

Challenges and Strategies in Cross-Cultural NLP

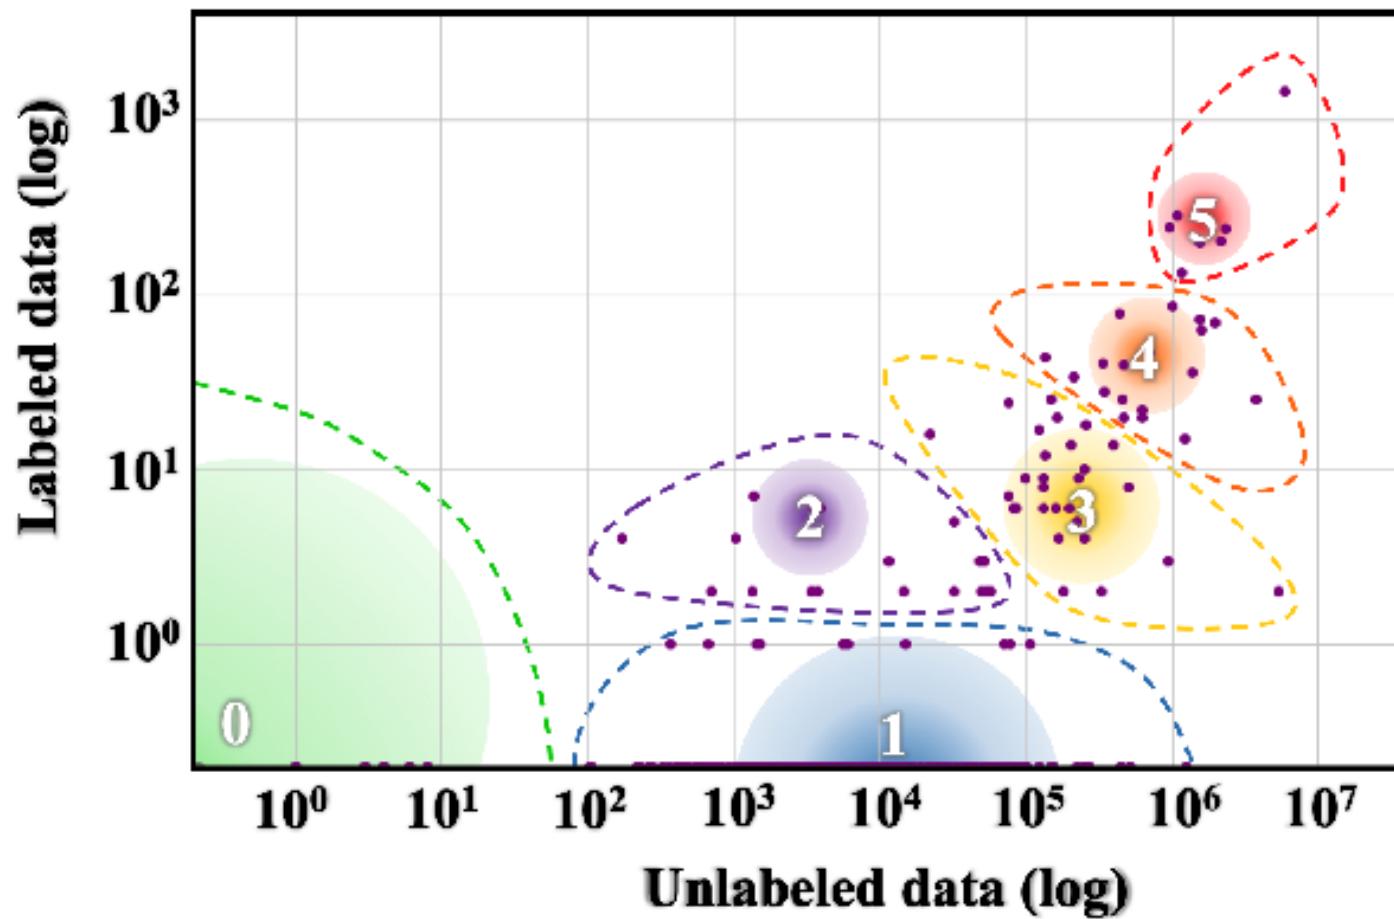
Daniel Hershcovich, Stella Frank, Heather Lent, Miryam de Lhoneux, Mostafa Abdou, Stephanie Brandl, Emanuele Bugliarello, Laura Cabello Piqueras, Ilias Chalkidis, Ruixiang Cui, Constanza Fierro, Katerina Margatina, Phillip Rust and Anders Søgaard

ACL 2022

UNIVERSITY OF COPENHAGEN



Resource disparity for languages



The State and Fate of Linguistic Diversity and Inclusion in the NLP World
(Joshi et al., ACL 2020)

Social factors

NLP is for people (not just languages)



