

PONK

Asistent přístupné úřední komunikace

Tereza Novotná

novotna@ufal.mff.cuni.cz

České právo a informační technologie

Právnická fakulta MUNI Brno

13. září 2024



Univerzita Karlova
Matematicko-fyzikální fakulta
Ústav formální a aplikované lingvistiky



unless otherwise stated

- PONK Psaní Orientované Na Klienta
- projekt č. TQ01000526
- poskytovatel TAČR
- doba řešení 9/2023-12/2025, **jsme v polovině**
- řešitel MFF UK
- aplikační garant Frank Bold Society, z.s.
- web <https://ufal.mff.cuni.cz/grants/ponk>

Cíl

Vytvořit webovou aplikaci pro automatické hodnocení srozumitelnosti českých právních textů s využitím metod umělé inteligence a ručních pravidel.

- **Srozumitelnost** posuzujeme v těchto aspektech
 - předvídatelnost - míra překvapení při čtení textu
 - stylistika - stylistická správnost textu
 - právní argumentace - relevance a koherence textu
- Metody umělé inteligence budeme trénovat na korpusu **KUK**
- Jako vedlejší výsledek projektu vzniká nástroj **MasKII** pro pseudonymizaci a anonymizaci českých právních textů



Lexikální překvapení

Definice

- Situace, kdy čtenář narazí na slovo či slovní spojení, které je **nečekané** nebo **neobvyklé** v daném kontextu.

Příčiny

- Neznámé slovo
- Neobvyklé použití slova
- Výraz netypický pro danou situaci či text

Dopad na porozumění

- Může zpomalit porozumění
- Vyžaduje větší kognitivní úsilí
- Může vést k nepochopení textu a chybnému jednání

Lexikální překvapení

PONK-GLITTER

- Modul aplikace PONK
- Použití jazykových modelů pro výpočet pravděpodobnosti/entropie textu

Pravděpodobnost následujícího slova ~ lexikální překvapení

Příklad:

$$p = 0.0002$$



Smlouva obsahuje klauzuli o odstoupení od smlouvy .



$$p = 0.0001$$



$$p = 0.00000015$$

Gramatická pravidla & stylometrické indikátory

Gramatická pravidla

- Detekujeme **výskyty jevů**, které by mohly **zhoršovat srozumitelnost**
- Inspirujeme se příručkami srozumitelného právního a akademického psaní
- Např. trpný rod, pozice příslušku, podstatná jména slovesná, přebytek negací, ...

Stylometrické indikátory

- **Číselné** “zhodnocení”
- Vztahují se na **text jako celek**
- Např. type-token ratio, aktivita, Gunning fog index, ...

Používáme nástroj **UDPipe** pro větný rozbor textů (<https://lindat.cz/services/udpipe/>).

Gramatická pravidla & stylometrické indikátory

Příklad

Navrhovatelé dále vyjádřili názor, že zásady územního rozvoje mohou **být** soudem **přezkoumány** již v okamžiku jejich **vydání**, **nebot** od tohoto okamžiku „právně **existují**“, a není tak potřeba čekat na **nabytí** účinnosti.

