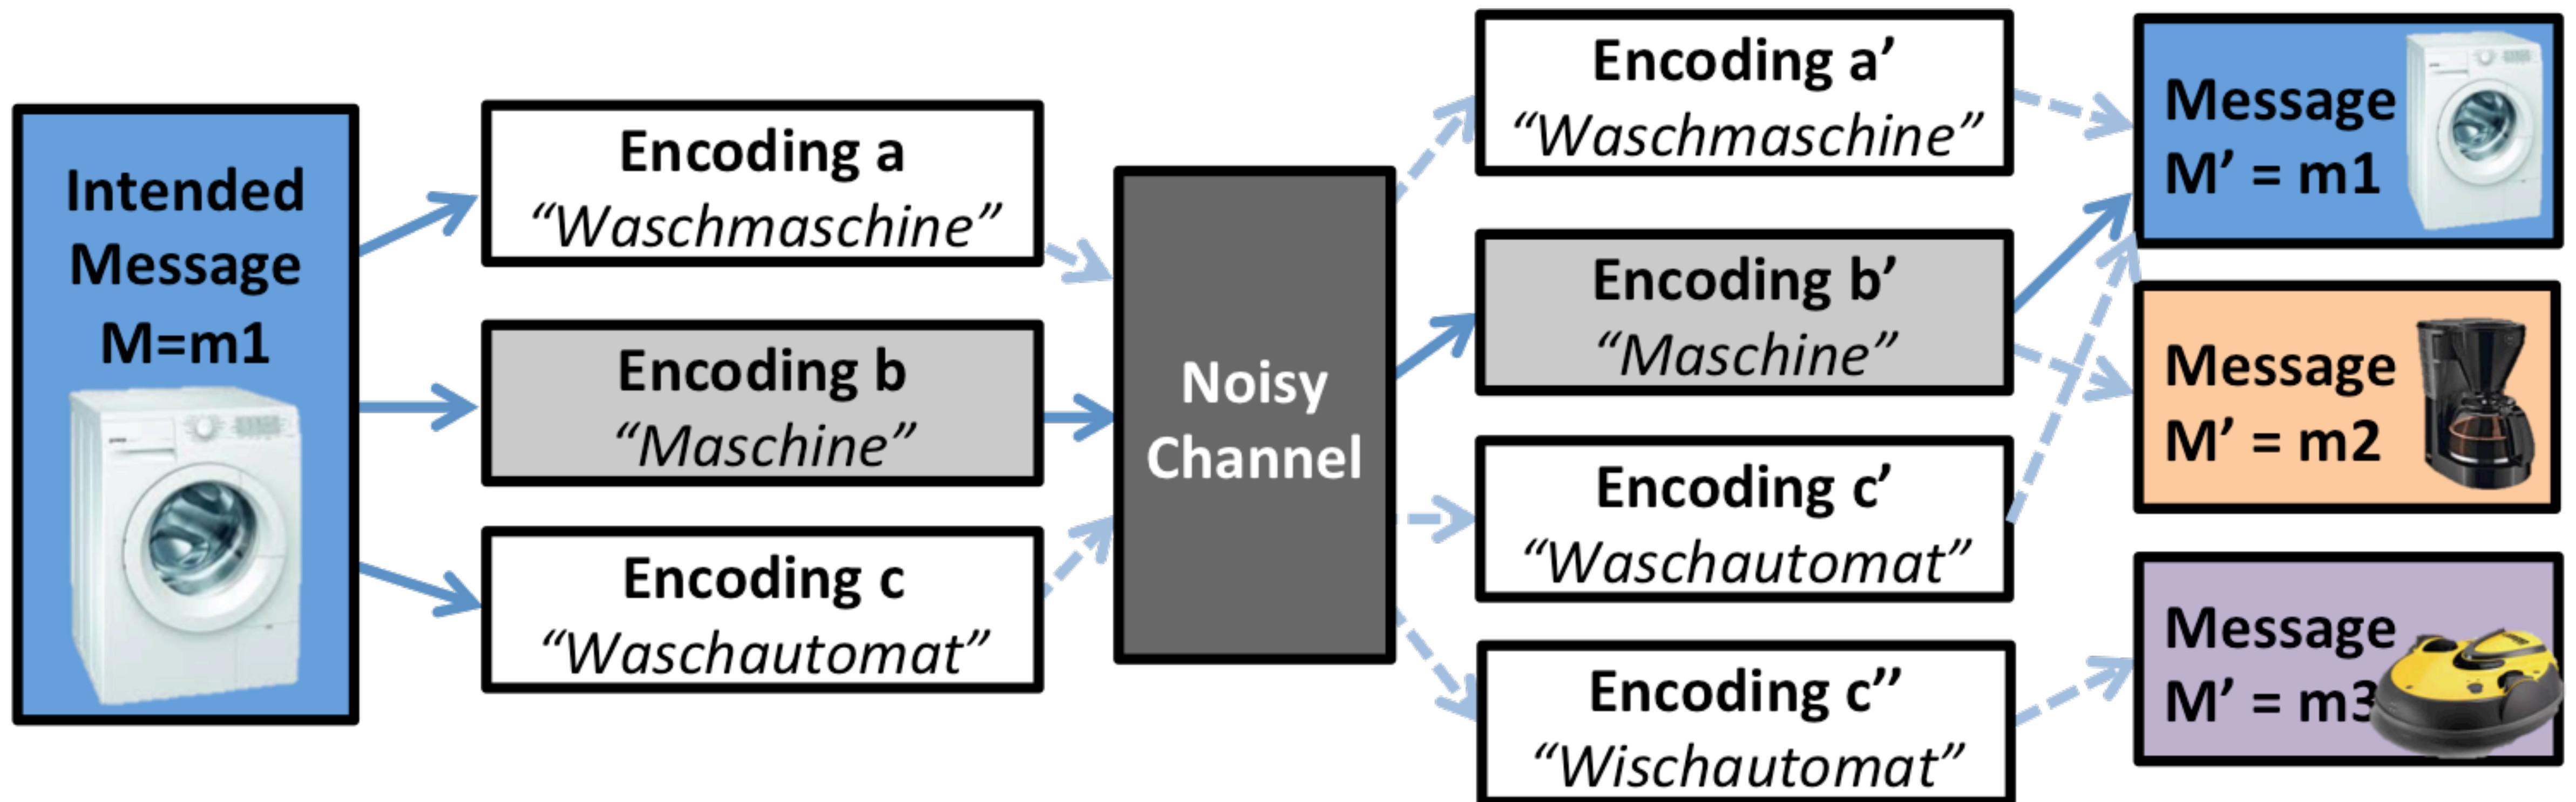
Paradigm with contextualized stimuli



- Contextualization does make a difference:
in this setting, the pronominalization rate of predictable referents
is larger than the pronominalization rate of unpredictable ones ($p < 0.001$)
=> naturalistic tasks should be taken more seriously in experimental design.
- Nevertheless, the largest effect on pronoun choice is whether the pronoun
refers to the subject or the object of the previous sentence.

Speakers select encodings rationally.

Listeners rationally combine bottom-up and top-down evidence



Q3 – Wie können wir die nötigen Wahrscheinlichkeiten abschätzen?