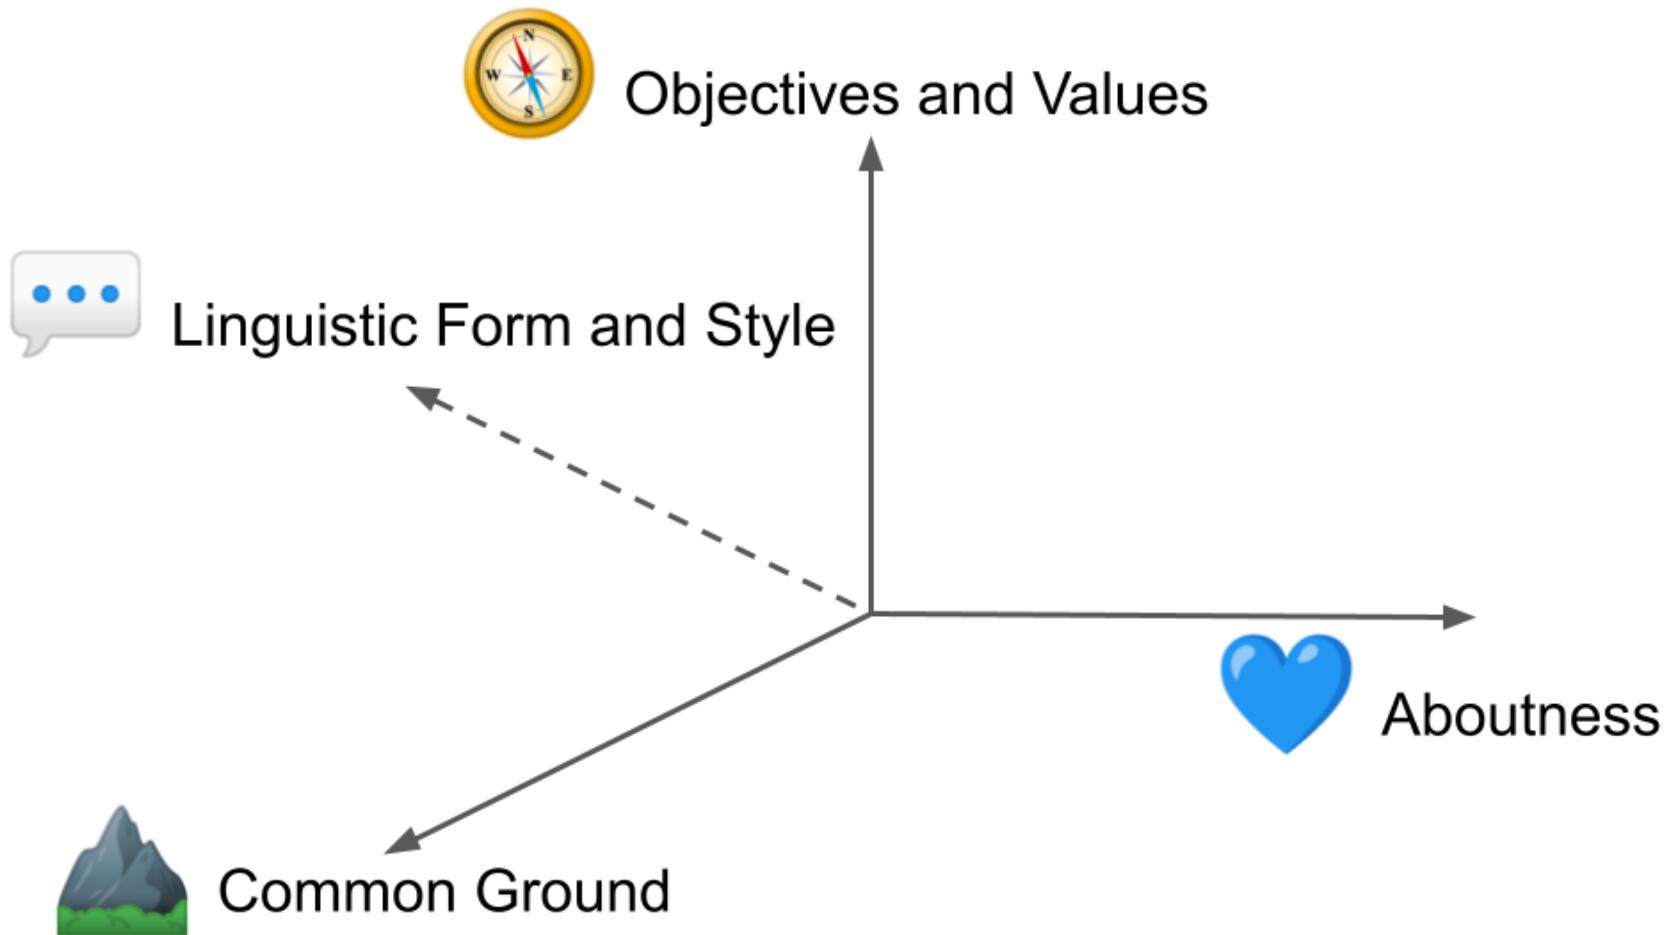
The Importance of Modeling Social Factors of Language: Theory and Practice
(Hovy & Yang, NAACL 2021)

Social bias in language models

Models	Demographics Alignment															
bert-base-cased	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
bert-base-uncased	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
bert-base-multilingual-cased	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
bert-large-cased	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
bert-large-uncased	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
distilbert-base-uncased	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
albert-base-v2	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
albert-large-v2	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
albert-xxlarge-v2	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
roberta-base	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
roberta-large	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
google/electra-large-generator	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
google/electra-small-generator	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
gpt2	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
gpt2-medium	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
gpt2-large	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
gpt2-xl	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
Group	以人为中心的	中性的	种族主义的	性别平等的	中性的	中性的	中性的	中性的	中性的							
Mean Rank	3.1	3.4	4.0	6.1	6.1	8.1	8.1	9.2	9.8	9.9	10.3	10.3	10.8	11.1	12.0	13.8

Sociolectal Analysis of Pretrained Language Models
(Zhang et al., EMNLP 2021)

