# Handleiding LeTs Preprocess demo

## LeTS Preprocess

Met deze demo kun je gebruikmaken van LeTs Preprocess, een tool voor **automatische zinsontleding** die gebruikmaakt van machinelearning. LeTs Preprocess is getraind voor vier talen: Nederlands, Frans, Engels en Duits. Je kunt voor elk van die vier talen een tekst (maximaal 1000 tekens, inclusief spaties) invoeren om die automatisch te laten verwerken.

## Aan de slag

Klik op 'Start the demo' om toegang te krijgen tot de interface van LeTs. Volg dan de onderstaande stappen:

1. **Taalselectie**: Kies de taal van de ingevoerde tekst in het dropdownmenu '**Language**'.
2. **Tekst invoeren**: Kopieer en plak je tekst in het veld '**Input text**', of upload een tekstbestand door te klikken op '**Upload file**'. Let op: de demo accepteert alleen platte tekstbestanden (met de extensie .txt). Teksten in andere formaten, zoals Word- of Excel-documenten, moeten eerst worden opgeslagen als een .txt-bestand. Dat kan je doen door te kiezen voor: 'Opslaan als…' → 'Tekst zonder opmaak (.txt)' Let erop dat je 'Unicode (utf-8)'. Zorg ervoor dat je 'Unicode (utf-8)' kiest als tekencodering.
3. **Verwerken**: Nadat je de taal hebt geselecteerd en de tekst hebt ingevoerd of geüpload, klik je op '**Submit**' om de analyse te starten.

## Verwerkingsstappen

LeTs Preprocess voert de volgende stappen uit:

1. **Zinssplitsing en tokenisering**: De tekst wordt automatisch verdeeld in zinnen en tokens. Een token kan een woord, een leesteken, een cijfer of een speciaal teken zijn (bv. hashtags of emoji's).
   **Voorbeeld**:
   - Originele tekst: "De prijzen? Die zijn gedaald met 22% 📉"
   - Getokeniseerde versie: "de" / "prijzen" / "?" / "die" / "zijn" / "gedaald" / "met" / "22" / "%" / 📉
2. **Woordsoorttoekenning (POS-tagging)**: Elk token krijgt een label dat de woordsoort (zoals zelfstandig naamwoord, bijvoeglijk naamwoord, werkwoord, enz.) aangeeft.
3. **Eigenaamherkenning (NER - Named Entity Recognition)**: Het systeem herkent of een token een eigennaam is en bepaalt over welke categorie het gaat. Er worden zes types eigennamen herkend, die onderaan deze handleiding verder worden uitgelegd.
4. **Lemmatisering**: Elk woord wordt herleid tot de basisvorm (lemma). Bijvoorbeeld, "vriendjes" wordt herleid tot "vriend" en "zwom" wordt herleid tot "zwemmen".
5. **Chunking**: Op basis van de woordsoorten worden zinsdelen (chunks) aangeduid, zoals naamwoordelijke en werkwoordelijke gezegdes. Zo kunnen syntactische eenheden in de zin worden onderscheiden.

## Uitvoer bekijken

Na verwerking wordt de uitvoer binnen enkele seconden op het scherm getoond. Rechts op het scherm verschijnt de tekst, waarbij verschillende visuele elementen worden gebruikt:

- **Zwarte kaders:** Die markeren zinsdelen (chunks), zoals een naamwoordelijk gezegde. Als woorden geen zwart kader hebben, dan werden ze door het systeem niet als 'chunks' beschouwd, zoals voegwoorden ('en', 'maar', 'of',…).
- **Kleuren:** De achtergrondkleur van een woord of zinsdeel geeft de woordsoort aan. Bijvoorbeeld:
  - Paars: werkwoord
  - Appelblauwzeegroen: voegwoord
  - roze: voornaamwoord
- **Rode tekst:** Eigennamen worden in rood aangeduid, zoals 'Hoogduits' in Figuur 1.

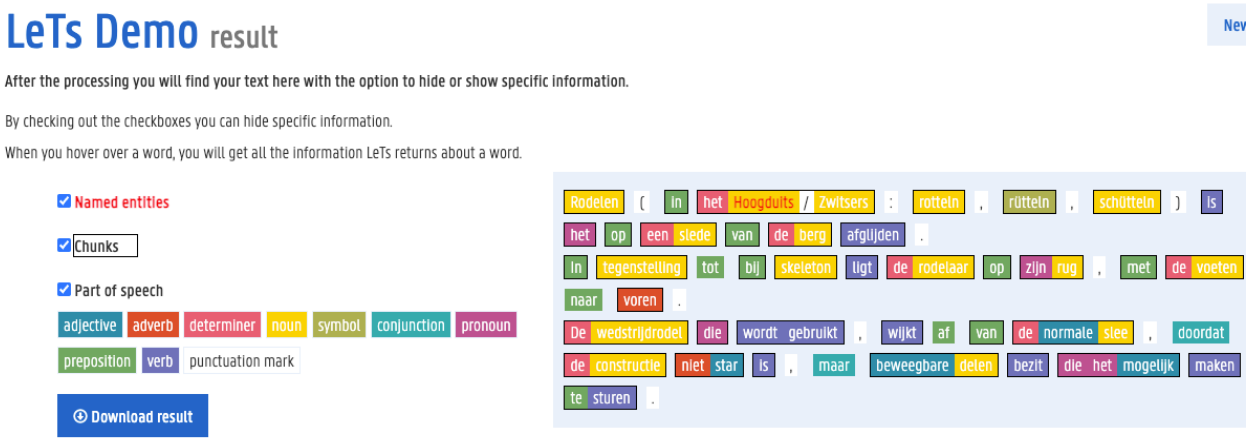


*Figuur 1: uitvoer LeTs Preprocess.*

### Resultaten downloaden

Voor een meer gedetailleerde weergave van de resultaten kun je de uitvoer downloaden door te klikken op '**Download results**'. Dat levert een .txt-bestand op dat je kunt openen in programma's zoals SublimeText, NotePad, Kladblok, Word of Excel. Als je het bestand opent in Word of Excel, zorg er dan voor dat je de tekencodering instelt op utf-8 voor een correcte weergave.