Detekovali jsme

- Trpný rod opisný
- Podstatná jména slovesná
- Přísudek daleko ve větě

Naměřené indikátory

- Activity: 0.29
- Entropy: 8.71
- TTR: 0.16
- Gunning Fog: 11.86

výběr indikátorů, naměřeno na celém původním textu

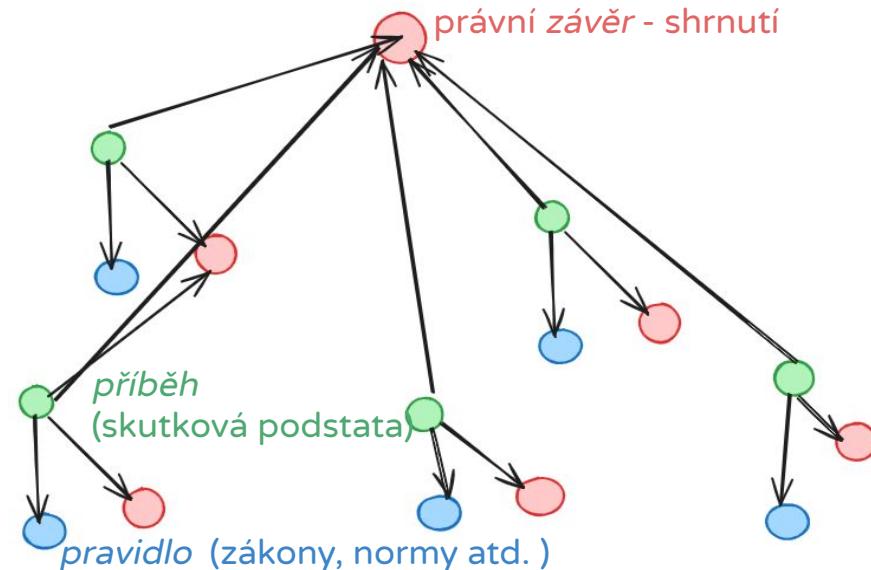
Anotace právní argumentace

Relevance



Koherence

Každý právní závěr má být podložen příběhem a pravidlem, nebo trojicí závěru, příběhu a pravidla.



Anotace právní argumentace

Anotační nástroj Gloss (Jaromír Šavelka)

Relevance

Types 4	Annotations 41
1_Nesrozumitelné	Komise předně podotýká, že p neznamená, že žadateli o dlu musí mimo realizaci formálních zejména k naplnění obligatorní dostatečně vysvětlit svoji moti mají žadatelé o dlouhodobé v nezbytných k individuálnímu p víza nepočítat pouhé splnění vnitra musí rovněž vyloučit pří uvedených v § 56 zákona č. 3
2_Zbytečné	
3_Relevantní	
komentář anotátora	Komise upřesňuje, že pohovo v souladu se zákonem č. 326/ zjištění objektivních skutečnos



Koherence

Data	Text	ArgMOmbu032024_odB:	
Types 8	Annotations 19	Již v době objednání dila žalobcem měl dlužník peněžeté závazky 30 dní po lhůtě splatnosti, jak vyplývá z přihlášek pohledávek vě specifikovaného insolvenčního řízení vedeného proti dlužníku (na veden pod čísla přihlášek P4, P5, P7, P8, P9, P11, P12 atd.), př pochybností, že tyto své závazky nebyl schopen plnit. Žalobce má žalobcovy objednávky dila byl dlužník předlužen, soud dle pomě likvidátora dlužníka ze dne 30. 7. 2013 vyplývá, že aktiva dlužníka pohledávkami za třetími osobami, jejichž vymahatelnost označil lik likvidátora za obec pasiva společnosti byla dle účetní závěrky připojené ke sdělení likvidátora v obd než dosprl k závěru předlužení, a to vzhledem k nutnosti posuzování aktiv dle je účetní hodnoty, neboť pokud jsou pohledávky dlužníka za třetími osobami obtíž jejich tržní hodnota značně nižší než uvedená hodnota účetní.	
Komentář o čemkolik			
Metatext			
Pravidlo			
Právní otázka			
Příběh			
Rada			
Výzva			
Závěr			



Anotace právní argumentace

Koherenční vztahy

- Anotátor vychází z příběhu.
- Segmentuje příběh tak, aby ho co nejlépe propojil s pravidly a závěry.
- Pole bez vztahů:
metatext, rady, výzvy

[Barbora Kubíková] Porušení povinnosti žalova...

[Barbora Kubíková] Důkazy: sdělení likvidátor...

[Barbora Kubíková] V situaci, kdy pohledávka ...

[Barbora Kubíková] Pokud by žalovaný danou ...

author: Barbora Kubíková
type: Příběh
start: 4776
end: 5181

pravidla: V situaci, kdy pohledávka věřitele vznikla až při p... (Barbora Kubíková)
Ustanovení § 99 InsZ pak stanoví, že osoba, která p... (Barbora Kubíková)

závěry: přičemž je bez jakýchkoliv pochybností že tyto své ... (Barbora Kubíková). Jelikož byl ale žalovaný v prodloužení se splněním své ... (Barbora Kubíková), **V.** Vzhledem k vyse uvedenemu začátku navr... (Barbora Kubíková)

zbytečného odkladu pot... žalovaného podat insolvenčního odhadu

Důkazy: sdělení likvidátor...

