

# Prepis hovorenej reči, podpora slovenského jazyka

Autor: Samuel Baran, 3Ib

Vedúci: RNDr. Erik Bruoth, PhD.

# Ciele

- ❖ Analyzovať existujúce prístupy STT
- ❖ Vytvoriť tréningovú sadu pre úlohu pomocou dostupných zdrojov
- ❖ Identifikovať open source implementácie modelov (min. 2) rozpoznávania reči (STT)
- ❖ Navrhnuť stratégiu tréningu modelov a ladenia hyperparametrov
- ❖ Základné porovnanie modelov na základe vybraných metrík resp. popis hlavných problémov

# Vytvorenie tréningovej sady pre úlohu pomocou dostupných zdrojov

- ◆ Datasets iniciatívy Mozilla Common Voice
  - ◆ 24 aktívnych jazykov (aj čeština) d'alšie pripravujú (slovenčinu :/)

Jazyk	čeština
VELKOSŤ	<b>774 MB</b>
VERZIA	<b>cs_29h_2020-06-22</b>
CELKEM VALIDOVANÝCH HODIN	<b>26</b>
CELKOVÝ POČET HODIN	<b>29</b>



# Vytvorenie tréningovej sady pre úlohu pomocou dostupných zdrojov

## 1. KAPITOLA

APRÍL 2002

Stál sám uprostred noci a vedel, že musí zabiť. Sú  
korunách stromov a ohýbal konáre, akoby sa zvijali

.....

jej starý Homolka exol na stole trikrát za sebou, t  
nie.

~ 5 ~

Ani policajti, ktorých ofúkla. Kým stihli neveriac  
baterky s červeným skličkom, už bola z dohľadu.

„Čo to bolo?“

„Méd'ák...!“

- ❖ spracovanie audiokníh
- ❖ 3 knihy ~ 50 hodín (e-kniha + audiokniha)
  - ❖ e-kniha epub
  - ❖ audiokniha
    - ❖ mp3 pre každú kapitolu
- ❖ pooloautomatizované spracovanie
  - ❖ extrahovanie raw textu z epub publikácie knihy
    - ❖ online converter (málo kníh)
  - ❖ rozsekanie textu na kapitoly (korešpondujúce s mp3)
    - ❖ python skript
    - ❖ úpravy “na mieru” (odstránenie úvodu, označenia kapitol)

# Vytvorenie tréningovej sady pre úlohu pomocou dostupných zdrojov

- ❖ stav datasetu:
  - ❖ počet (nahrávka, prepis) - rádovo v desiatkach
  - ❖ trvanie nahrávky - rádovo v desiatkach minút
- ❖ požiadavky modelu:
  - ❖ trvanie nahrávky – jednotky – desiatky sekúnd
  - ❖ počet – čo najviac



# Vytvorenie tréningovej sady pre úlohu pomocou dostupných zdrojov

- ❖ stav datasetu:
  - ❖ počet (nahrávka, prepis) - rádovo v desiatkách
  - ❖ trvanie nahrávky - rádovo v desiatkách minút
- ❖ požiadavky modelu:
  - ❖ trvanie nahrávky – jednotky – desiatky sekúnd
  - ❖ počet – čo najviac
- ❖ riešenie
  - ❖ rozsekať kapitoly na menšie jednotky (vety)



# Vytvorenie tréningovej sady pre úlohu pomocou dostupných zdrojov

## Forced alignment

- ◆ zarovnanie ortografických prepisov a zvukových záznamov
- ◆ väčšina nástrojov založená na ASR (automatic speech recognition)
- ◆ Princíp:
  - ◆ rozpoznanie obsahu nahrávky (STT)
  - ◆ namapovanie na originálny text

1  
From fairest creatures we desire increase,  
That thereby beauty's rose might never die,  
But as the riper should by time decease,  
His tender heir might bear his memory:  
But thou contracted to thine own bright eyes,  
Feed'st thy light's flame with self-substantial fuel, => [00:00:18.800, 00:00:22.760]  
Making a famine where abundance lies,  
Thy self thy foe, to thy sweet self too cruel:  
Thou that art now the world's fresh ornament,  
And only herald to the gaudy spring,  
Within thine own bud buriest thy content,  
And tender churl mak'st waste in niggarding:  
Pity the world, or else this glutton be,  
To eat the world's due, by the grave and thee.  
=> [00:00:22.760, 00:00:25.680]  
=> [00:00:25.680, 00:00:31.240]  
=> [00:00:31.240, 00:00:34.400]  
=> [00:00:34.400, 00:00:36.920]  
=> [00:00:36.920, 00:00:40.640]  
=> [00:00:40.640, 00:00:43.640]  
=> [00:00:43.640, 00:00:48.080]  
=> [00:00:48.080, 00:00:53.240]