Dimensions of culture



Form

*How we express
ourselves in
language*

Morphosyntax

Word choice

Style

Style

Stylistic aspects of
linguistic form:

Directness

Formality

Politeness

Emotional expression

Levels of granularity

Linguistic and cultural variation within groups



Idiolect	Sociolect, dialect	Standardised language	Language, language family
Individual, personality	Social group or region, sub-culture	Country, national culture	International cultures

Common ground

Shared
knowledge based
on which people
reason and
communicate

Conceptualisation

Commonsense

Conceptualisation

Objects

Colours

Kinship

Space

Time

Events

Events and rituals



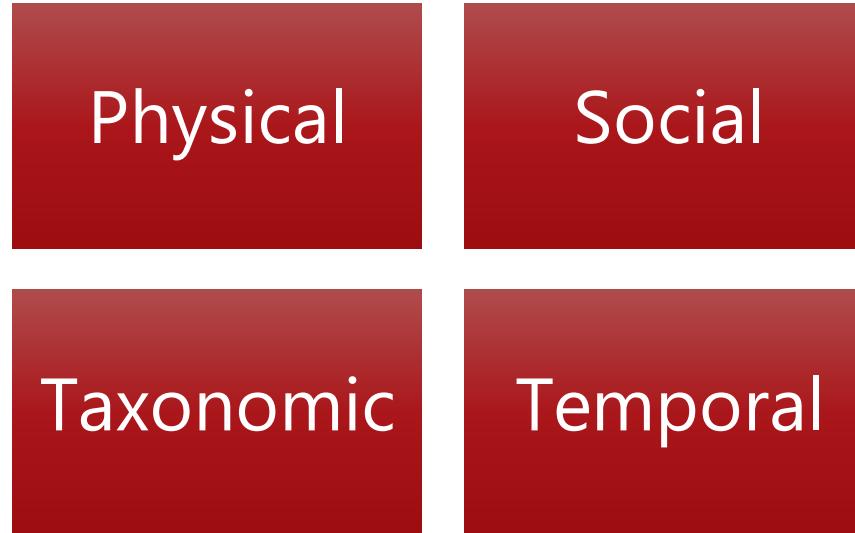
Tamil
ஜல்லிக்கட்டு
jallikattu

Visually Grounded Reasoning across Languages and Cultures

(Liu et al., EMNLP 2021)

Visual concepts include culture-specific activities that cannot be mapped across cultures.

Commonsense



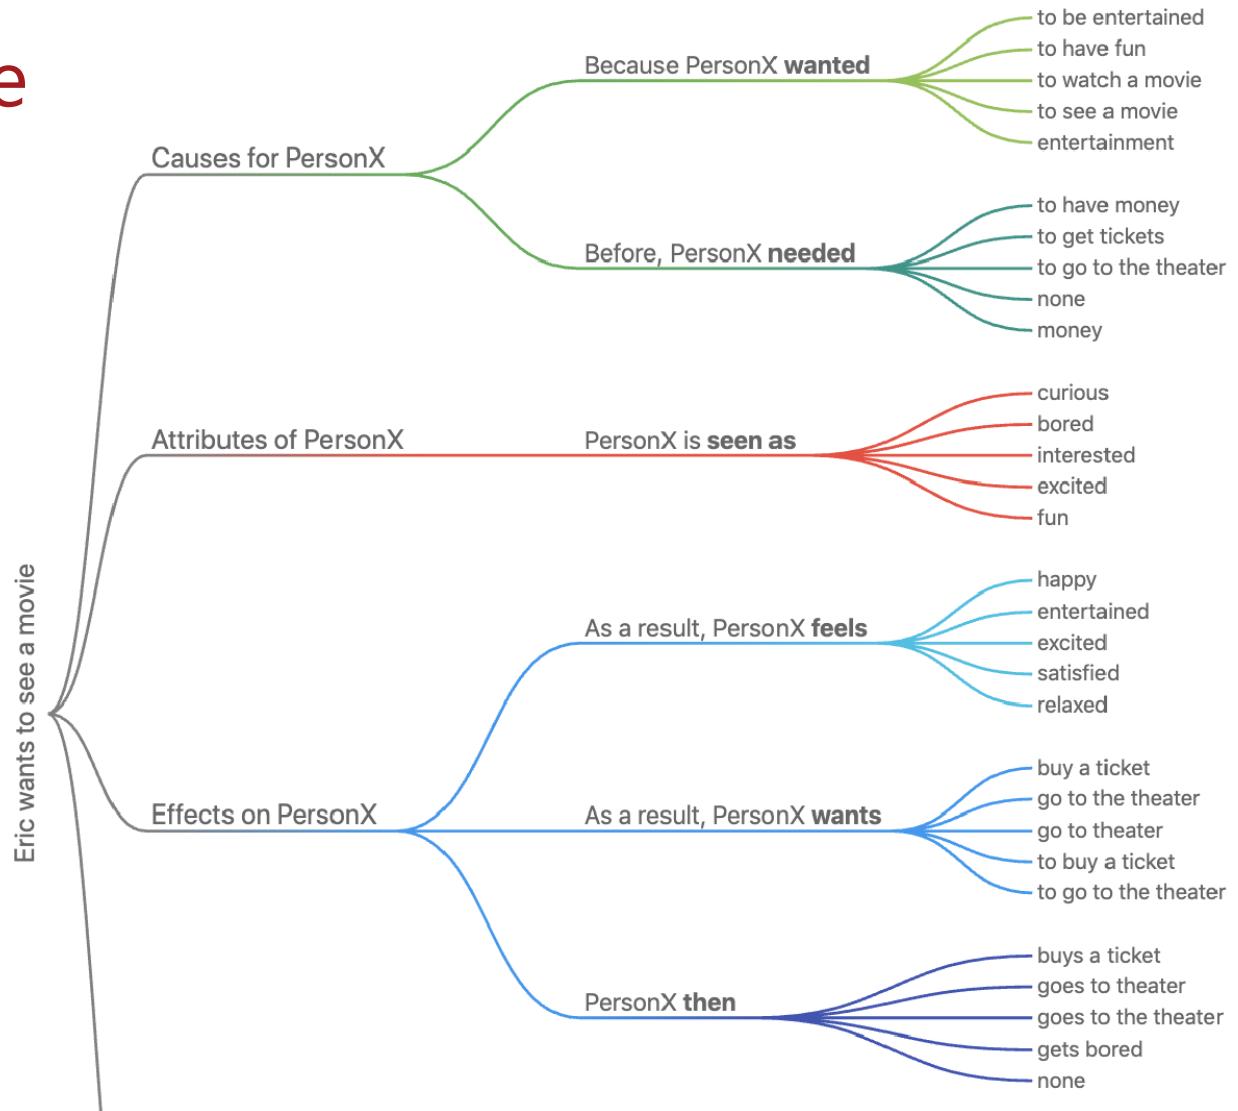
"Commonsense is the basic level of practical knowledge and reasoning concerning everyday situations and events that are commonly shared among most people."