IV.

V situaci, kdy pohledávka Nejvyššího soudu (viz na kterou věřitel posléze ob dlužníkem představuje c...

Pokud by žalovaný danou uzavřel za zcela odlišnýdjakýchkoliv vad), připad specifikovanou povinnos...

Jelikož byl ale žalovaný rozpoznat a pohledávka pak stanoví, že osoba, k jinou újmu, kterou způsob...

```
graph TD; A[V situaci, kdy pohledávka...] --> B[Pokud by žalovaný danou...]; C[závěry: přičemž je bez jakýchkoliv pochybností že tyto své ...] -.-> D[Jelikož byl ale žalovaný v prodloužení se splněním své ...]
```

Anotace právní argumentace



Originál:
mísení segmentů
v rychlém sledu, často uvnitř
jedné věty



Přepis:
často stručnější, méně
střídání segmentů

MasKIT

MasKIT je webový nástroj a služba REST API pro pseudonymizaci a anonymizaci českých právních textů:

1. Zpracuje vstupní text (např. dopis zasláný právním orgánem občanovi) pomocí nástrojů UDPipe a NameTag
2. V textu identifikuje a nahradí osobní informace

K dispozici na adrese <https://quest.ms.mff.cuni.cz/maskit/run.php>

NameTag rozpoznává jména osob, institucí, geografické názvy a jiné jmenné entity v textu (<https://lindat.cz/services/nametag/>).

MasKIT

[i O programu](#)[Spustit](#)[Dokumentace REST API](#)

▼ MasKIT je webový nástroj a služba REST API pro pseudonymizaci a anonymizaci českých právních textů.

▼ Informace o serveru MasKIT: verze: *0.64 20240820*, stav: *online*

Vstup: Prostý text Předrozdělený (každá věta na samostatném řádku)

Výstup: TXT (s označením pomocí speciálních znaků) HTML (s barevným zvýrazněním)

Další volby: Náhodná volba při nahrazování Použití tříd při nahrazování

[A Vstupní text](#)[Smazat vstupní text](#)

Paní Marie Nováková z Myslíkovy ulice č. 25 dostala dopis od firmy Škoda.

[↓ Zpracovat vstup ↓](#)[původní barvy](#)[A Výstup](#)[Uložit](#)[Další informace](#)[Uložit](#)

Paní Anna[Marie] Svobodová[Nováková] z Polní[Myslíkovy] ulice č. 29[25] dostala dopis od firmy ProfiServis[Škoda].

MasKIT - podporované vlastnosti

▼ Informace o serveru MasKIT: verze: *0.64 20240820*, stav: *online*

Informace o serveru MasKIT

- verze: *0.64 20240820*, stav: *online*
- podporované vlastnosti: *first names (not judges)* • *surnames (not judges, male and female tied)* • *phone numbers (non-emergency)* • *e-mails* • *www addresses* • *street names (incl. multiword)* • *street numbers* • *town/town part names (incl. multiword; not places of court)* • *ZIP codes* • *company names (incl. multiword)* • *cult./educ./scient. institutions (incl. multiword)* • *commercial register number (IČO)* • *tax register number (DIČ)* • *land registration numbers (registrační čísla pozemků)* • *birth registration numbers (rodná čísla)* • *dates of birth/death* • *agenda reference numbers (čísla jednací)* • *vehicle registration numbers (SPZ)*

Pro testovací účely je služba poskytována zdarma, za [těchto podmínek užívání](#). Pro komerční využití softwaru je požadován výslovný písemný souhlas autorů MasKITu a volaných externích služeb ([UDPipe](#) a [NameTag](#)).