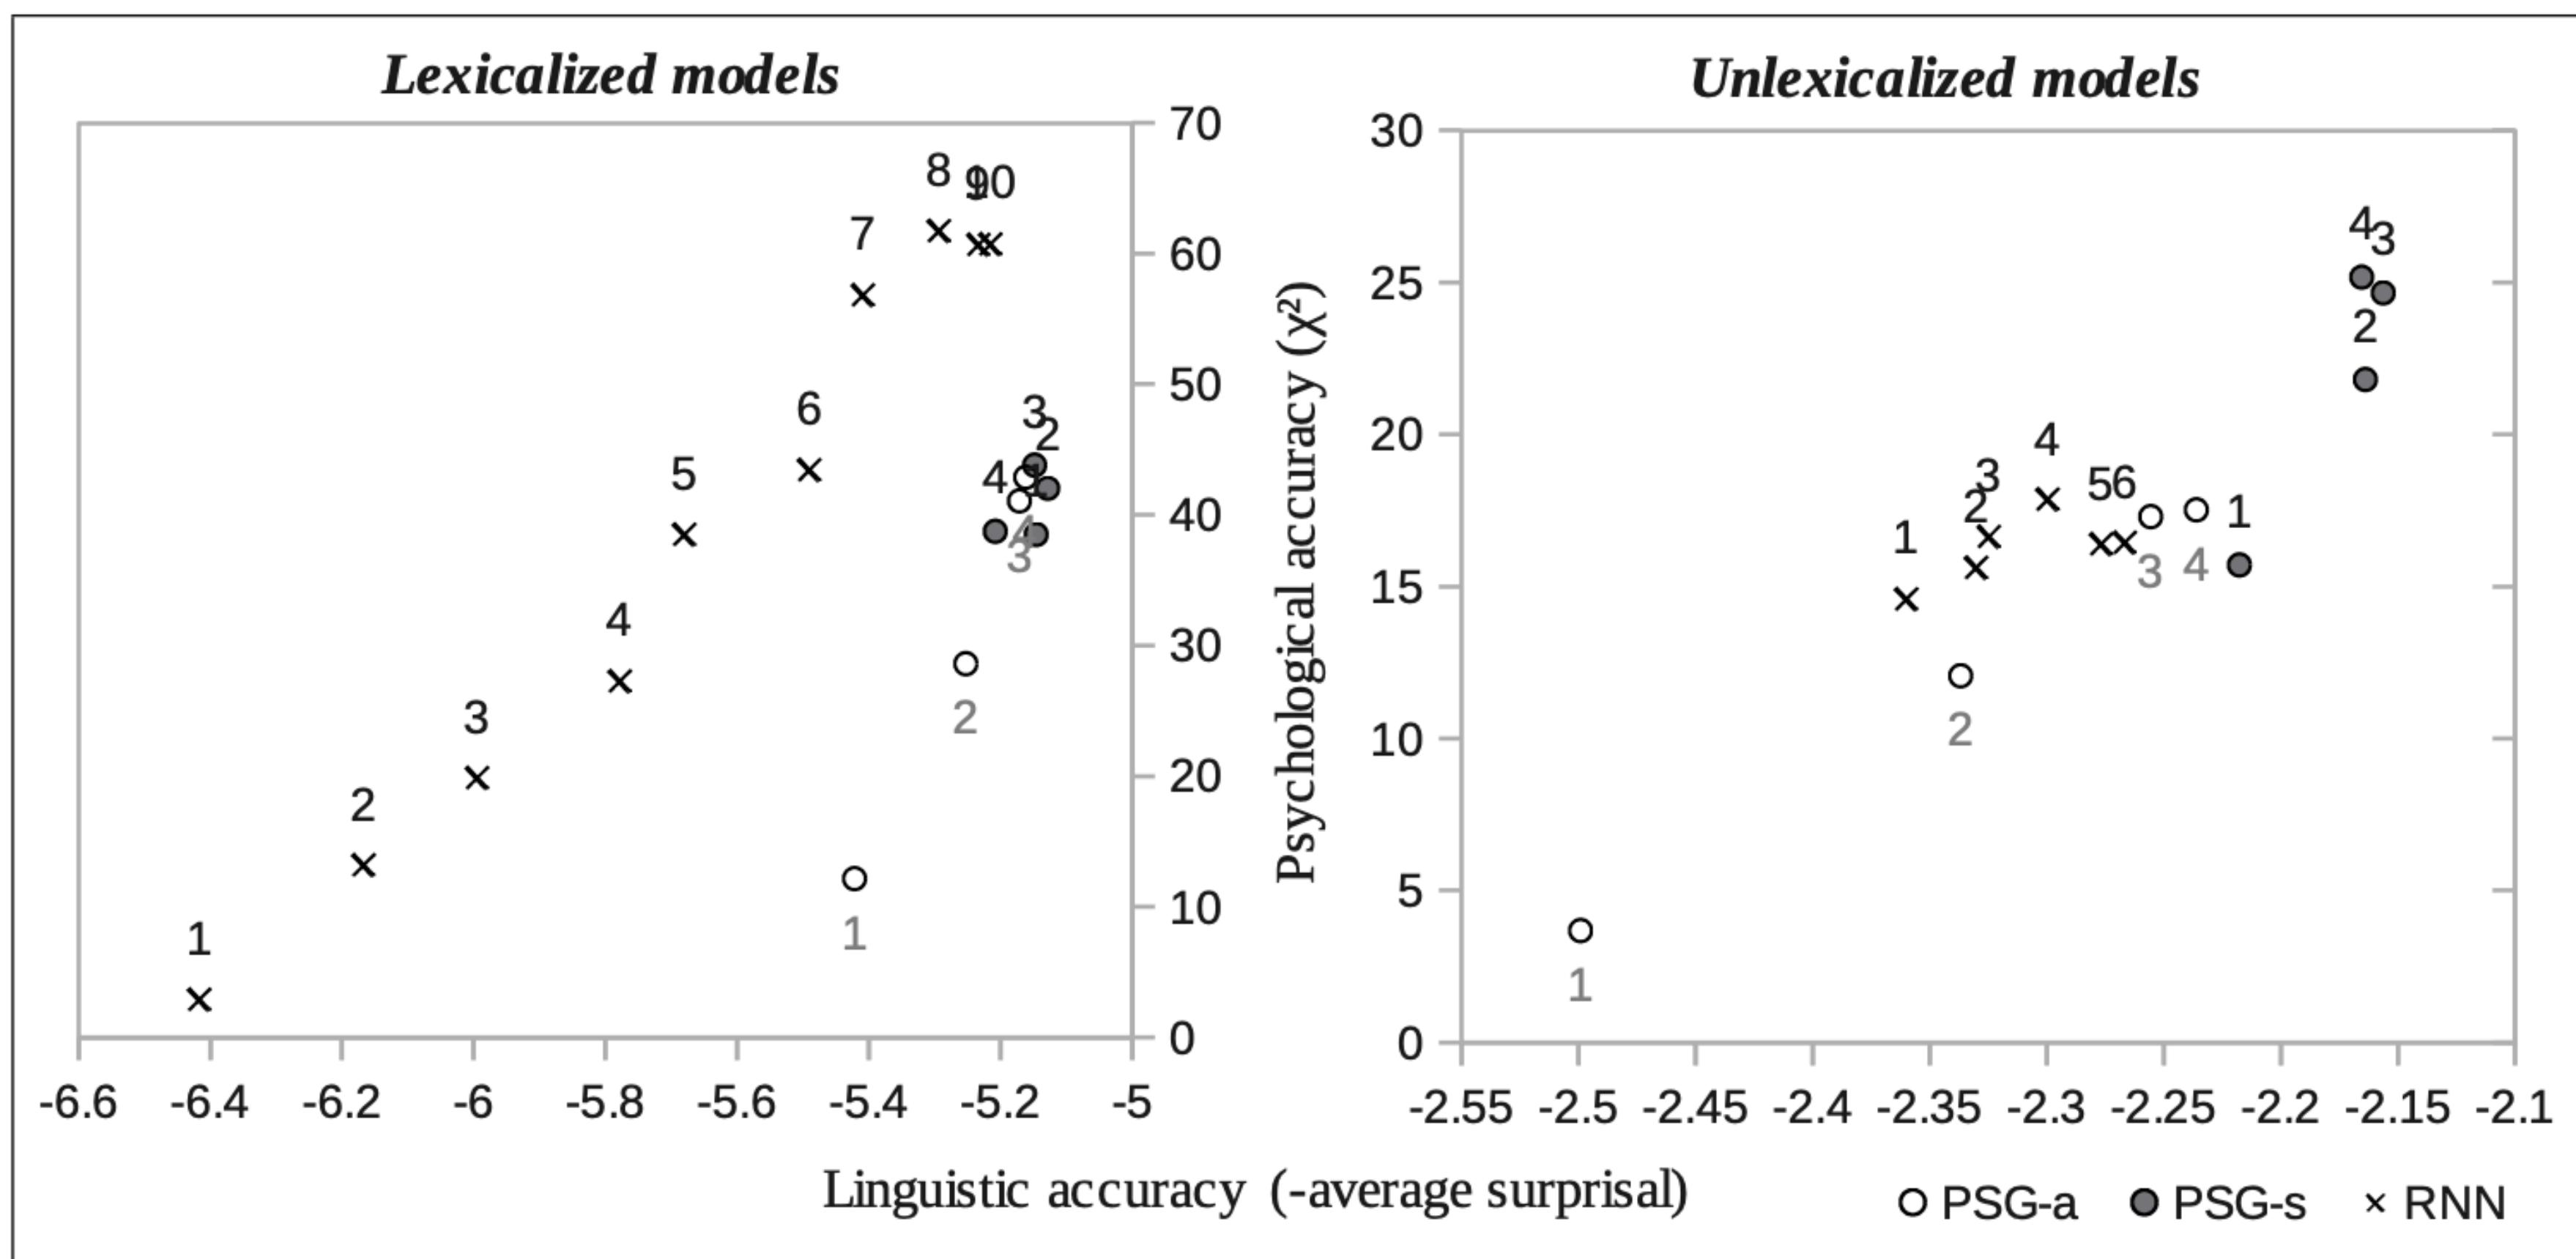
Estimating surprisal

Extensive literature on how to estimate surprisal:

- from humans using cloze probabilities
- from language models
 - n-gram models
 - syntactic parsers
 - neural models (feedforward)
 - newest large language models
- recent studies find that estimation from language models may be more accurate than estimation from cloze probabilities (Michaelov et al., 2023).

