

Pokročilé algoritmy na segmentáciu astronomických snímok kozmického odpadu

Daniel Kyselica

Vedúci: Mgr. Stanislav Krajčovič

Téma

Návrh a implementácia pokročilých algoritmov za účelom extrahovania pozícií kozmického odpadu z astronomických CCD snímok

Motivácia

Oddelenie Astronómie a
Astrofyziky fakulty Matematiky
fyziky a informatiky UK v
Bratislave

Disponuje teleskopom
využívaním na snímanie nočnej
oblohy


Vesmírny odpad sa stáva veľkým
problémom, preto je potrebné
sledovať tieto objekty



System

Existujúci systém spracováva astronomické snímky a lokalizuje pohybujúce sa objekty na obežnej dráhe.

Získané informácie sú následne použité pri výpočte obežnej dráhy objektu a určení jeho trajektórie




Pokrok práce

Generovanie dát

Pre tréovanie hlbokej neurónovej siete je potrebné veľké množstvo dát. Získať takéto množstvo označených dát je veľmi časovo náročné. Preto budeme využívať generátor, ktorý generuje tieto snímky.

Generátor vytvára snímok s nastaviteľným počtom nehybných hviezd a pohybujúcich sa objektov




Na implementáciu Hlbokej neurónovej siete budem používať knižnicu PyTorch pre Python. Jej výhodou je možnosť upravovať architektúru siete veľmi pružne. Obsahuje implementácie väčšiny funkcií, ktoré sú potrebné pri vytváraní siete.

```
class CNNNet(nn.Module):  
  
    def __init__(self, num_classes=2):  
        super(CNNNet, self).__init__()  
        self.features = nn.Sequential(  
            nn.Conv2d(3, 64, kernel_size=11, stride=4, padding=2),  
            nn.ReLU(),  
            nn.MaxPool2d(kernel_size=3, stride=2),  
            nn.Conv2d(64, 192, kernel_size=5, padding=2),  
            nn.ReLU(),  
            nn.MaxPool2d(kernel_size=3, stride=2),  
            nn.Conv2d(192, 384, kernel_size=3, padding=1),  
            nn.ReLU(),
```

Konvolučná neurónová sieť


Pri spracovaní obrazu sa ukázala konvolučná sieť ako dobrá voľba. Obraz je spracovaný prostredníctvom konvulučných vrstiev, ktoré pomocou filtrov vytvárajú projekciu obrazu s N kanálmi do nového priestoru s K kanálmi. V tomto novom obraze sú viac zachytené vzťahy medzi susednými pixelmi, obsahujú aj informáciu o nejakom vzore v mriežke napr. diagonála.



Rekurentná sieť


Pri vyhľadávaní pohybujúceho sa objektu na snímke je dôležité poznať polohu objektov na predchádzajúcich snímkach. Až z tejto informácie je možné určiť trajektóriu a rýchlosť pohybujúceho sa objektu.

Na tento účel sa hodia rekurentné siete, ktoré vedú spracovávať aj sekvencie napríklad obrázkov




Obojsmerné LSTM

Na spracovanie sekvenčnej informácie použijem obojsmerné LSTM, long short term memory, ktoré dokážu získať informáciu z predchádzajúcich aj budúcich snímok sekvencie.



Segmentácia

Pri segmentácii je dôležité detegovať objekty na snímku. Snímky obsahujú šum ktorý sťažuje rozpoznanie menej jasných a menších objektov.



Najlepšie výsledky pri segmentácii dosahujú hlboké konvolučné siete. Táto metóda je však náročná na trénovací čas. Preto zatiaľ používame existujúcu segmentáciu.

Testovanie

Výsledky práce budú priamo porovnávané s výsledkami existujúceho systému.

Presnosť detekcie spolu s časom spracovania bude kľúčová.

Ďakujem za
pozornosť