Commonsense Reasoning for Natural Language Processing
(Sap et al., ACL 2020 Tutorial)

Culture-dependent

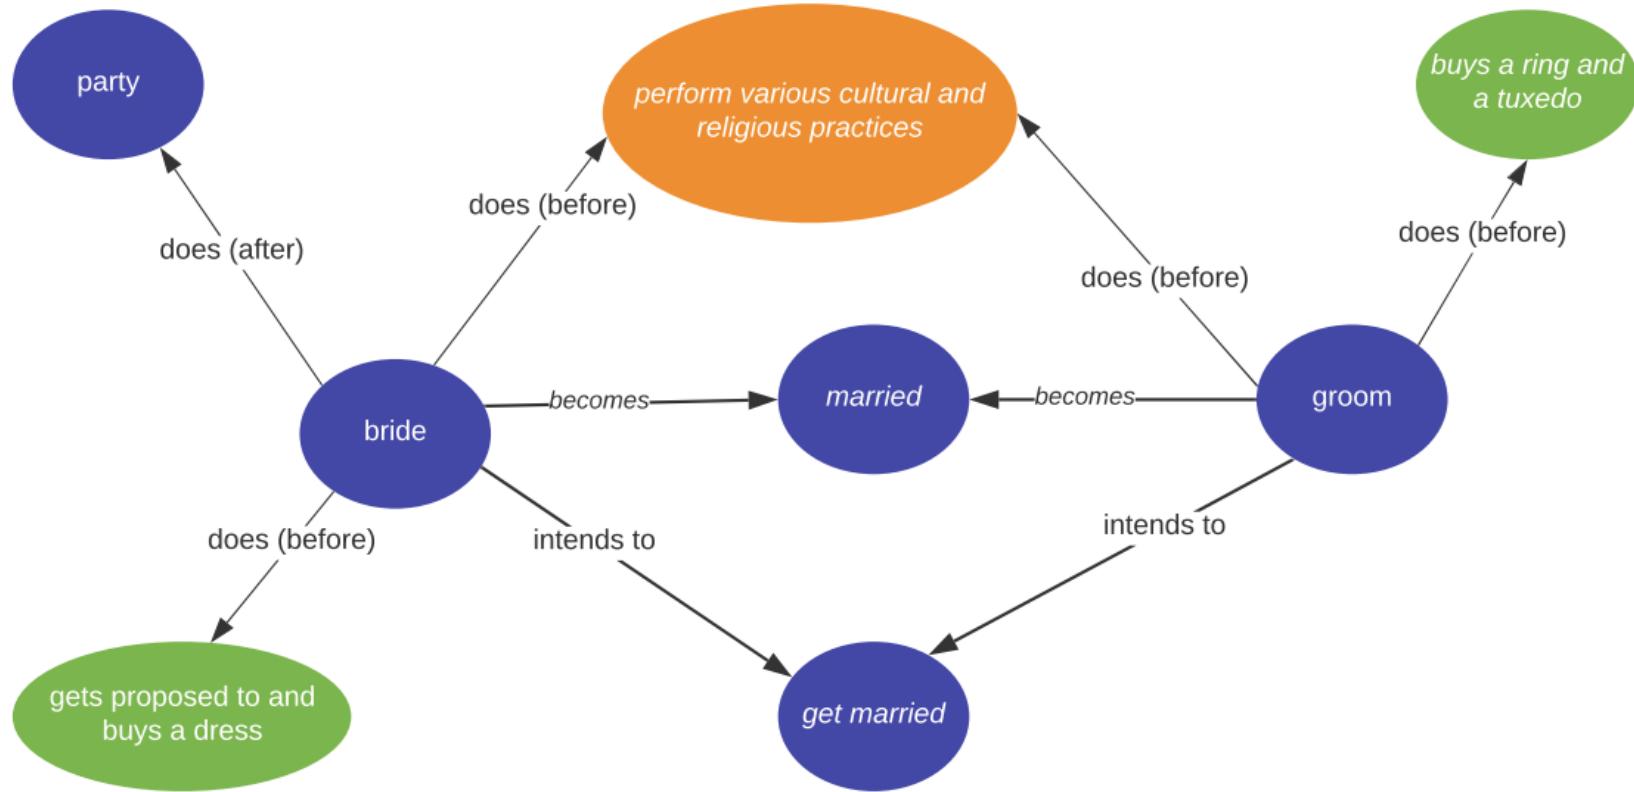
Commonsense

Many resources to represent implicit knowledge are culturally biased



COMET: Commonsense Transformers for Automatic Knowledge Graph Construction
(Bosselut et al., ACL 2019)