Findings 2008 – 2020

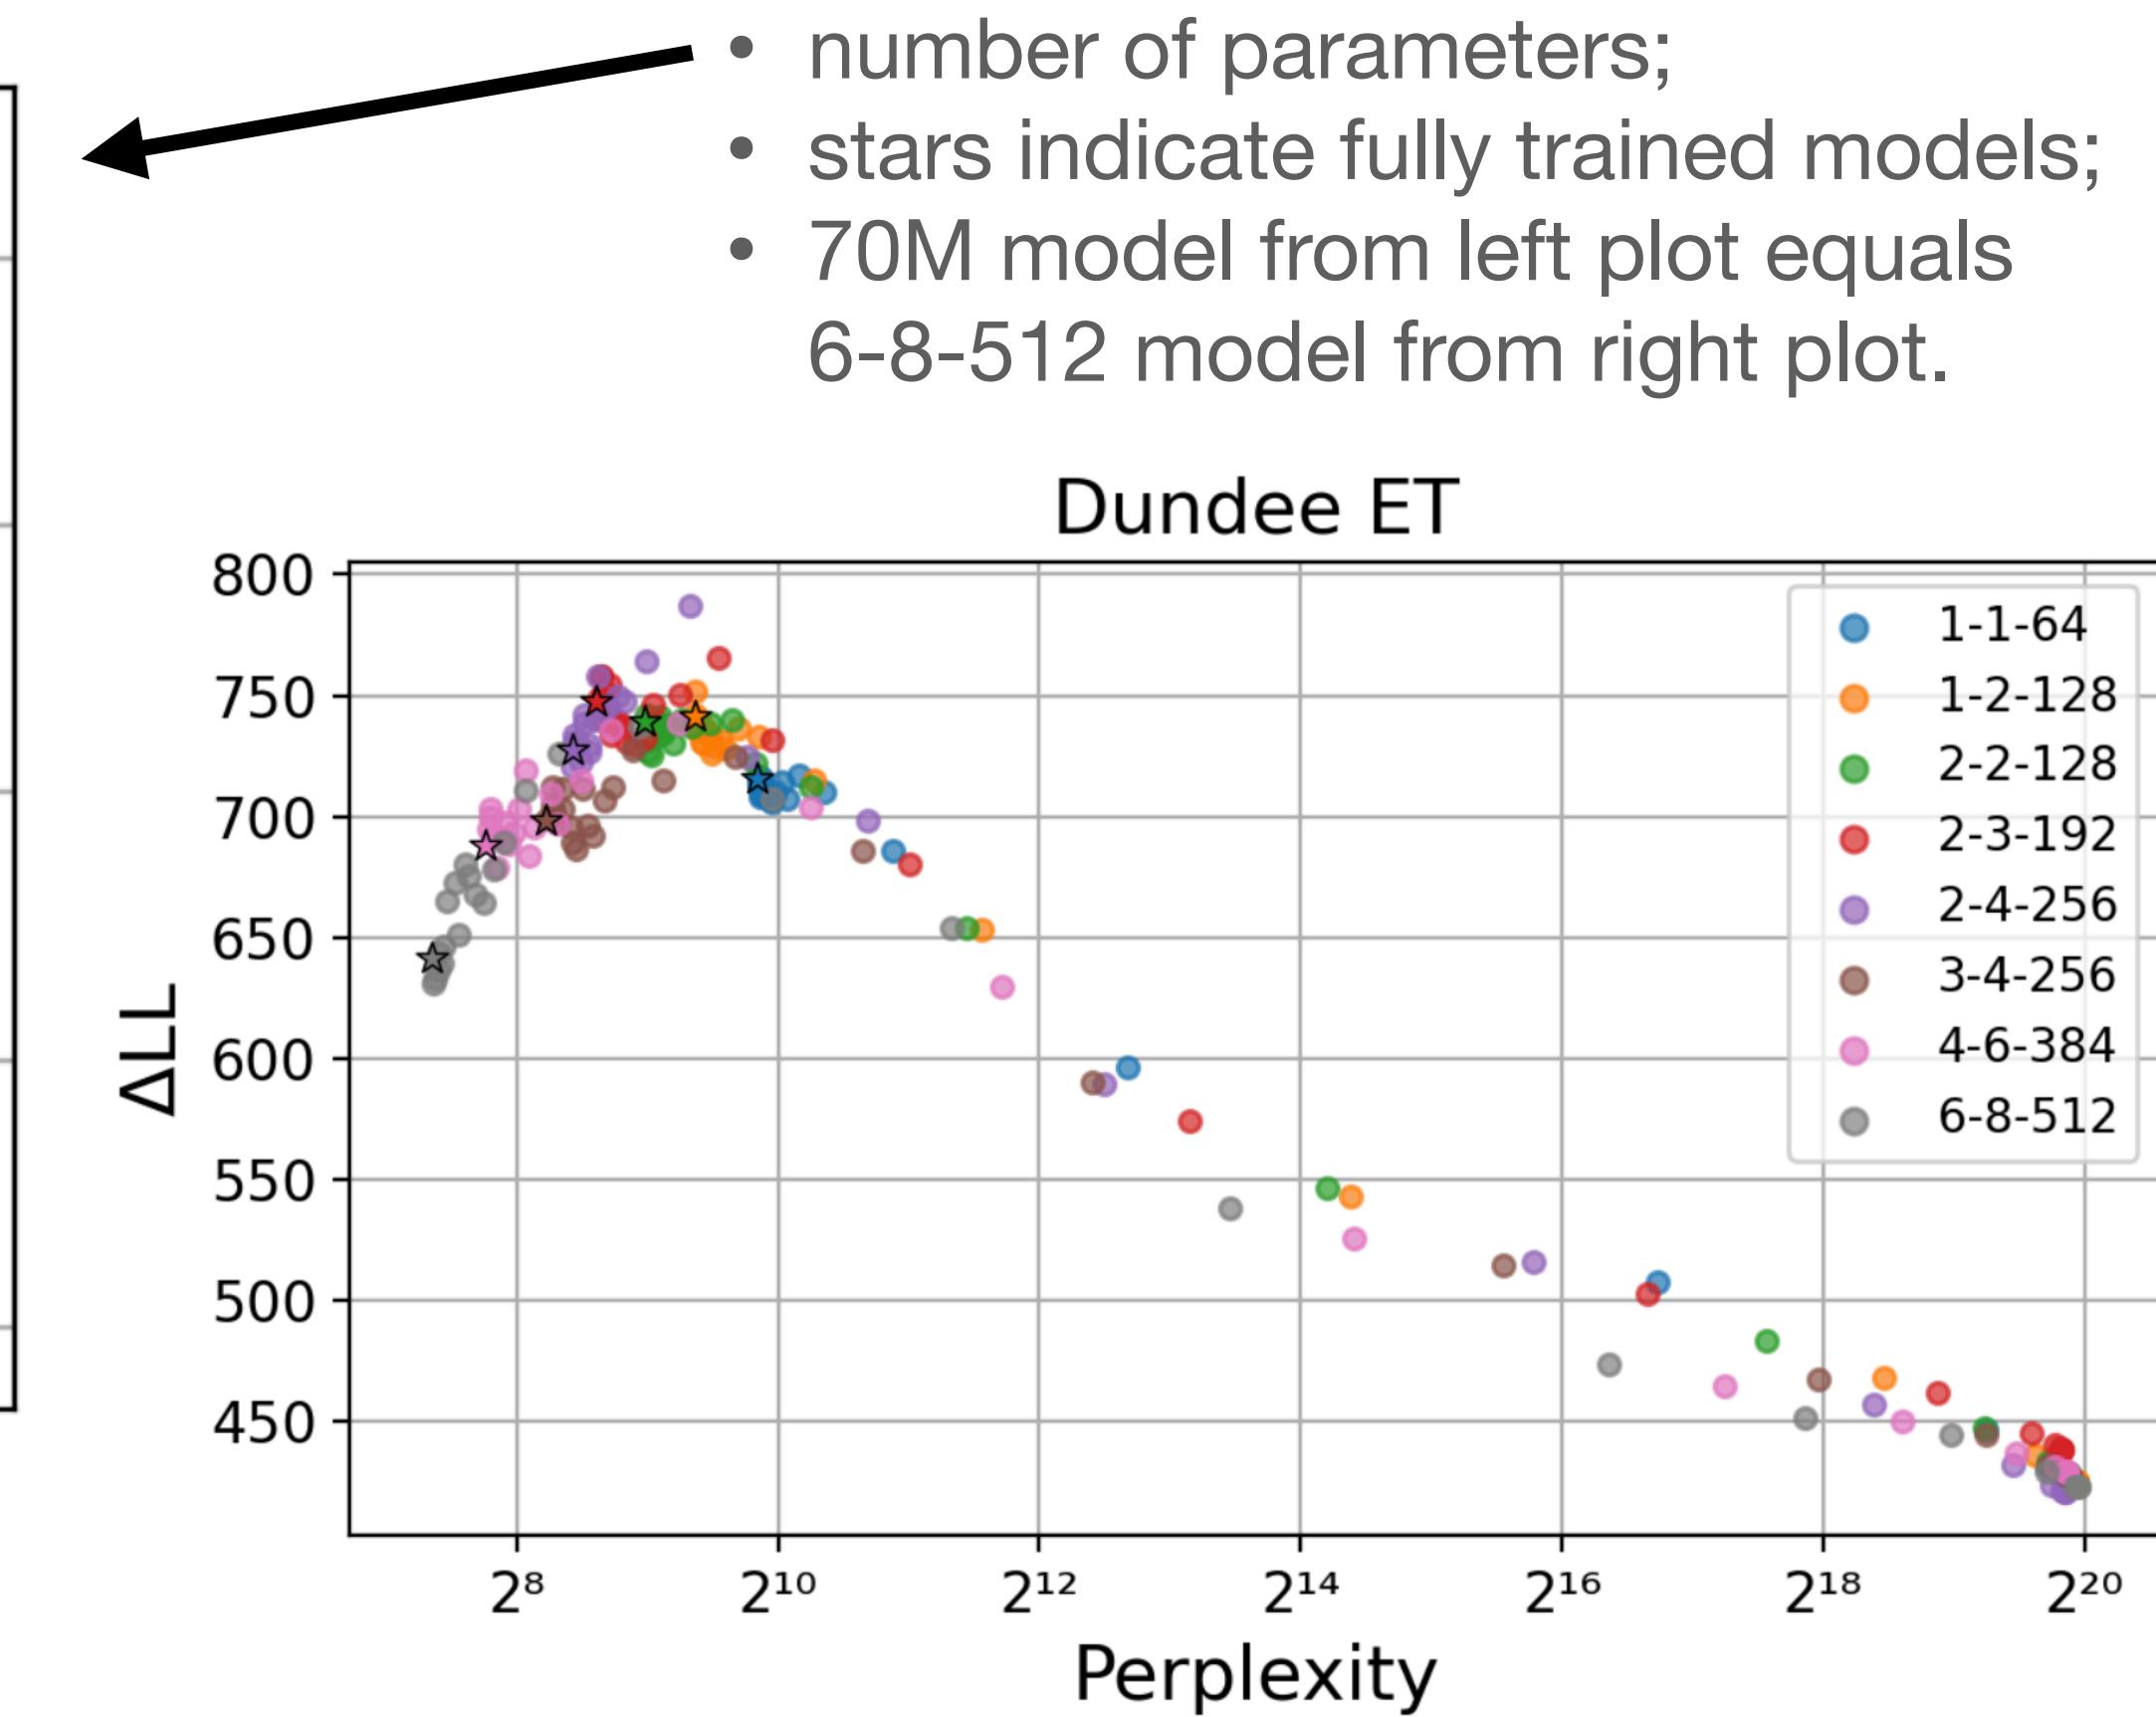
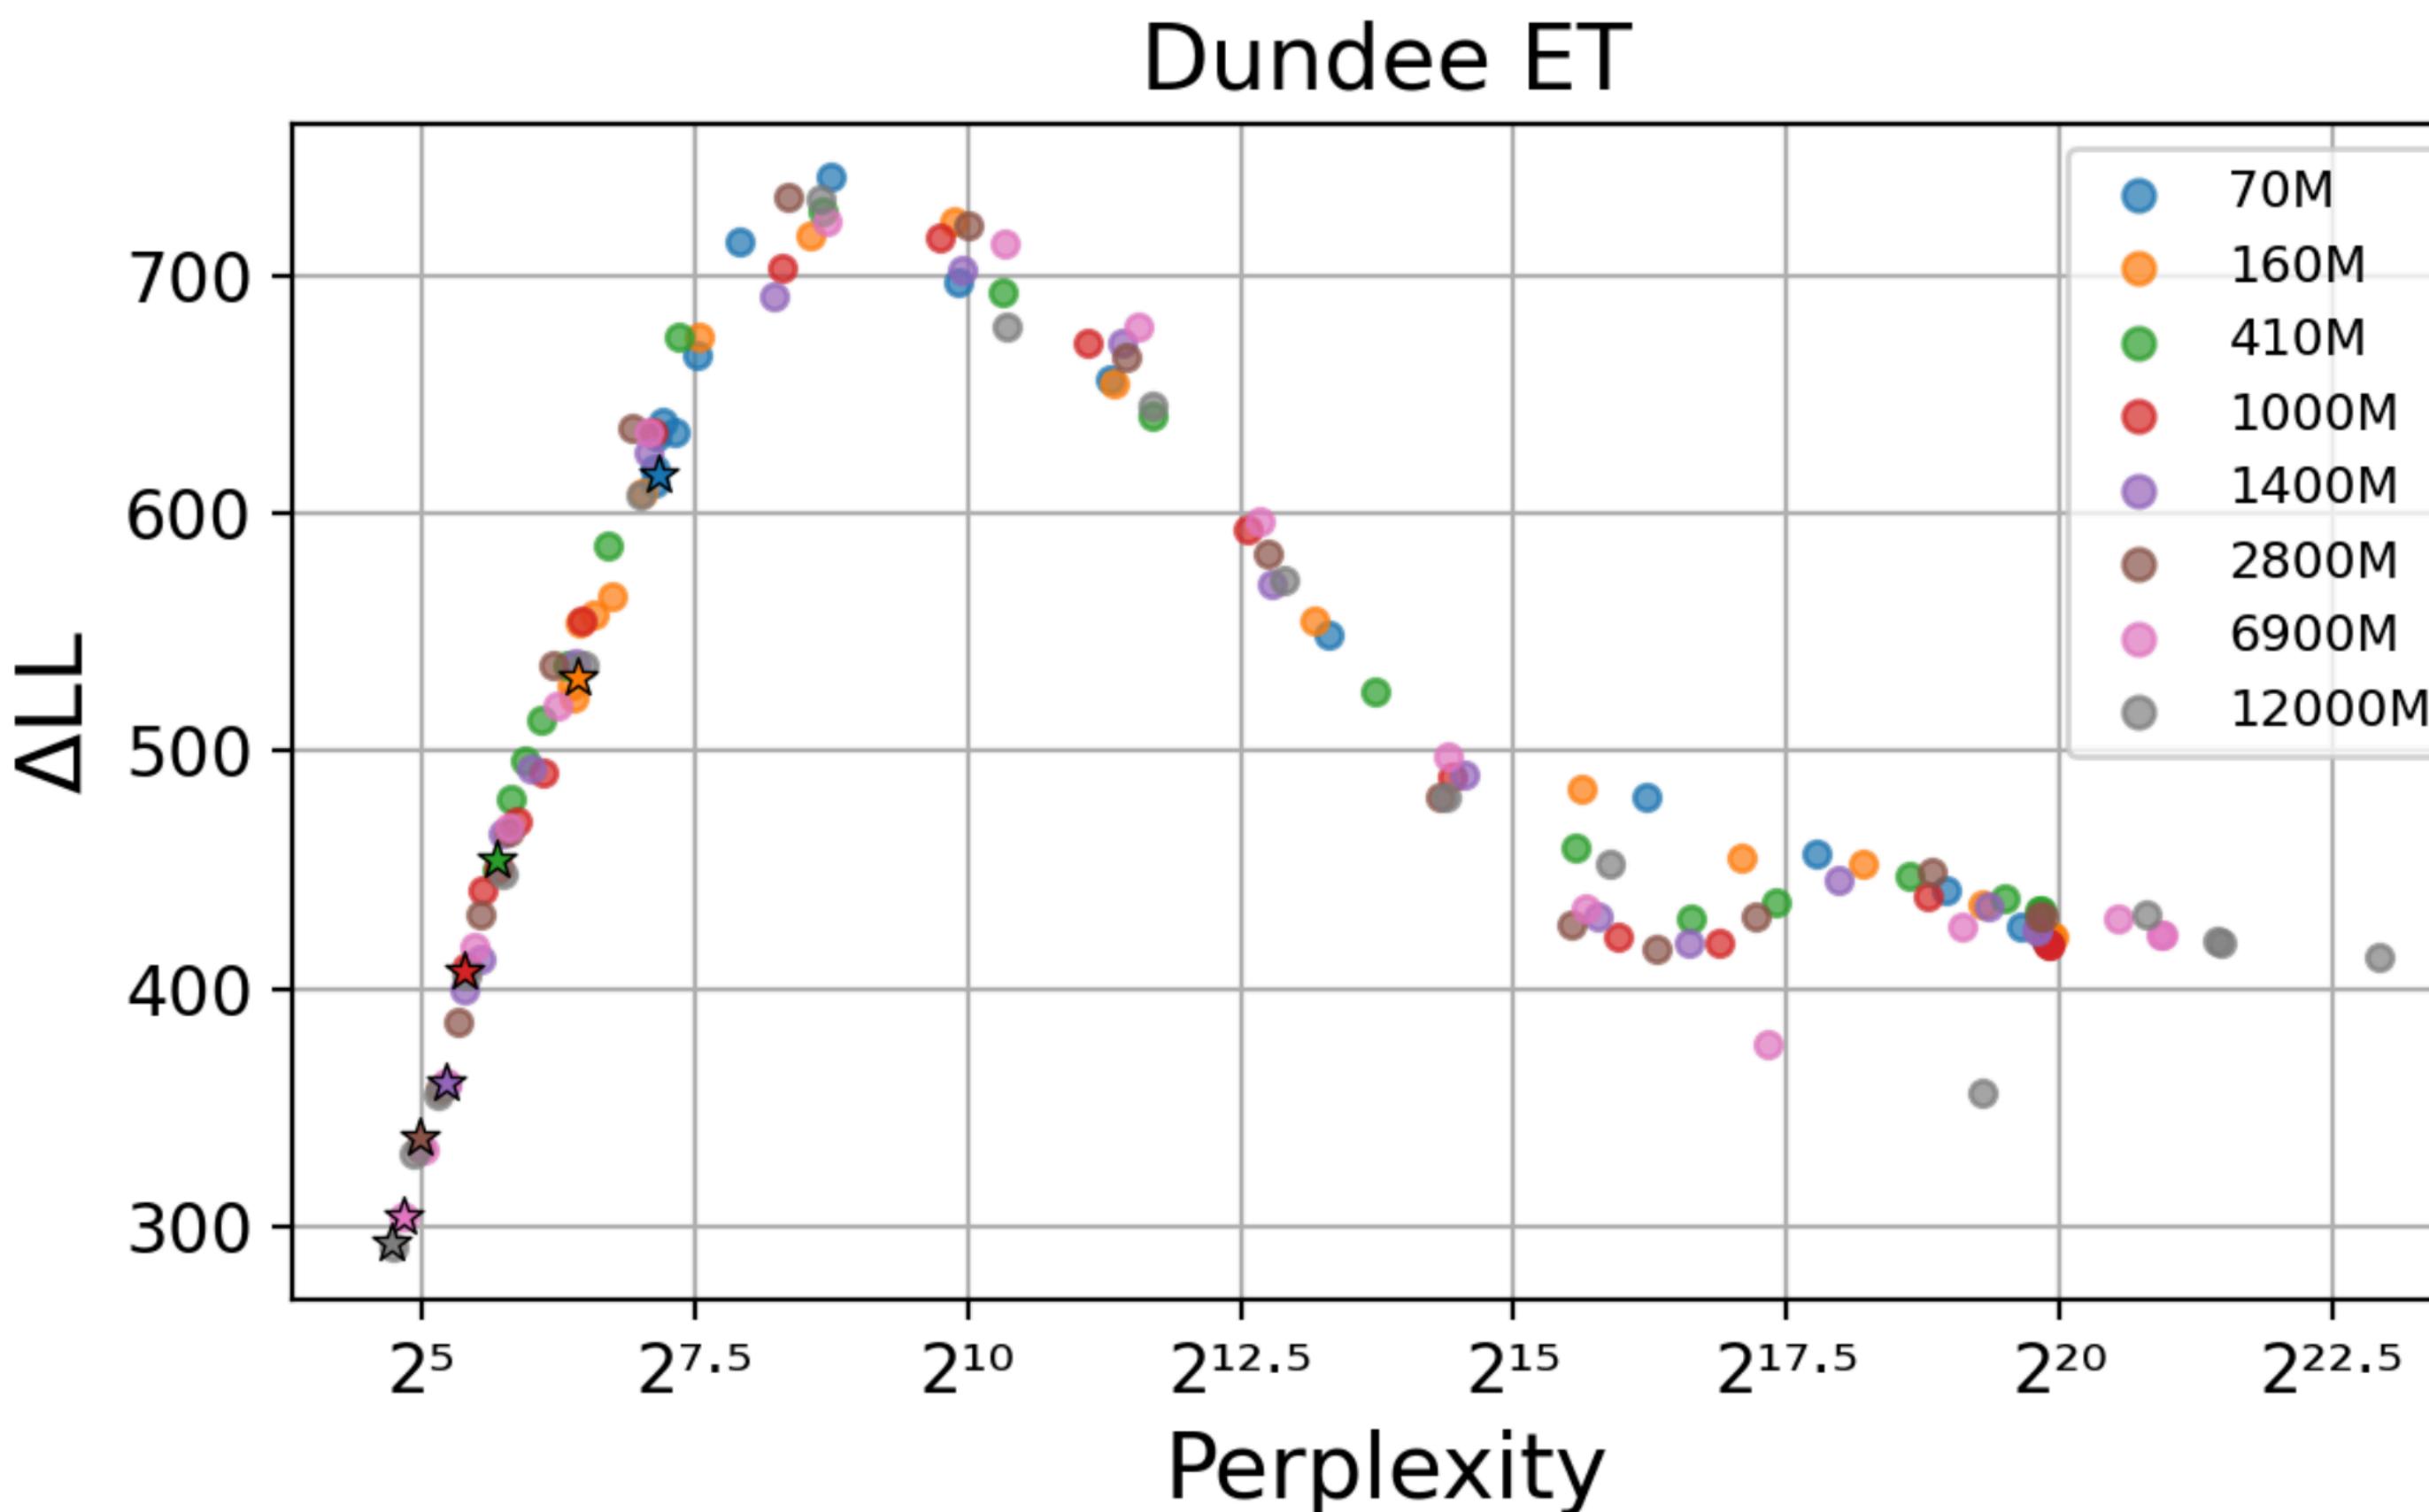
Better language models are typically also better at predicting psychometric measures.