# Vytvorenie tréningovej sady pre úlohu pomocou dostupných zdrojov

Forced alignment - Aeneas

- ❖ produkt firmy ReadBeyond
  - ❖ Audio e-books (synchronizácia audioknihy a eknihy epub)
- ❖ Python/C knižnica
- ❖ odlišný prístup založený na spracovávaní signálu
- ❖ DTW (dynamic time wraping)
- ❖ TTS (text to speech)

❖ Princíp:

- ❖ syntéza audia z textu (TTS)
  - ❖ eSpeak (aj SK)
- ❖ hľadanie zhody audia a časti mp3



# Vytvorenie tréningovej sady pre úlohu pomocou dostupných zdrojov

Aktuálny stav:

- ❖ 11 598 audiosegmentov dĺžky ~ 10s
- ❖ približne 30 hodín

Ďalšie možnosti:

- ❖ Spracovanie podcastov
  - ❖ potrebné presné prepisy
  - ❖ Newsletter
- ❖ Slovenský národný korpus <https://korpus.sk/>
  - ❖ bezplatné využitie na vedecko-výskumné ciele
  - ❖ k 22.07.2020 približne 1,65 mld tokenov
  - ❖ hovorený korpus ~ 700 hodín

Voice STT  
moz://a

Identifikovanie open source implementácie modelov (min. 2) rozpoznávania reči (STT)

Common Voice  
moz://a



## MOZILLA

- ❖ Voice STT DeepSpeech
  - ❖ Tensorflow
  - ❖ end to end rozpoznávania reči
    - ❖ konverzia dataframe-ov na fonémy
    - ❖ generovanie textu z postupnosti foném
    - ❖ kombinovanie s jazykovým modelom
- ❖ Common voice
  - ❖ Iniciatíva zbierajúca dátu
- ❖ TTS

TT

# Ďalšie ciele

- ❖ Analyzovať existujúce prístupy STT
  - ❖ Získať prehľad v už existujúcich prístupoch STT konverzie
  - ❖ Porovnať dané prístupy
- ❖ Navrhnuť stratégiu tréningu modelov a ladenia hyperparametrov
- ❖ Základné porovnanie modelov na základe vybraných metrík resp. popis hlavných problémov

# Najbližšie kroky

- ❖ Naštudovať aktuálne prístupy spracovávania prirodzeného jazyka s použitím hlbokého učenia
- ❖ Preskúmať architektúru open source implementácie STT algoritmu z dielne Mozilly
- ❖ Nájsť ďalšiu implementáciu STT algoritmu
- ❖ Získať väčší dataset
- ❖ Trénovať model
- ❖ Identifikovať hyperparametre modelov

Ďakujem za pozornosť

Otázky?

# Literatúra

- ❖ Dan Jurafsky and James H. Martin. Speech and Language Processing (3rd ed. draft  
[https://web.stanford.edu/~jurafsky/slp3/edbook\\_oct162019.pdf](https://web.stanford.edu/~jurafsky/slp3/edbook_oct162019.pdf))
- ❖ Ian Goodfellow, Yoshua Bengio, and Aaron Courville. Deep Learning  
(<http://www.deeplearningbook.org>)
- ❖ Jacob Eisenstein. Natural Language Processing
- ❖ <http://web.stanford.edu/class/cs224n/>
- ❖ <https://github.com/espnet/interspeech2019-tutorial>
- ❖ <https://github.com/mozilla/DeepSpeech> open source

# Literatúra

- ❖ <https://medium.com/@techfirst/forced-alignment-how-to-match-audio-with-a-transcript-via-machine-learning-dd19da8c0f04>
- ❖ <https://medium.com/@klintcho/creating-an-open-speech-recognition-dataset-for-almost-any-language-c532fb2bc0cf>
- ❖ <https://github.com/readbeyond/aeneas>
- ❖ <https://www.readbeyond.it/aeneas/docs/>
- ❖ <https://usabilitygeek.com/automatic-speech-recognition-asr-software-an-introduction/>
- ❖ <https://github.com/readbeyond/aeneas/blob/master/wiki/HOWITWORKS.md>
- ❖ <https://medium.com/@techfirst/forced-alignment-how-to-match-audio-with-a-transcript-via-machine-learning-dd19da8c0f04>
- ❖ <http://espeak.sourceforge.net/>