Commonsense



Towards an Atlas of Cultural Commonsense for Machine Reasoning
(Acharya et al., CSKGs 2021)

Some knowledge is "universal", other culture-specific

Knowledge bias in language models

“[X] was created in [Y]”

en

Japan (170), Italy (56)

de

Deutschland (217), Japan (70)

nl

Nederland (172), Italië (50)

it

Italia (167), Giappone (92)

The language of prompting affects the model's answer to prompts

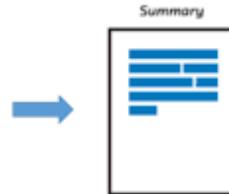


Multilingual LAMA: Investigating Knowledge in Multilingual Pretrained Language Models (Kassner et al., EACL 2021)

Aboutness ❤️

What content do people *care about*?

- Related to topic/domain



Entities



Experiences



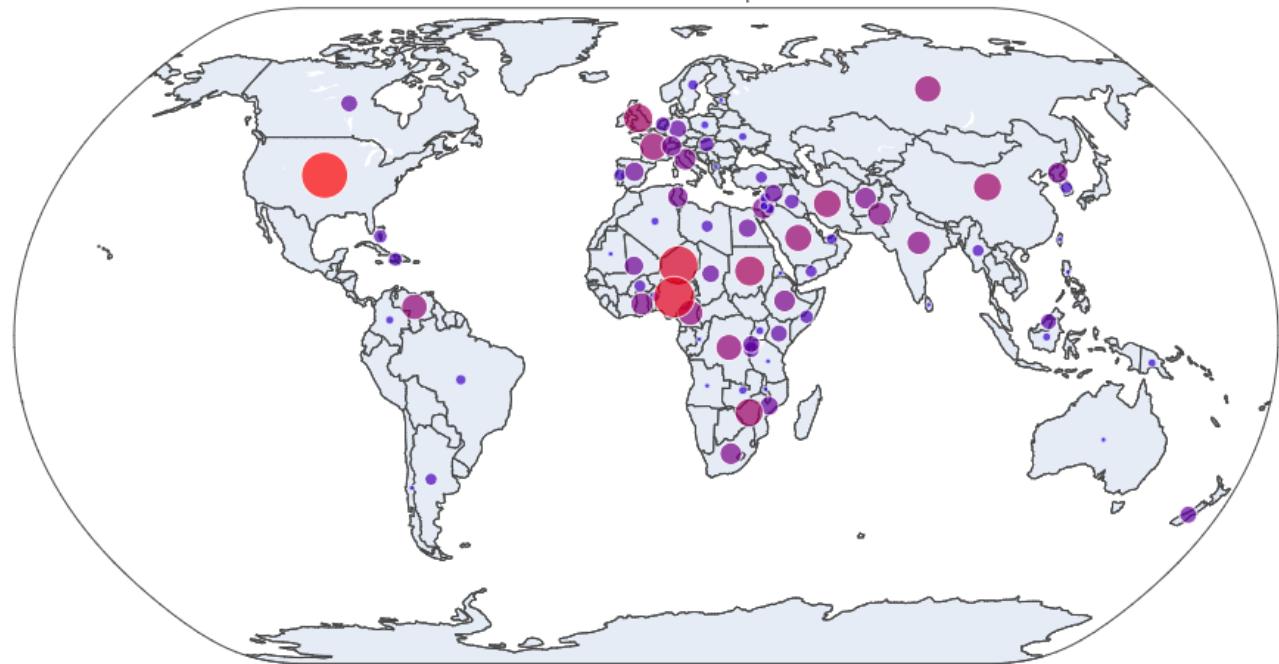
Aspects

Entities

USA & Europe
are over-
represented in
datasets across
languages

Dataset Map: Masakhaner hausa

Dataset Entities Map

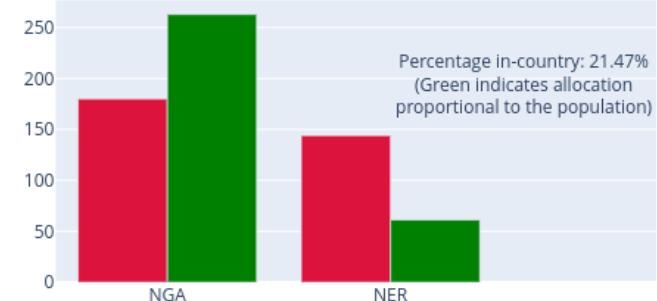


Top-10 Represented Countries

Countries Missing: 143 of 243 (58.85%)



Main Countries where language is spoken.