Graph from Monsalve et al., 2012

Recent Findings on LLMs

Better language models are NOT necessarily better at predicting psychometric measures – there seems to be a sweet spot (Kuribayashi et al, 2021; Oh and Schuler, 2023).



What does this mean?

Transformers work differently from humans in language processing

- they may miss some world-knowledge related predictability effects
 - they are better at storing prior context verbatim
 - have read A LOT more texts than humans can ever read in their lifetime, which may lead to underestimates of reading times on e.g., named entities (Oh and Schuler, 2023)
 - or, maybe, our assumptions of a linear relationship between surprisal and human reading times are wrong.
- We should rather estimate models that fit humans / human experience better.
- To what extent does the language model match the readers and their background knowledge? → **Unexplored as of yet**

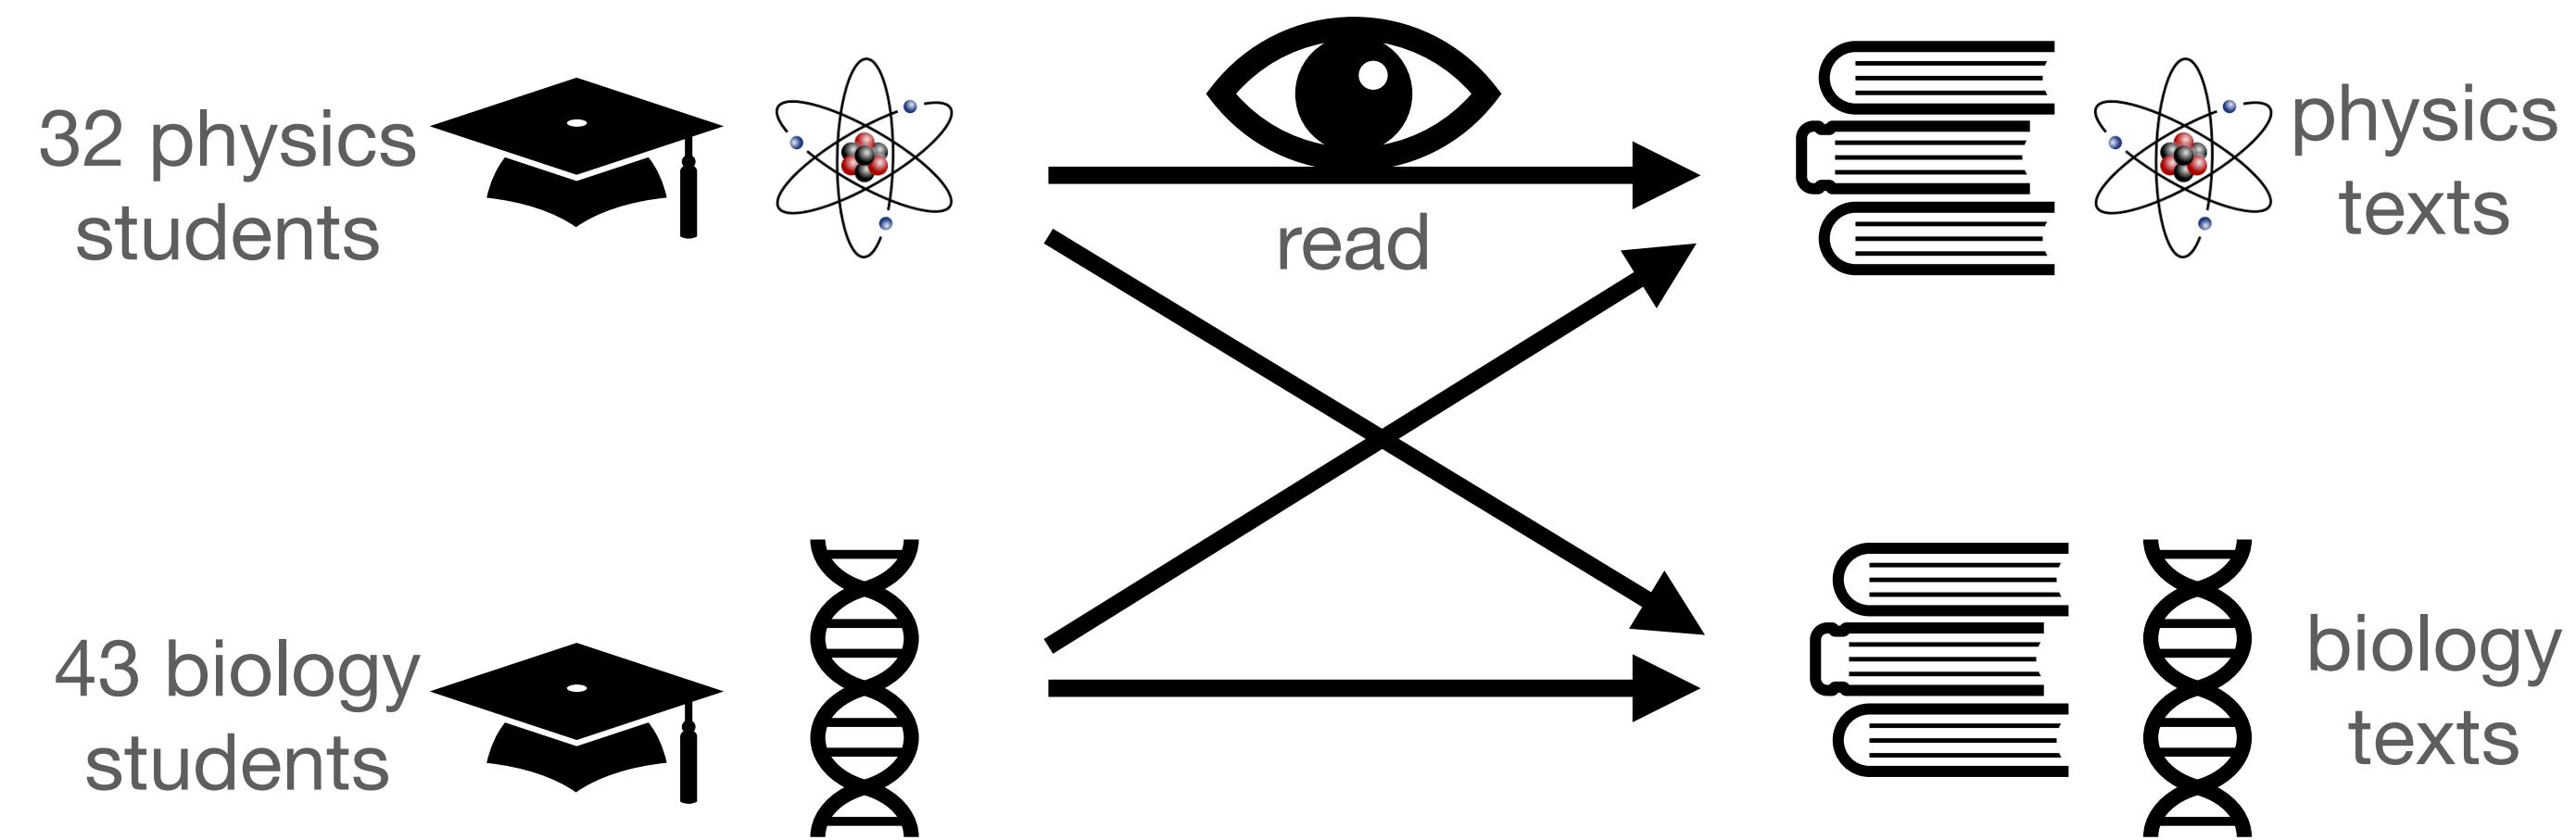
Reading data: POTECH corpus



POTECH corpus (Jäger et al., 2021): Scientific text with technical terms

Um das Vorhandensein der Polymerasekettenreaktion-Produkte feststellen zu können, verwendet man die Gelelektrophorese mit einer anschließenden Behandlung des Gels durch Ethidiumbromid. ...

Eye-tracking dataset: POTEc



- Terminology annotation: common and technical terms

Um das Vorhandensein der Polymerasekettenreaktion-Produkte feststellen zu können, verwendet man die Gelelektrophorese

