

Universal Dependencies と Syntactic Word の 闇

京都大学
村脇 有吾





にゃかがわりようじ

@nyakagawa_r

Follow



「ネットで見つけた格好いい船。なんて名前なんだろう？」

× 「この船の名前を教えてください」
→ 「ググレカス」

○ 「この"戦艦"超かっこいい！」
→ 「FF外から失礼します。戦艦ではなく
駆逐艦です」「ズムウォルト級です」
「アーレイ・バーク級に代わる最新鋭次
世代駆逐艦として建造が予定されていま

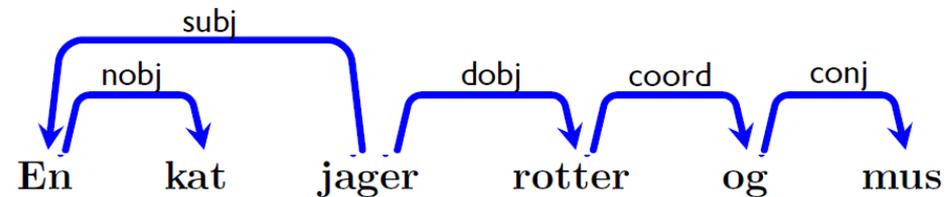
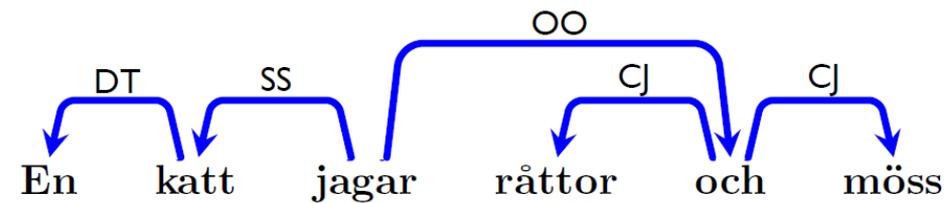
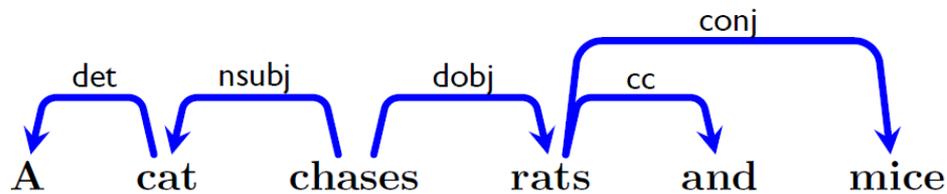
🗣 Translate from Japanese



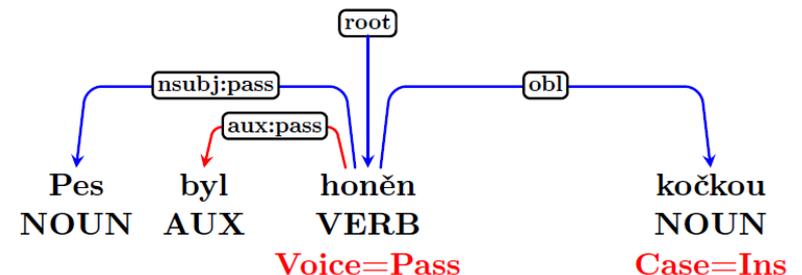
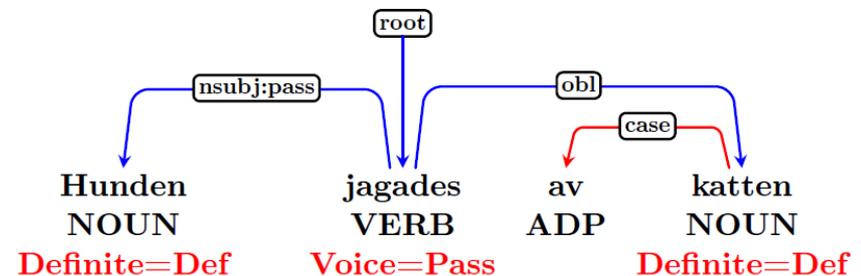
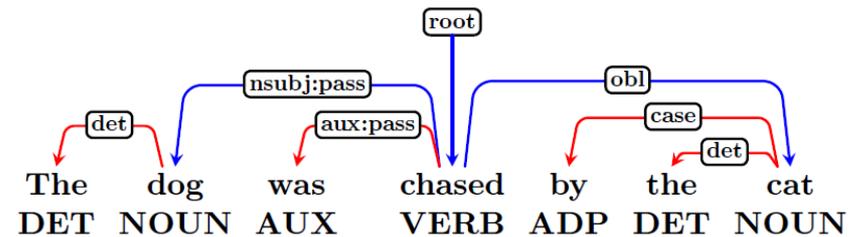
https://twitter.com/nyakagawa_r/status/945933804182560769

Universal Dependencies (UD)

UD以前



UD



言語学でもいまだ作られた
ことのない言語アノテー
ションを工学系の我々が設
計しようとしているし、そ
の難しさをコア開発者たち
は当初認識していなかった
ように見える

UDが開いたパンドラの箱

- 伝統文法は言語ごとにばらばら
- 言語類型論の沼
 - 形容詞という範疇は通言語的に存在するか?
 - 比較のための一部の言語現象を取り出すのと、各言語に一貫した体系を与えるのは別
 - どうしても広く浅い比較になりがち
- 語彙、形態論と統語論の切り分けの妥当性?
- 応用にとって本当に便利な表現?

UDにおける語: Syntactic Word

The UD annotation is based on a lexicalist view of syntax, which means that dependency relations hold between words. Hence, morphological features are encoded as properties of words and there is **no attempt at segmenting words into morphemes**.

However, it is important to note that the basic units of annotation are **syntactic words** (not phonological or orthographic words), which means that we systematically want to **split off clitics**, as in Spanish *dámelo* = *da me lo*, and undo contractions, as in French *au* = *à le*. We refer to such cases as multiword tokens because a single orthographic token corresponds to multiple (syntactic) words. In exceptional cases, it may be necessary to go in the other direction, and combine several orthographic tokens into a single syntactic word.

Syntactic wordを採用すると 日本語ではどうなるか?

- 既存の文節、BCCWJ短単位、中単位、長単位のいずれでもない、新しい単位を導入せざるを得ない [村脇, UD Japanese mtg. 2017-06]
- おおよそ: 短単位 \subseteq 語 \subseteq 文節



そもそも syntactic word を 採用すべきか?

- 構造主義言語学以来の古い単位 [服部, 1950]
- 類型論の立場から見直すと、通言語的に一貫した基準を見いだせない [Haspelmath, 2011]
- 意味的スコープとの不整合
 - [大阪に寄って、神戸に帰っ] た
- 複合語の扱いの問題

素人談義には限界
があるので、みな
さんの協力をお待
ちしております