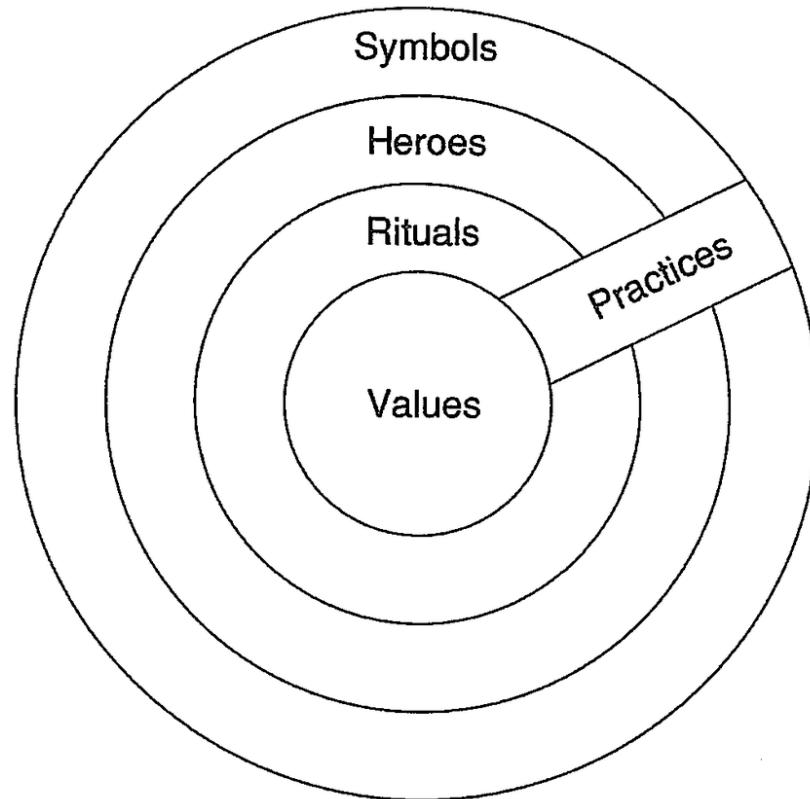


Dataset Geography: Mapping Language Data to Language Users
(Faisal et al., 2021)

Values

Objectives and
goals
people strive for

- What is considered
desired or desirable



Cultures and Organizations: Software of the Mind
(Hofstede, 1991)

(Meta) values

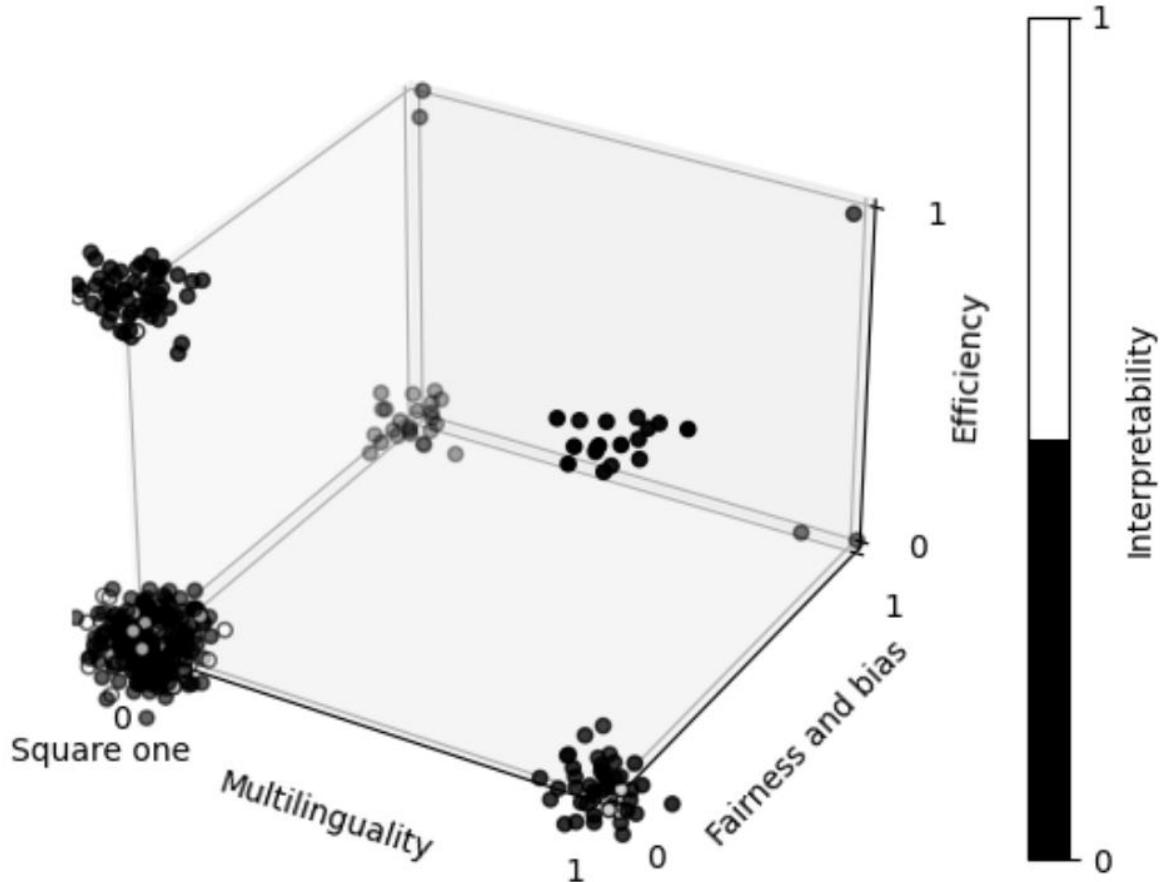
Why are we doing NLP?