Same text, different readers



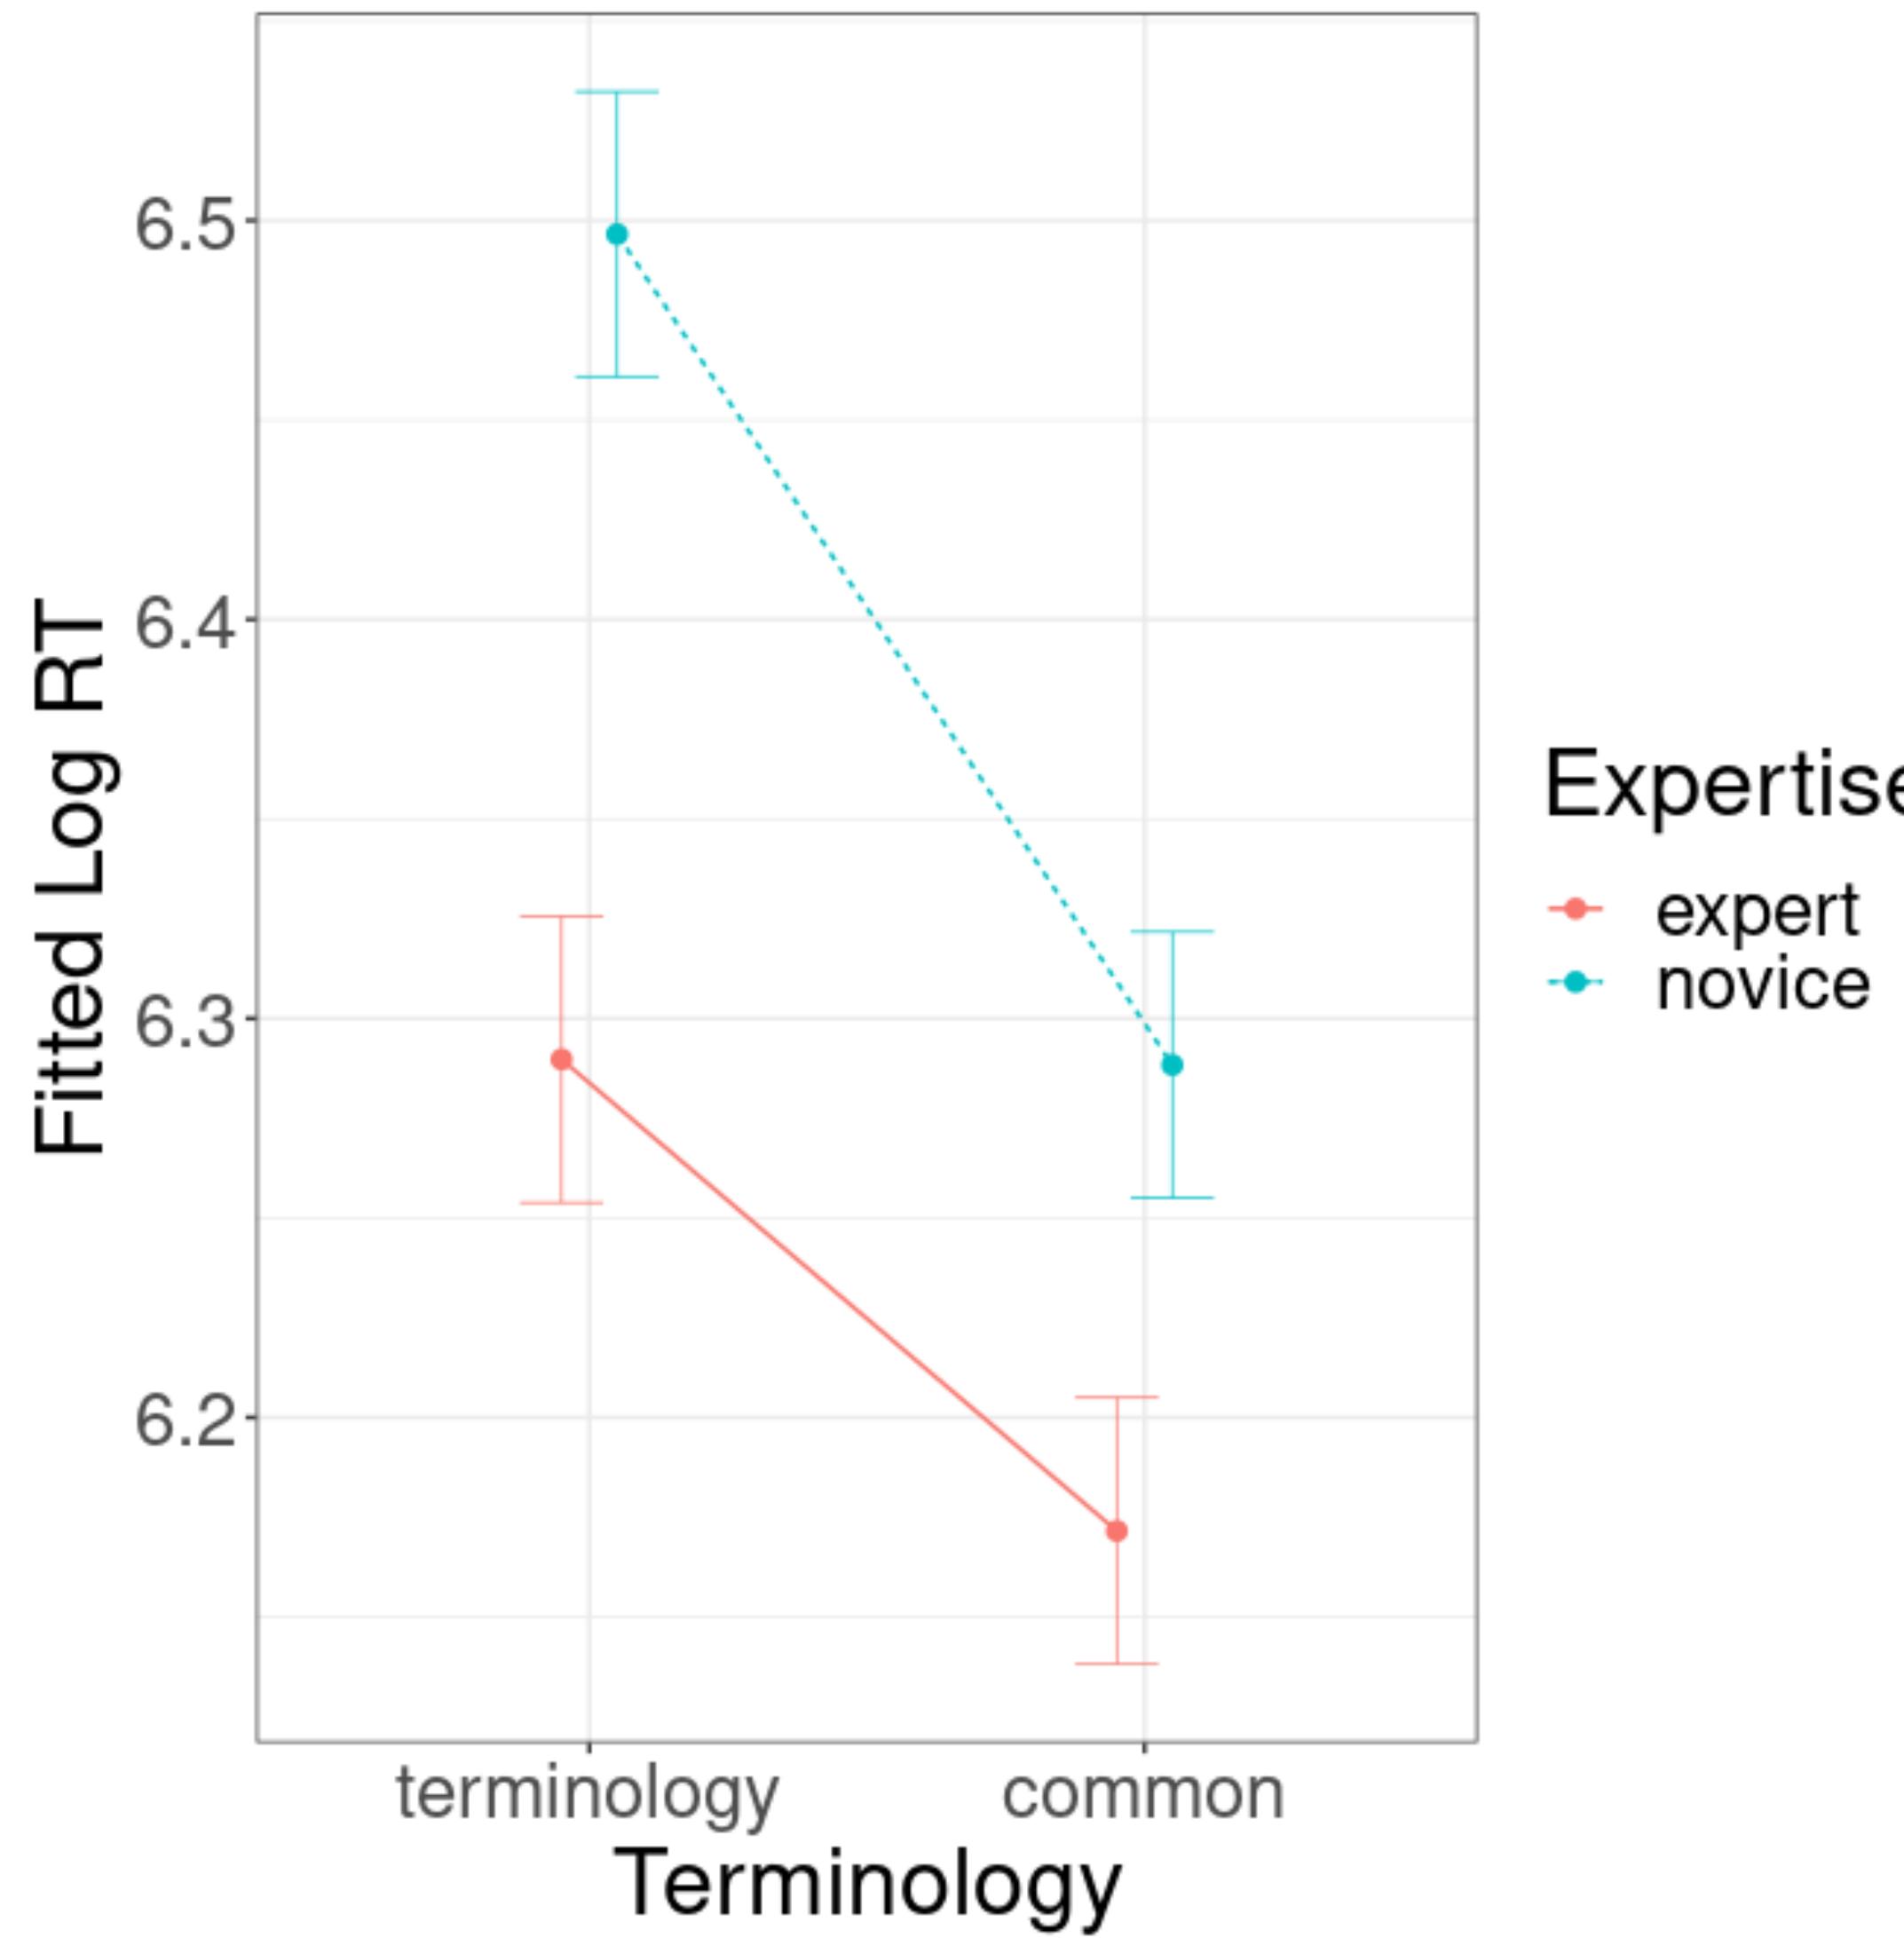
Expert in biology

Um das Vorhandensein der Polymerasekettenreaktion-Produkte festzustellen zu können, verwendet man die Gelektrophorese mit einer anschließenden Behandlung des Gels durch Ethidiumbromid. ...

Novice in biology

Um das Vorhandensein der Polymerasekettenreaktion-Produkte festzustellen zu können, verwendet man die Gelektrophorese mit einer anschließenden Behandlung des Gels durch Ethidiumbromid. ...

