


Integrácia a nasadenie softvérových aplikácií 2

Peter Bednár

Vývojové prostredie

Vývojové prostredie (1)



Vývojové prostredie (2)

Integrované prostredie = dáta + kód + modely +
infraštruktúra

- Riadiaca platforma celého životného cyklu strojového učenia, ktorá umožňuje spoľahlivé experimentovanie, reprodukovateľnosť, spoluprácu a nasadenie

Vývojové prostredie - požiadavky (1)

- Produktivita a experimentovanie
- Vývojové prostredie poskytuje nástroje, ktoré umožňujú rýchlu iteráciu nápadov:
 - Interaktívne programovanie (napr. notebooky, IDE),
 - Okamžitú spätnú väzbu o správaní modelu,
 - Rýchle prototypovanie
- Skrátenie cyklu experiment–vyhodnotenie–zlepšenie, čo je v ML zásadné, keďže rozhodnutia sú založené na empirických výsledkoch

Vývojové prostredie - požiadavky (2)

- Spracovanie a prieskum dát
- Systémy strojového učenia sú orientované na dáta. Prostredie musí podporovať:
 - Získavanie dát z rôznych zdrojov
 - Čistenie, transformáciu a tvorbu atribútov
 - Exploračnú analýzu dát (EDA) a vizualizáciu

Vývojové prostredie - požiadavky (3)

- Vývoj a tréning modelov
- Vývojové prostredie umožňuje:
 - Implementáciu algoritmov pomocou ML knižníc a rámcov
 - Využitie hardvérovej akcelerácie (GPU/TPU)
 - Konfiguráciu nastavení algoritmov (hyper-parametrov) a tréningových pipeline-ov
- Abstrahuje nízkoúrovňovú zložitosť, aby sa vývojári mohli sústrediť na logiku modelu namiesto infraštruktúry

Vývojové prostredie - požiadavky (4)

- Správa závislostí a prostředí
- Vývojové prostredie musí zabezpečiť čo najväčšiu reprodukovateľnosť:
 - Správa verzií kódu
 - Konzistentné verzie knižníc
 - Izolované prostredia (napr. virtuálne prostredia, kontajnery)

Vývojové prostredie - požiadavky (5)

- Sledovanie experimentov a reprodukovateľnosť
 - Okrem sledovanie verzií kódu je potrebné sledovať verzie dát a modelov
 - Sledovanie experimentov (metriky, nastavenia algoritmov, artefakty, ako sú napr. dáta v jednotlivých fázach spracovania, modely alebo vizualizácie a reporty z vyhodnotenia)

Vývojové prostredie - požiadavky (6)

- Testovanie a validácia
- Okrem metrík presnosti prostredie podporuje:
 - Jednotkové a integračné testy dátových pipeline-ov
 - Validáciu predpokladov modelu
 - Kontroly zaujatosti, robustnosti a meranie škálovateľnosti

Vývojové prostredie - požiadavky (7)

- Spolupráca a škálovanie tímu
- Pri tímovom vývoji ML prostredie umožňuje:
 - Zdieľané kódy a dátové množiny
 - Štandardizované pracovné postupy
 - Zdieľanie znalostí medzi doménovými expertmi a dátovými analytikmi

Vývojové prostredie - požiadavky (8)

- Nasadenie a integrácia MLOps
- Kontinuálne prepojenie s produkčným prostredím:
 - Príprava inštalačného balíka pre inferenciu
 - CI/CD pipeline pre ML
 - Monitorovanie výkonu po nasadení
 - Integrovanie spätnej väzby od používateľov

Správa závislostí a prostředí

Sledovanie verzií kódu

- Systém na sledovanie zmien v zdrojovom kóde v čase
 - Nie len zdrojový kód ale aj ďalšie textové artefakty (konfiguračné súbory, dokumentácia, inštalačné skripty)
- Uchováva kompletnú históriu úprav
- Umožňuje návrat k predchádzajúcim verziám
- Podporuje tímovú spoluprácu a umožňuje paralelný vývoj
- Zlepšuje kvalitu kódu