- Users may have different goals, often implicit

No single correct answer.

Changing the World by Changing the Data (Rogers, ACL 2021)

Common meta-objectives in NLP



Accuracy,
fairness,
etc. reflect
the values
of NLP
researchers

Square One Bias in NLP: Towards a Multi-Dimensional Exploration of the Research Manifold (Ruder et al., ACL 2022)

Conflicting objectives between stakeholders



Researchers



Practitioners



End-users



Affected communities

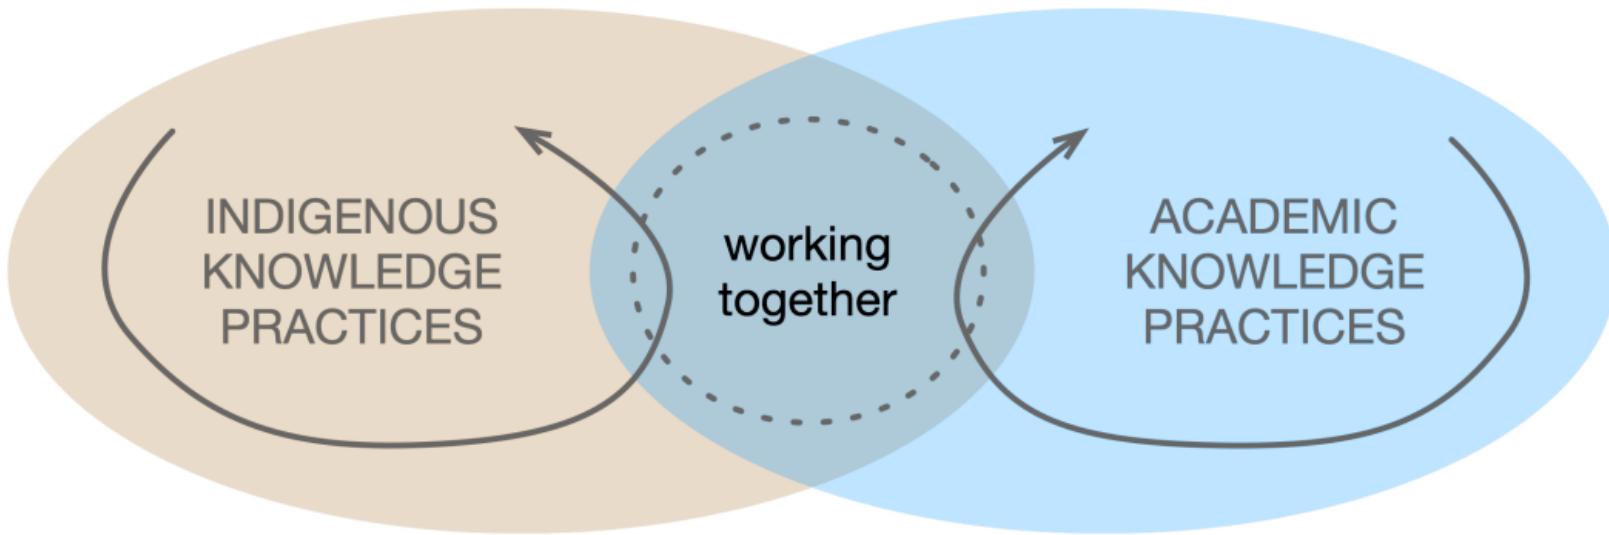


Regulators



Transparent values
facilitate adaptation
and decision making

Language technology for all (potential) users



Local Languages, Third Spaces, and other High-Resource Scenarios
(Bird, ACL 2022)

Benefit to all requires finding the intersection,
particularly for local languages

Value bias in language models



Die allermeisten von uns kennen den Zustand völliger Erschöpfung auf der Flucht, verbunden mit Angst um das eigene Leben oder das Leben der Kinder oder der Partner, zum Glück nicht. Menschen, die sich zum Beispiel aus Eritrea, aus Syrien oder dem Nordirak auf den Weg machen, müssen oft Situationen überwinden oder Ängste aushalten, die uns wahrscheinlich schlichtweg zusammenbrechen ließen. Deshalb müssen wir beim Umgang mit Menschen, die jetzt zu uns kommen, einige klare Grundsätze gelten lassen. Diese Grundsätze entstammen nicht mehr und nicht weniger als unserem Grundgesetz, unserer Verfassung.

Values are altered
to reflect US culture

(translation)

GPT-3 →
summarise

"1. I am in favor of
limiting immigration.
2. I am in favor of
limiting immigration for
humanitarian reasons.
3. I am in favor of
limiting immigration for
economic reasons."