**Tip voor Excel**: In Excel kun je de resultaten gemakkelijk filteren op bijvoorbeeld woordsoort of eigennamen om een grondige analyse te maken.

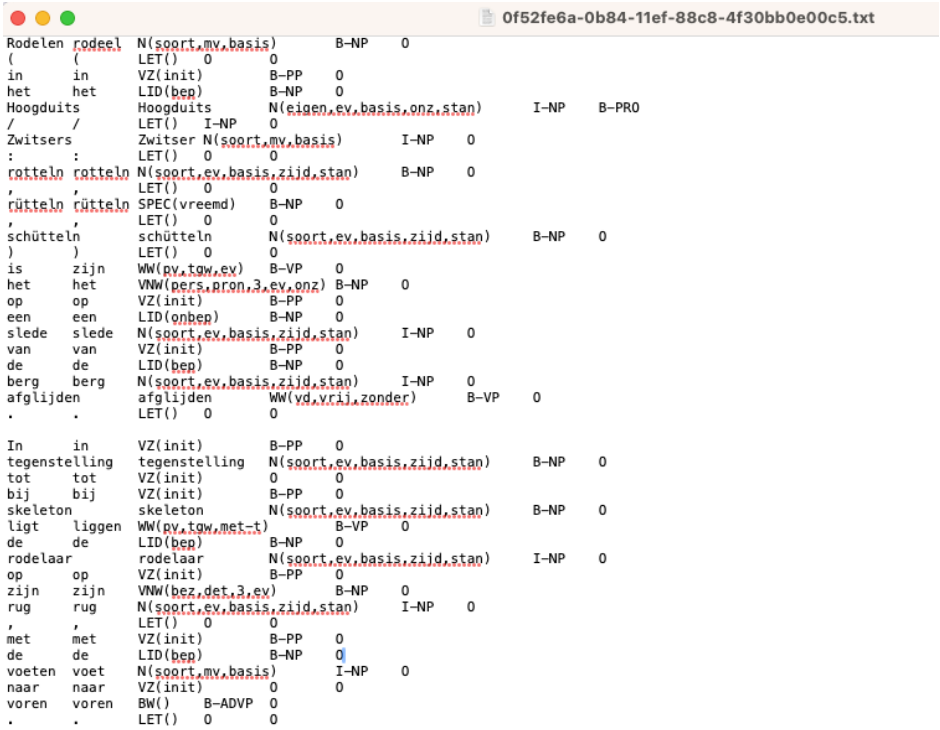


*Figuur 2: LeTs uitvoer gedownload als .txt-bestand en geopend met Kladblok.*

### Analyse van de uitvoer

Het gedownloade .txt-bestand bevat vijf kolommen met gedetailleerde informatie:

1. **Kolom 1:** De originele invoertekst, opgedeeld per token (woord, cijfer, leesteken). Lege regels scheiden zinnen van elkaar.

2. **Kolom 2:** Het lemma (de woordenboekvorm) van elk token.
3. **Kolom 3:** De woordsoort van elk token, gebaseerd op de categorisatie in de bijbehorende manual (zie link naar het overzicht op de hoofdpagina van de demo).
4. **Kolom 4:** De zinsdelen (chunks) worden aangegeven met de codes 'B' (begin) en 'O' (outside). Bijvoorbeeld, 'B-PP' bij het derde token in Figuur 2 betekent 'begin van een prepositional phrase'.
5. **Kolom 5:** Eigennamen worden aangeduid met 'B-' gevolgd door het type. Er worden zes types onderscheiden:
    - **PRO:** Product (bv. commerciële producten, voertuigen, diensten).
    - **PER:** Persoon (bv. familienamen, voornamen, artiestennamen).
    - **ORG:** Organisatie (bv. overheidsorganisaties, bedrijven, politieke partijen).
    - **LOC:** Locatie (bv. landen, steden, continenten, waterwegen).
    - **EVE:** Evenement (bv. wedstrijden, conferenties, oorlogen, festivals).
    - **MISC:** Diversen (bv. juridische termen, onjuiste hoofdletters).

**Aanvullende tips:**

Ervaar je problemen bij het opladen van een bestand? Controleer dan zeker het volgende:

- Unicode-codering: Zorg ervoor dat je altijd Unicode (utf-8) selecteert als tekencodering bij het opslaan van bestanden.
- Tekstformaten: De tool ondersteunt alleen tekstbestanden zonder opmaak (.txt). Andere bestandstypen moet je dus eerst converteren naar een .txt-bestand.

**Contact**

Technische problemen bij deze demo? Contacteer dan Michael.Lumingu@UGent.be.
Vragen over de tool zelf? Contacteer dan Orphee.DeClercq@UGent.be en Cynthia.VanHee@UGent.be.