

Tvorba LLM (Large Language Models) v jazyce Python

Kód kurzu: PYTHON_LLM

Kurz je určen pro programátory, kteří chtějí pochopit, jak velké jazykové modely (LLM) fungují „uvnitř“, a prakticky si projít cestu od jednoduchých statistických jazykových modelů přes RNN/LSTM až po transformer a mini GPT. V druhé části kurzu se účastníci naučí pracovat s hotovými modely (Hugging Face), provést fine-tuning (včetně LoRA) a postavit praktickou aplikaci nad vlastními dokumenty pomocí RAG (retrieval-augmented generation). Součástí jsou i produkční aspekty: latence, optimalizace, kvantizace a nasazení jako API včetně Dockeru.

Pro koho je kurz určen:

- Programátory se základní znalostí Pythonu, kteří chtějí porozumět LLM a umět je prakticky využít.
- Vývojáře, kteří chtějí implementovat a trénovat malé modely, a následně pracovat s existujícími LLM (fine-tuning, RAG, nasazení).
- Data/ML nadšence, kteří chtějí získat ucelený praktický přehled od „nuly“ po aplikaci.

Požadované vstupní znalosti

- Základní znalost jazyka Python na úrovni kurzu PYTHON_INTRO
- Základní znalost NumPy na úrovni kurzu PYTHON_DATAN
- Základy lineární algebry jsou výhodou (nejsou podmínkou)

Metody výuky

- Odborný výklad s praktickými ukázkami, cvičení na počítačích.
- Práce v Jupyter Notebook a skriptech, průběžné miniprojekty.
- Důraz na pochopení principů a reprodukovatelnost.

Studijní materiály

- Prezentace probírané látky v tištěné nebo online formě.
- Notebooky a referenční implementace k jednotlivým dnům.
- Ukázkové datasety a šablony pro trénování, vyhodnocení a nasazení.

Osnova

Základy neuronových sítí a NLP

- Co je jazykový model
- Pravděpodobnost a predikce dalšího slova / tokenu
- Tokenizace
- Embeddingy
- Neuronová síť (perceptron, vrstvy, aktivace)
- Backpropagation (intuice)
- Python + NumPy
- Implementace unigram modelu
- Implementace bigram modelu
- Trénink malé sítě v PyTorch
- Výstup dne: malý jazykový model predikující další slovo na malé vzorce textu

Rekurentní sítě a první generování textu

- RNN
- LSTM
- Problém miznícího gradientu
- Teacher forcing
- Sampling (temperature, top-k)
- Implementace LSTM modelu v PyTorch
- Trénink na malém datasetu (např. Shakespeare)

GOPAS Praha

Kodaňská 1441/46
101 00 Praha 10
Tel.: +420 234 064 900-3
info@gopas.cz

GOPAS Brno

Nové sady 996/25
602 00 Brno
Tel.: +420 542 422 111
info@gopas.cz

GOPAS Bratislava

Dr. Vladimíra Clementisa 10
Bratislava, 821 02
Tel.: +421 248 282 701-2
info@gopas.sk



Copyright © 2020 GOPAS, a.s.,
All rights reserved

Tvorba LLM (Large Language Models) v jazyce Python

- Generování textu
- Výstup dne: model generující krátké texty

Transformer architektura

- Attention mechanismus
- Self-attention
- Multi-head attention
- Positional encoding
- Encoder vs Decoder
- Proč je transformer škálovatelný
- Implementace mini-transformera
- Vytvoření malého GPT-like modelu
- Trénink na malém datasetu
- Výstup dne: fungující mini GPT model

Trénink, fine-tuning a práce s hotovými modely

- Pretraining vs Fine-tuning
- Transfer learning
- LoRA a parameter-efficient fine-tuning (PEFT)
- Tokenizéry (BPE)
- Použití knihovny Hugging Face Transformers
- Fine-tuning malého modelu
- Práce s modely (např. LLaMA / kompatibilní open-source modely dle dostupnosti)
- Vytvoření vlastního chatbot skriptu
- Výstup dne: fine-tuned model na vlastních datech

RAG, nasazení a produkční aspekty

- Embeddingy pro vyhledávání
- Vektorové databáze (FAISS)
- RAG architektura
- Latence a optimalizace
- Kvantizace modelů
- Nasazení (API, Docker)
- Generování embeddingů
- Uložení do FAISS
- Implementace RAG pipeline
- Vytvoření jednoduchého API (FastAPI)
- Finální projekt: interní chatbot nad vlastními dokumenty

Používané technologie

- Python 3.11+
- PyTorch
- Hugging Face Transformers
- FAISS
- FastAPI
- Jupyter Notebook

Co si účastník odnese

- Rozumí, jak LLM fungují vnitřně a jaké jsou jejich stavební bloky
- Umí postavit jednoduchý transformer a mini GPT na malém datasetu
- Umí fine-tunovat model včetně LoRA/PEFT
- Umí postavit RAG aplikaci nad vlastními dokumenty

GOPAS Praha

Kodaňská 1441/46
101 00 Praha 10
Tel.: +420 234 064 900-3
info@gopas.cz

GOPAS Brno

Nové sady 996/25
602 00 Brno
Tel.: +420 542 422 111
info@gopas.cz

GOPAS Bratislava

Dr. Vladimíra Clementisa 10
Bratislava, 821 02
Tel.: +421 248 282 701-2
info@gopas.sk



Copyright © 2020 GOPAS, a.s.,
All rights reserved

Tvorba LLM (Large Language Models) v jazyce Python

- Umí nasadit model jako API a chápe základní produkční aspekty (latence, optimalizace, kvantizace)

GOPAS Praha
Kodaňská 1441/46
101 00 Praha 10
Tel.: +420 234 064 900-3
info@gopas.cz

GOPAS Brno
Nové sady 996/25
602 00 Brno
Tel.: +420 542 422 111
info@gopas.cz

GOPAS Bratislava
Dr. Vladimíra Clementisa 10
Bratislava, 821 02
Tel.: +421 248 282 701-2
info@gopas.sk



Copyright © 2020 GOPAS, a.s.,
All rights reserved