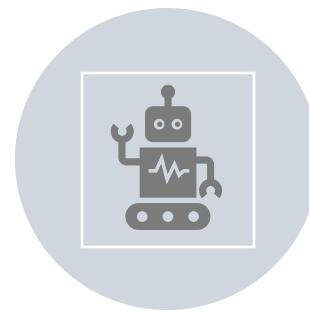
The Ghost in the Machine has an American accent: value conflict in GPT-3
(Johnson et al., 2022)

Strategies

Existing and potential ways to address the challenges



DATA



MODELS



TASKS

Data



Selection

Annotation

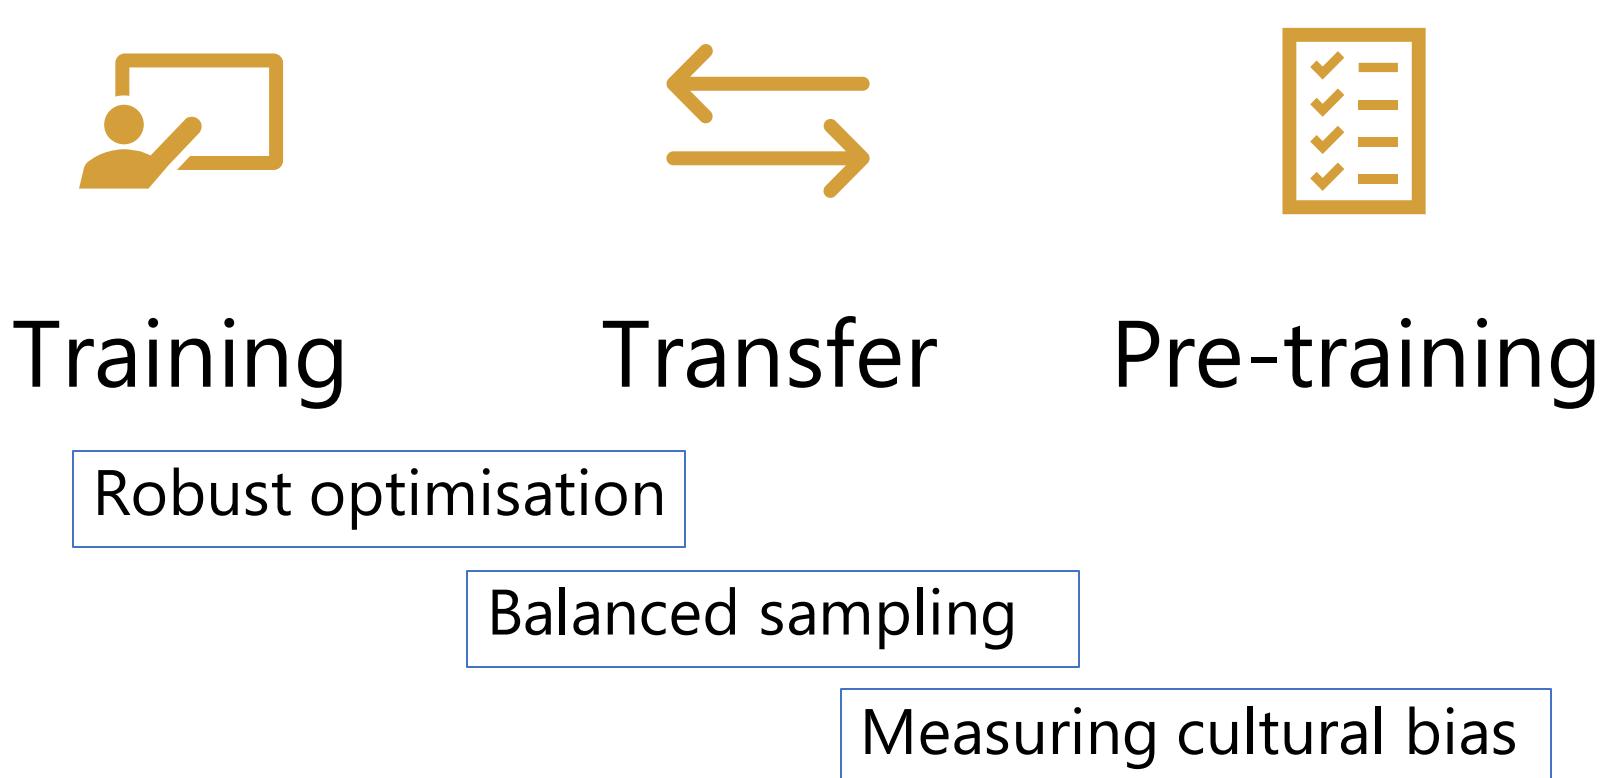
Projection

Culture-sensitive curation

Culturally diverse collection

Native data or culturally sensitive translation

Models



Tasks

Cross-cultural translation



"I saw Merkel eating a Berliner from Dietsch on the ICE"



I saw Biden eating a Boston Cream from Dunkin' Donuts on the Acela

Adapting Entities across Languages and Cultures

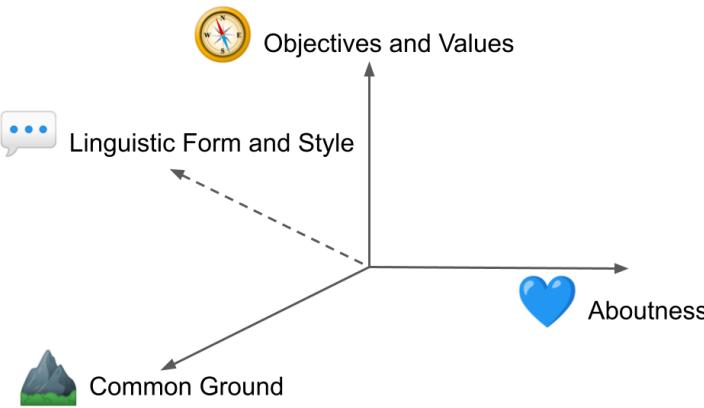
(Peskov et al., Findings 2021)

Style transfer

Entity adaptation

Explanation by analogy

Summary



NLP is for people (not just languages)

Culture is multidimensional

Objectives may be in conflict

Generalisation-representation trade-off