Úvod do Git

- Distribuovaný systém správy verzií (DVCS)
- Navrhnutý pre rýchlosť, efektivitu a škálovateľnosť
- Každý vývojár má kompletnú lokálnu kópiu repozitára
- Široko používaný v modernom vývoji softvéru



Základné pojmy v Git

- **Repozitár** – úložisko projektu s históriou
- **Commit** – snímka zmien v kóde
- **Branch** (vetva) – samostatná línia vývoja
- **Merge** – zlúčenie zmien z vetiev
- **Tag** – pomenované označenie snímky kódu (napr. číslom verzie)



Základný pracovný tok Git

1. **clone** - vytvorenie lokálnej kópie, alebo **pull** načítanie zmien z repozitára
 2. zmena kódu
 3. **commit** zmien (zaznamenaných lokálne)
 4. **push** odoslanie zmien do repozitára
- Je možné vytvoriť samostatnú vetvu vývoja (**checkout**) pre novú funkčnosť
 - Hlavná vetva zostáva stabilná, vo vývojovej vetve je možné experimentovať
 - Konflikty sa riešia pri zlúčení (**merge**)




GitHub

- **GitHub** je cloudová platforma na hostovanie Git repozitárov
- Umožňuje spoluprácu vývojárov na diaľku
- Poskytuje nástroje ako:
 - Pull Requests
 - Code Review
 - Issues (sledovanie úloh a chýb)
 - CI/CD pipeline (automatizované testovanie a nasadenie)
- Často sa používa na open-source aj komerčné projekty




Správa prostredia

Programové prostredie




- Základné požiadavky na programové prostredie
 - Efektívne využívanie výpočtových zdrojov
 - Škálovateľnosť
 - Flexibilita pri nasadení
 - Jednoduchá údržba
 - Prenositelnosť
 - Bezpečnosť

Virtualizácia



Kontajnerizácia



Virtualizácia vs Kontajnerizácia

Virtualizácia

- Silná izolácia zátáže a vyššia miera bezpečnosti
- Podpora rôznych operačných systémov na jednom hostiteľovi

Kontajnerizácia

- Efektívnejšia réžia
- Rýchlejší štart/reštart aplikácií
- Vyššia hustota izolovaných aplikácií na jednom hostiteľskom serveri
- Optimalizované prostredie pre (mikro)služby

Docker

- Kontajnerové prostredie, ktoré umožňuje vytváranie a spúšťanie kontajnerov
- Základné pojmy
 - **Image** (obraz) – uložená kópia konfigurovaného prostredia, ktorá slúži ako šablóna pri vytvorení kontajnera
 - **Dockerfile** – konfiguračný súbor, ktorý definuje ako má byť image zostavený
 - **Docker image repozitár** – úložisko ktoré umožňuje zdieľanie image-ov



Konfigurácia kontajnerov – Dockerfile (1)

- Textový konfiguračný súbor na základe ktorého Docker vytvorí image
- Základné príkazy:
 - **FROM** – základný image (znovapoužiteľnosť/rozšíriteľnosť)
 - **RUN** – spustenie programu pre konfiguráciu prostredia počas vytvárania image-u
 - **COPY** – pridávanie súborov do image-u
 - **CMD/ENTRYPOINT** – definuje, ktorý program sa má spustiť pri spustení kontajnera



Konfigurácia kontajnerov – Dockerfile (2)

```
FROM python:3.12-slim  
  
COPY requirements.txt .  
RUN pip install -r requirements.txt  
  
COPY app.py .  
  
CMD ["python", "app.py"]
```

`docker build -t peterbednar/hello-world:0.1.0 .`

`docker container run peterbednar/hello-world:0.1.0`



DockerHub


- Oficiálna kladová služba Docker
- Prednastavený repozitár pre zdieľanie image
- Oficiálne verzie pre viacero štandardných aplikácií

```
docker image push peterbednar/hello-world:0.1.0
```

```
docker image pull peterbednar/hello-world:0.1.0
```