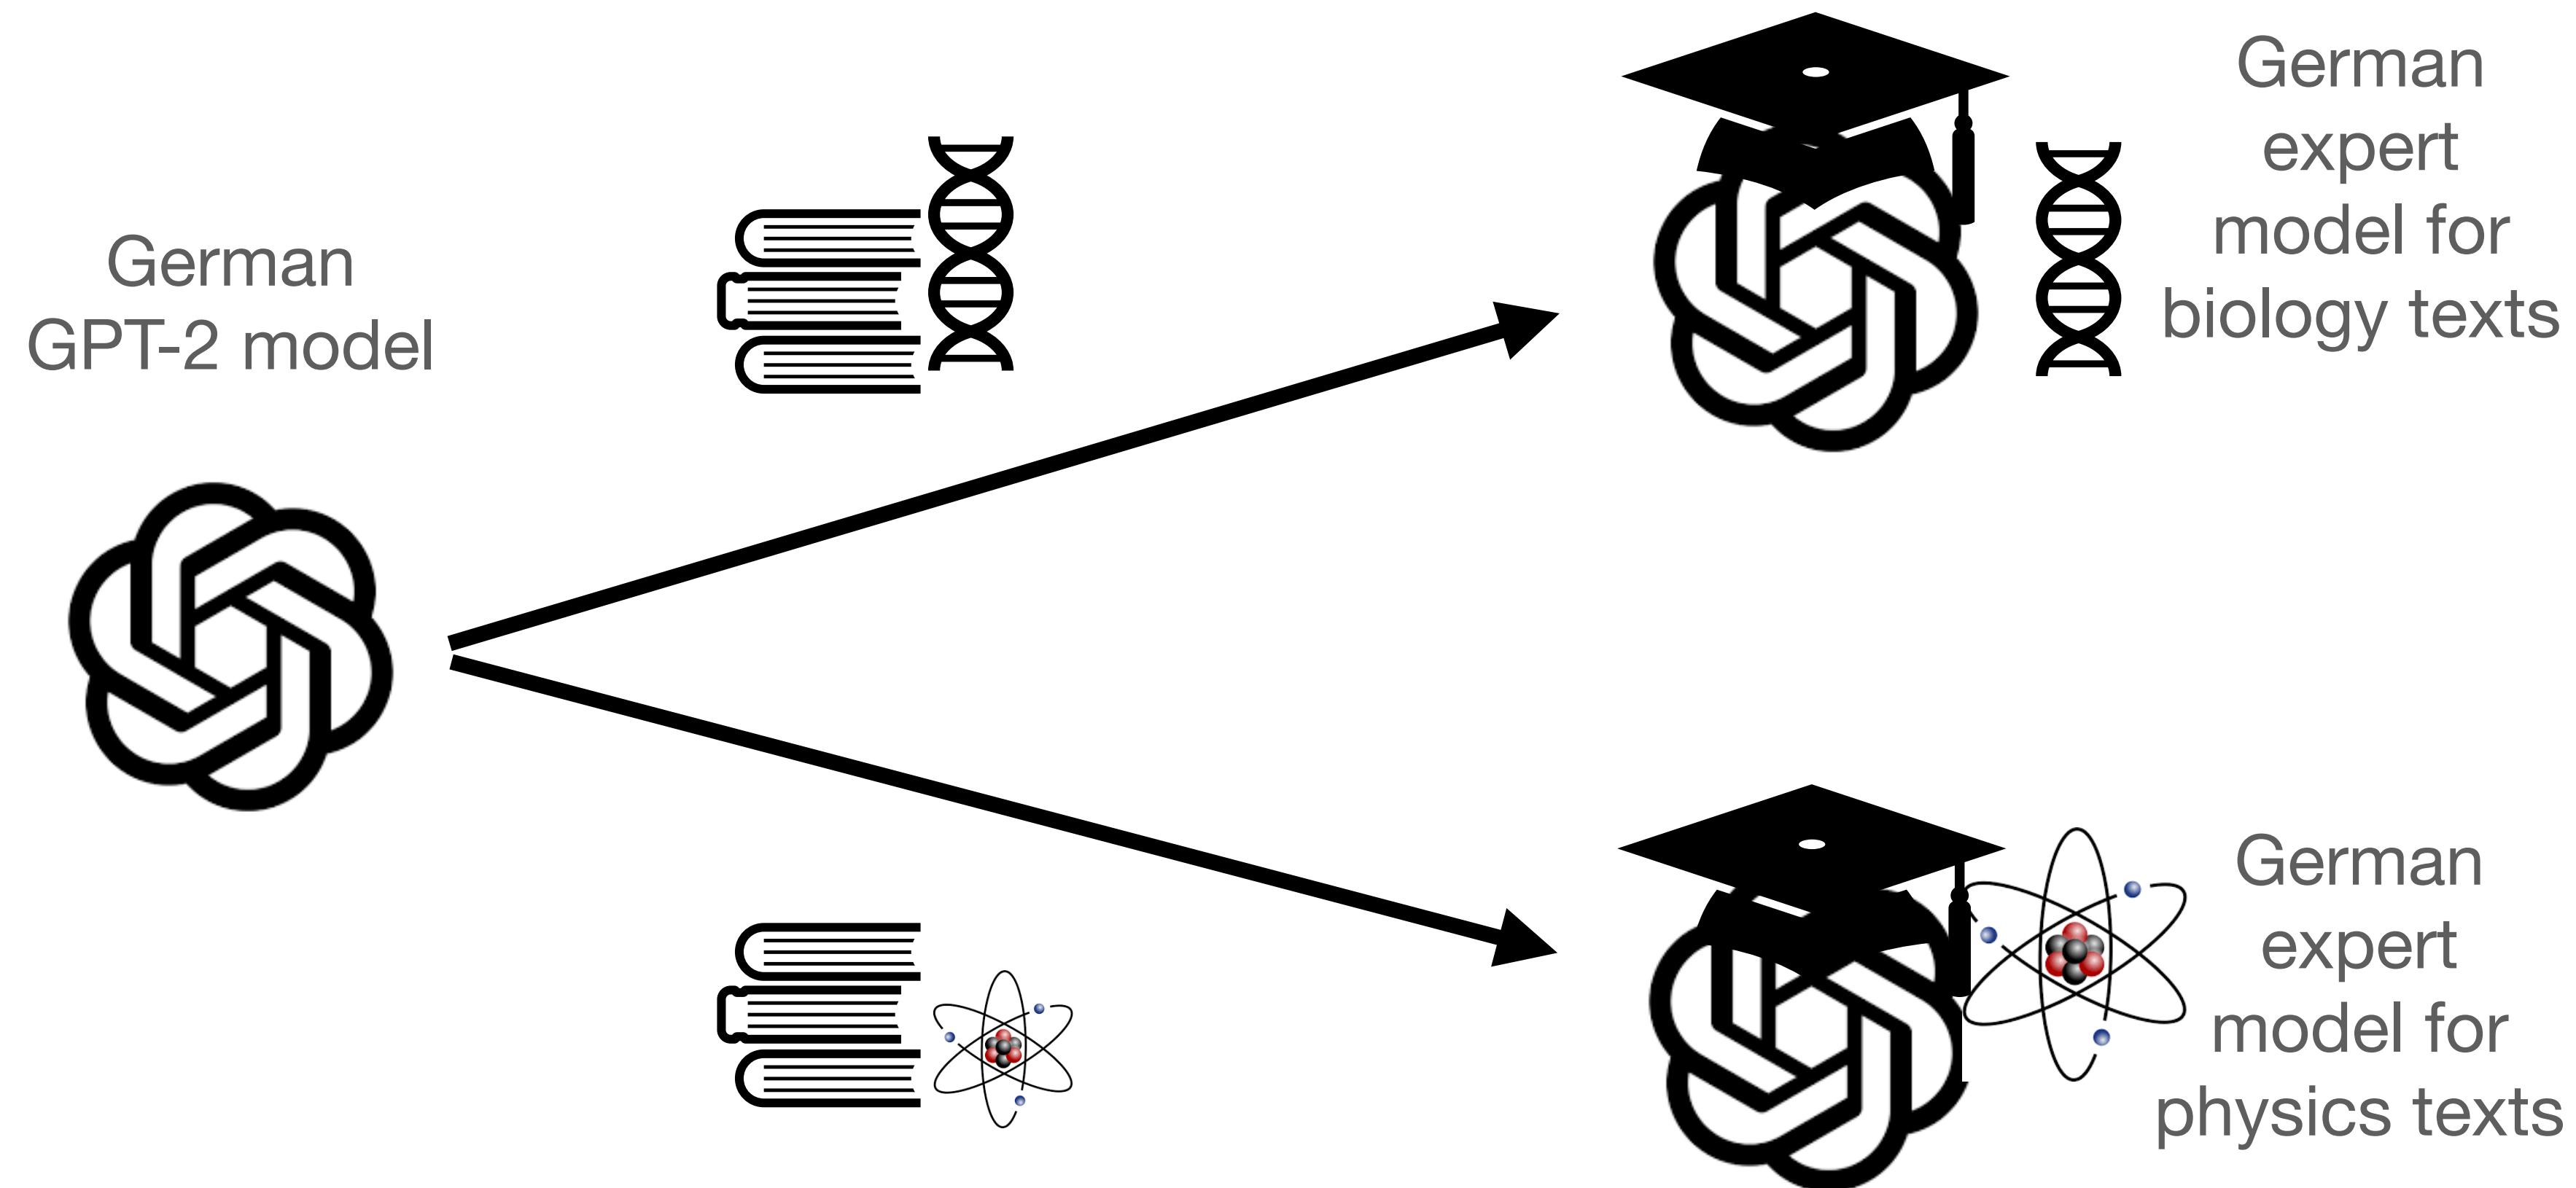
Effect of expertise



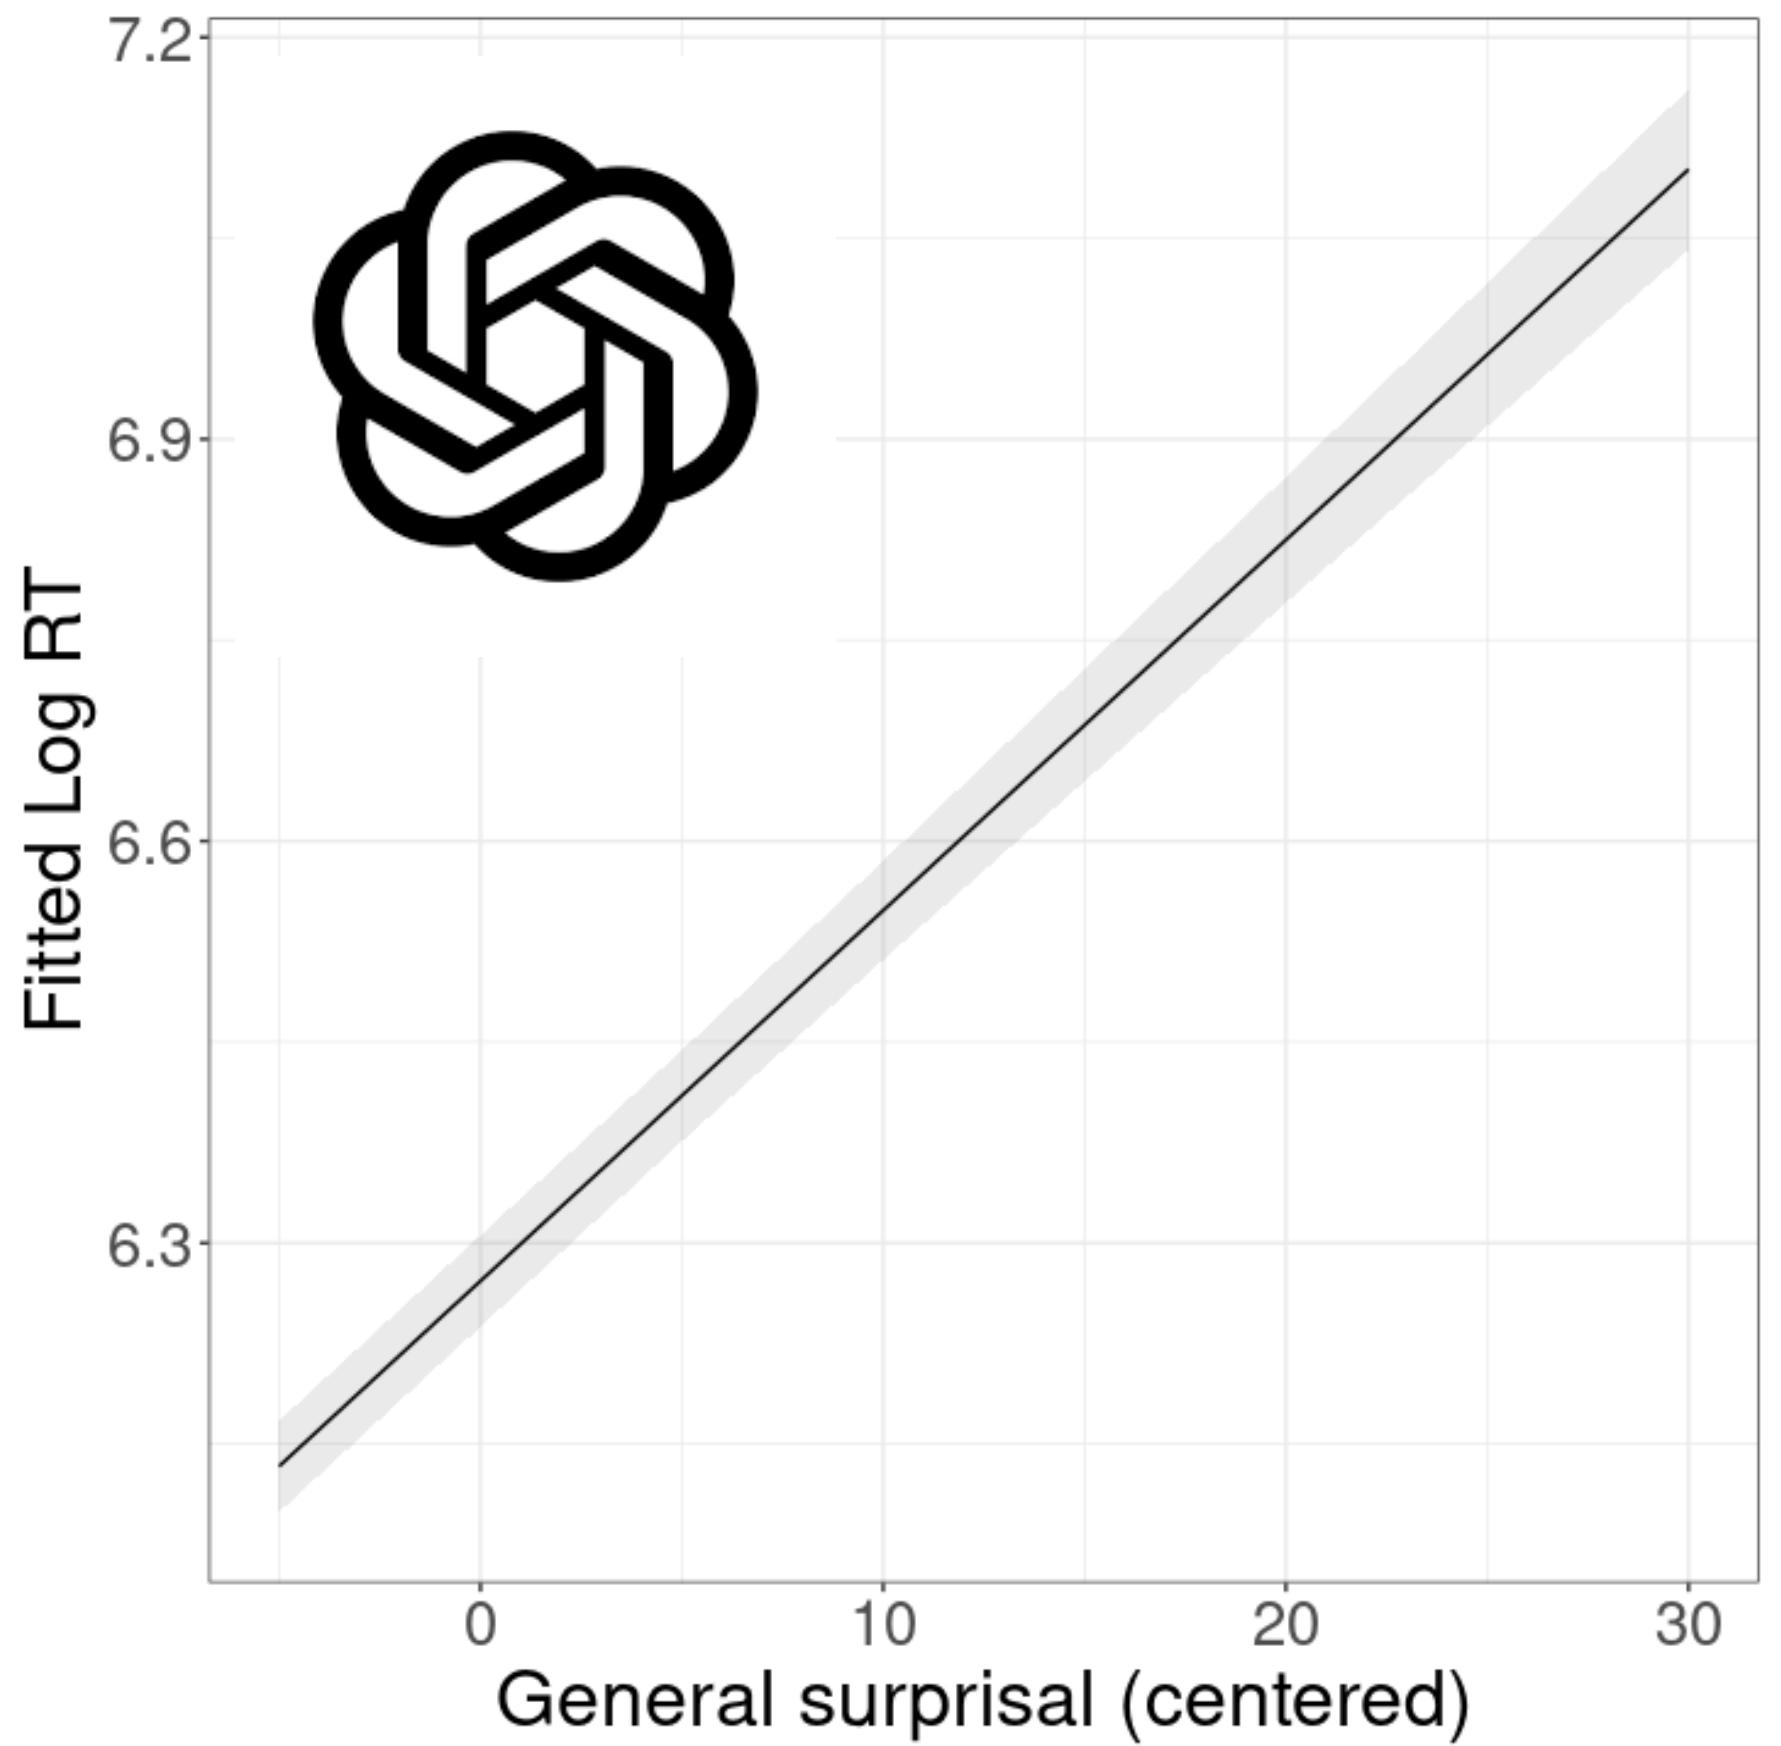
- Experts read faster than novices
- Terminology is read more slowly than common words
- There is a significant interaction such that novices have less of a terminology “penalty”.