Anonymita

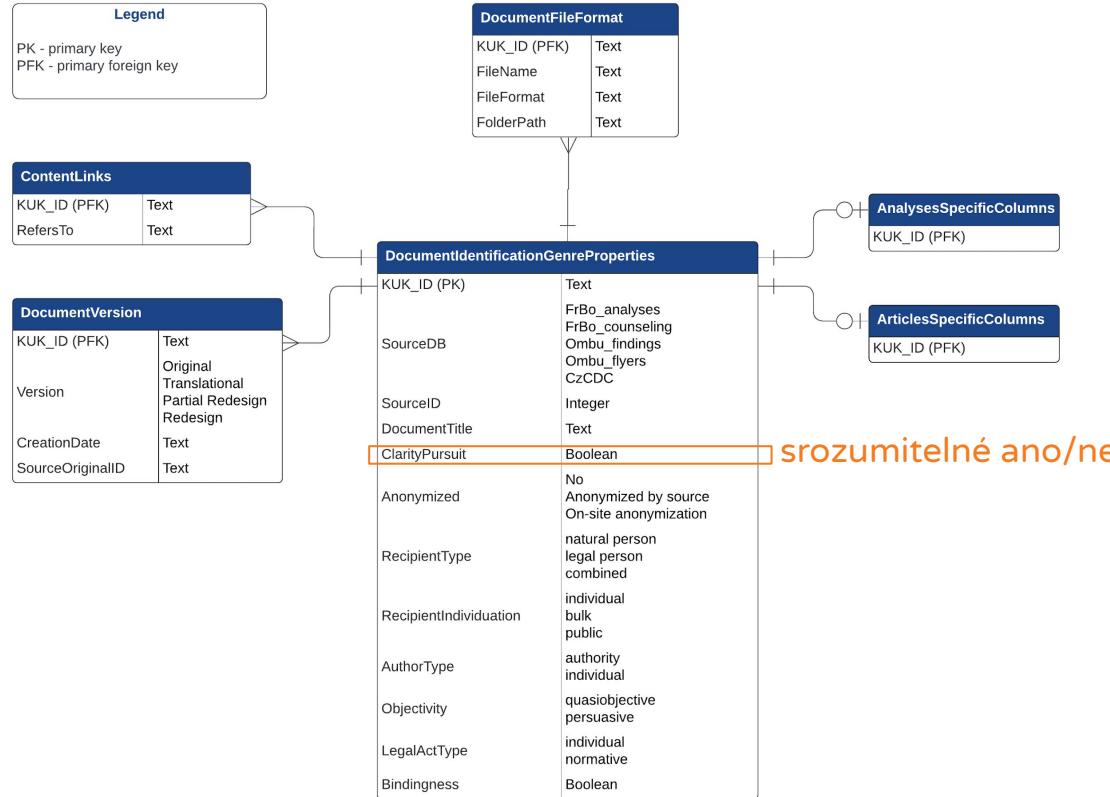
V zájmu zachování anonymity na tomto serveru MasKIT ani externí služby UDPipe a NameTag neukládají zpracovávané texty. Jediné informace, které mohou být ukládány, jsou: čas použití, velikost zpracovávaných dat, konfigurace systému a IP adresa, ze které bylo k systému přistupováno; pokud službu používáte prostřednictvím rozhraní REST API, ujistěte se, že používáte metodu POST, protože adresy URL rozhraní REST API mohou být také ukládány.

Všechny připomínky a reakce jsou vítány.

KUK 0.0

- Korpus Úřední Komunikace
- České právní a administrativní texty pro trénování metod umělé inteligence
- Verze 0.0
 - 6 051 dokumentů, 19 196 037 slov
 - právní analýzy a zodpovězené dotazy z databáze Frank Bold
 - stanoviska a letáky vydané Kanceláří veřejného ochránce práv
 - soudní rozhodnutí tří nejvyšších českých soudů
 - právní texty v několika parafrázích ze studie srozumitelnosti českých administrativních textů
 - ke stažení v repozitáři LINDAT/CLARIAH-CZ [url](#)
 - k prohlížení v nástroji TEITOK [url](#)

KUK 0.0 - metadata



srozumitelné ano/ne