Docker prostredie – zhrnutie




Správa verzii

Sémantické označovanie verzií


- Štandardizovaná schéma pre označovanie verzií
 - Napr. numpy 2.4.2

MAJOR . MINOR . PATCH



Manažovanie Python prostredia – pip

- pip
 - Základný program pre inštalovanie balíkov (knihnice/aplikácie) v Python prostredí
 - Balíky sú stiahnuté z repozitárov
 - PiPy – oficiálny repozitár
 - Inštalácia priamo z git alebo z privátnych repozitárov
 - Manažuje iba balíky pre Python (nie samotnú inštaláciu Python interpretera)



Manažovanie Python prostredia – conda

- conda
 - Cross-platformový manažér prostredia
 - Manažuje nie len Python balíky ale aj Python verzie a binárne závislosti (ostatné aplikačné knižnice napr. v C/C++)
 - Využíva vlastnú sieť repozitárov (napr. conda-forge), ale umožňuje aj inštaláciu cez pip
 - Populárny pre dátovú analytiku a ML



Manažment balíkov – pip

```
pip install numpy  
pip install "numpy==2.4.1"  
pip install "numpy==2.4.*"  
pip install "numpy>=2.3,<2.4.1,!2.3.8"
```

```
pip install -r requirements.txt
```

```
numpy  
pandas==3.0.1  
scikit-learn 1.8.0  
...
```

```
pip list  
pip uninstall numpy
```



Manažment balíkov – conda

```
conda install numpy  
conda install "numpy=2.4.1"  
conda install "nypmy=2.4.*"  
conda install "numpy>=2.3,<2.4.1,!2.3.8"
```

```
conda list  
conda remove numpy
```



Virtuálne Python prostredia (1)

- Umožňujú lokálne vivíjať viacero projektov s rôznymi závislosťami a replikovať Python prostredie

- `pip`

```
python -m venv myenv
```

```
source myenv/bin/activate
```

```
myenv\Scripts\activate
```

```
pip install numpy pandas  
python app.py
```



Virtuálne Python prostredia (2)

- conda

```
conda create -n myenv python=3.11
```

```
conda activate myenv
```

```
conda install numpy pandas
```

```
python app.py
```



Virtuálne Python prostredia (3)

- conda

conda create -f environment.yml

```
name: myenv
channels:
  - conda-forge
dependencies:
  - python=3.11
  - numpy
  - pandas
  ...
```



Stabilné softvérové prostredie (1)

app.py

- pandas
- scikit-learn=1.7.2

app.py
pandas 2.3.1
scikit-learn 1.7.2
numpy 1.3.8

pandas 2.3.1

- numpy>=1.2.6

...

scikit-learn 1.7.2


- numpy>=1.3
- pandas>=2.0

...


numpy 1.3.8**numpy 1.3.7**

...


Stabilné softvérové prostredie (2)



app.py
pandas 2.3.1
scikit-learn 1.7.2
numpy 2.0.0



...



...



...

Ak niektorá závislosť (aj nepriama)
zavedie nekompatibilnú zmenu,
môže to spôsobiť chybu v našej
aplikácii

Stabilné softvérové prostredie (3)

app.py

- pandas=2.3.1
- scikit-learn=1.7.2
- numpy=1.3.8

app.py
pandas 2.3.1
scikit-learn 1.7.2
numpy 1.3.8

Bezpečnejšie je špecifikovať verzie všetkých závislostí (aj keď ich priamo nevyužívame v našom kóde)

pandas 2.3.1

- numpy>=1.2.6

...

scikit-learn 1.7.2


- numpy>=1.3
- pandas>=2.0

...

numpy 2.0.0**numpy 1.3.8**

...

Privátne repozitáre



Sonatype Nexus, AWS CodeArtifact, GitHub packages, ...