Skrjanec, Broy and Demberg, 2023

General & expert models

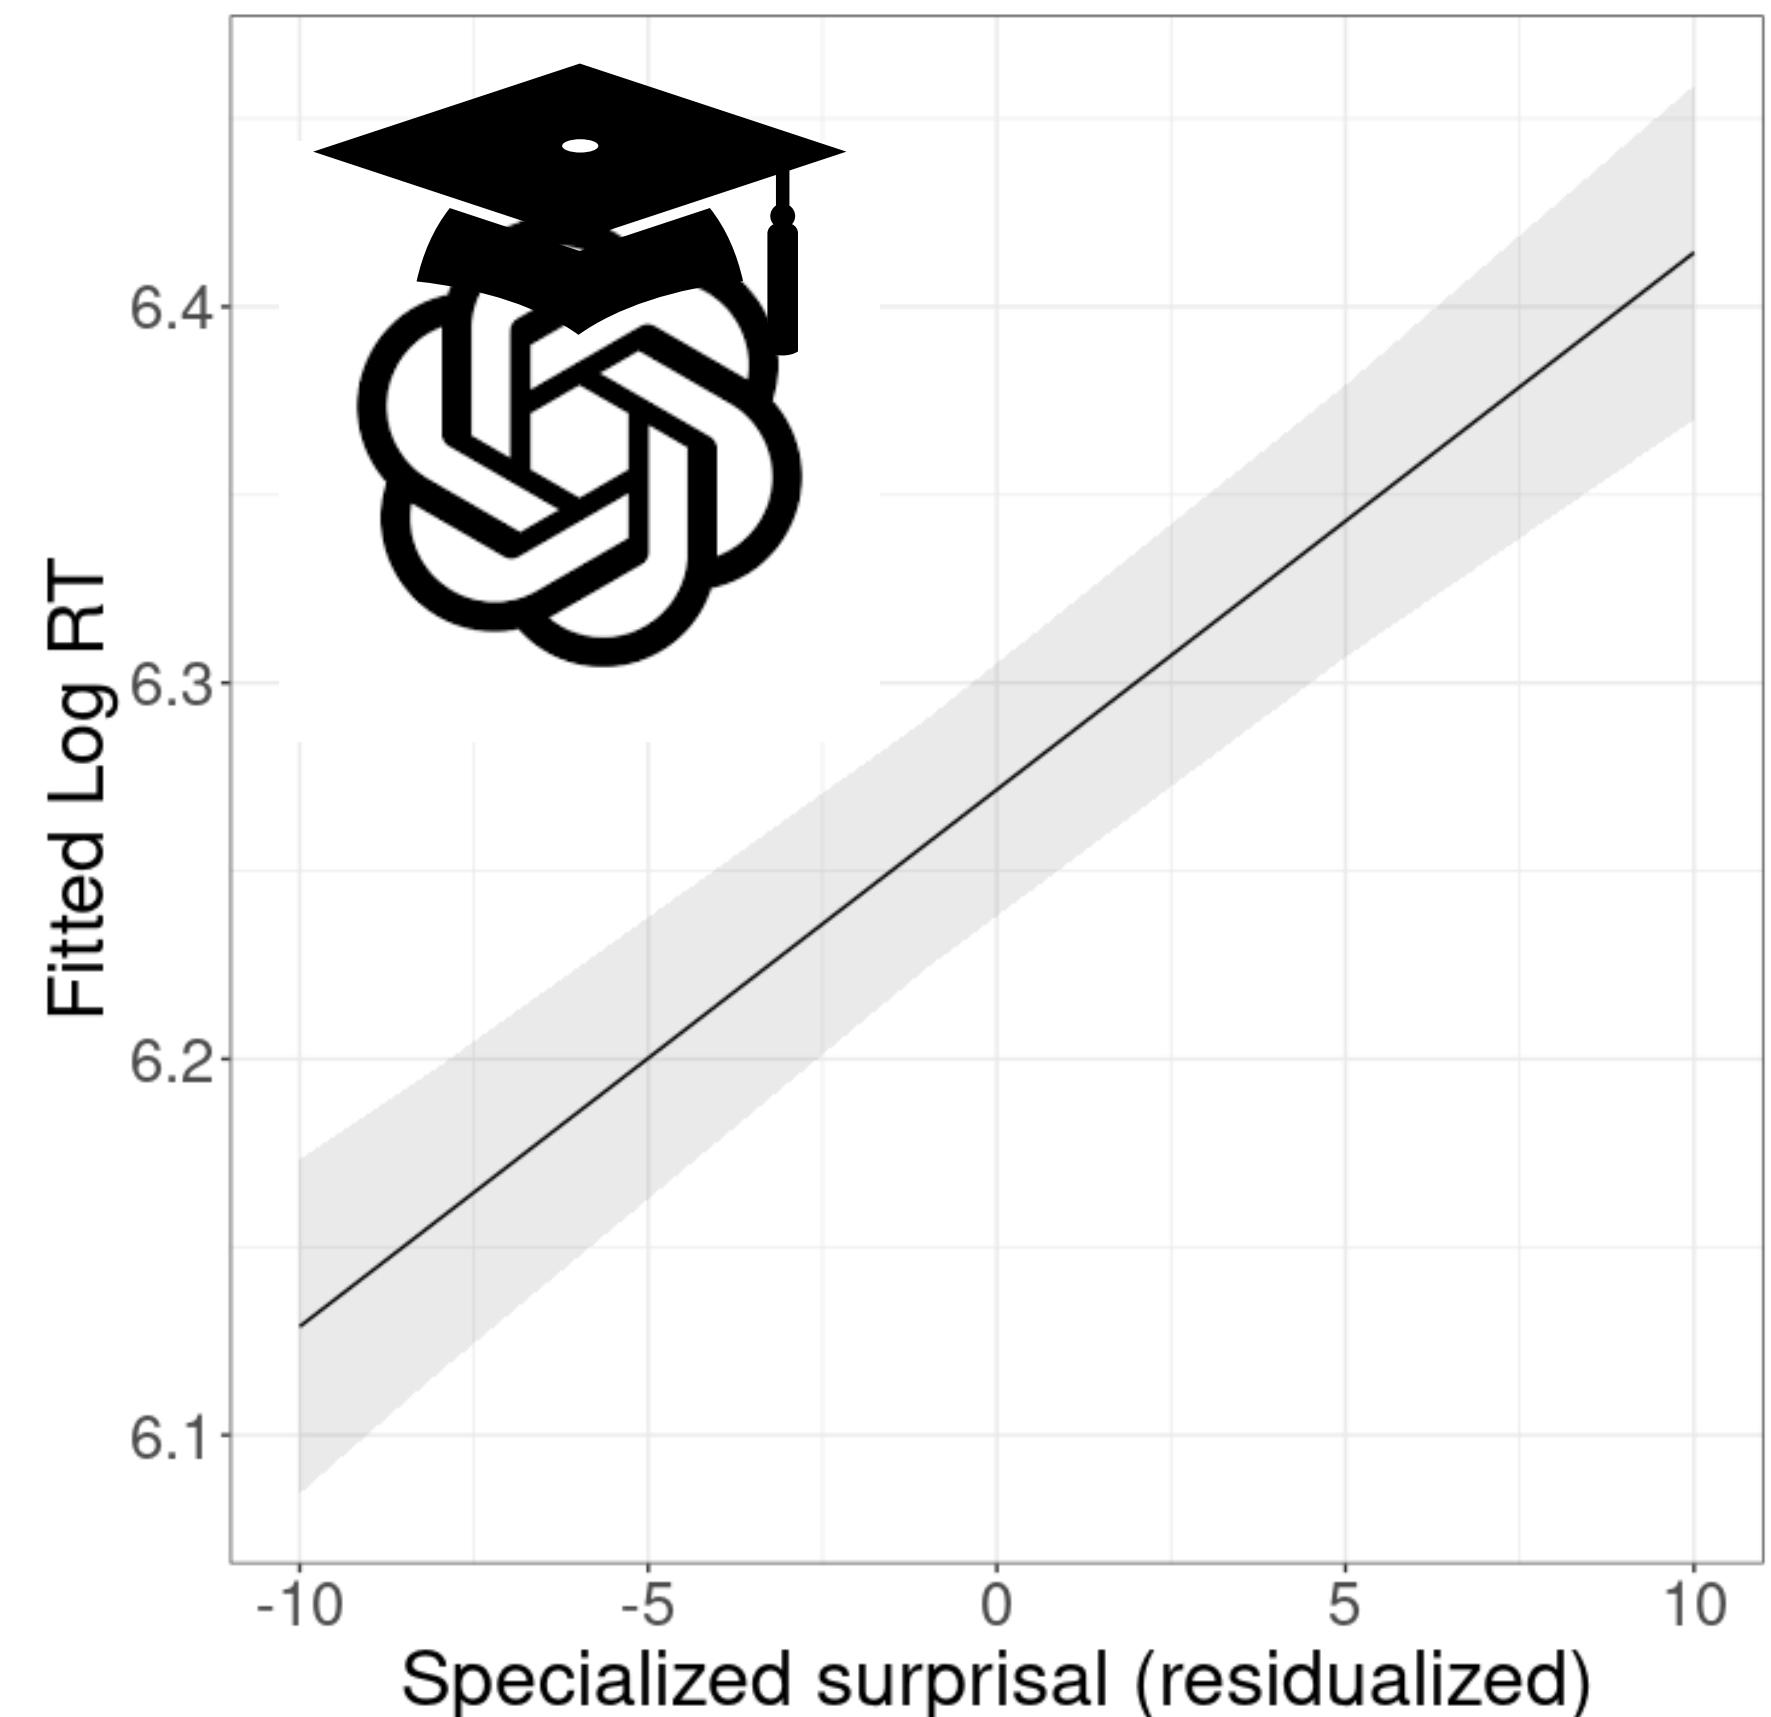


Performance of surprisal models



Surprisal estimates from a LM are predictive of reading times.

An “expert” model further trained on in-domain texts predicts expert reading times more accurately than a non-expert model.



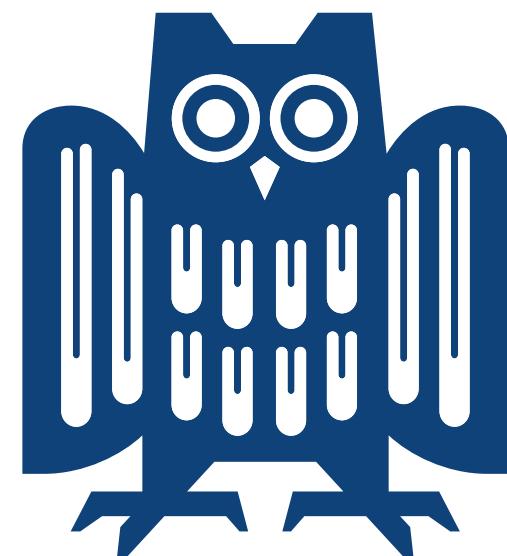
Skrjanec, Broy and Demberg, 2023

Zusammenfassung

- Noisy channel model besagt, dass Hörer bottom-up Information aus Signal mit top-down Kontexterwartungen rational kombinieren.
- Diese Vorhersagen werden durch experimentelle Daten bestätigt.
- Sprecher richten Wortwahl nach kontextueller Erwartbarkeit aus.
=> Sprachwandel
- Sprachmodelle zur Abschätzung der Wahrscheinlichkeiten sollten mit Bedacht ausgewählt werden; evtl. an den Leser angepasst werden.

vielen Dank für Ihre Aufmerksamkeit!

vielen Dank an die beteiligten Mitarbeiter / Koautoren:
Marjolein van Os, Jia Loy, Katja Kravtchenko, Iza Skrjanec,
Anupama Chingacham, Alessandra Zarcone.



UNIVERSITÄT
DES
SAARLANDES

