

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



Úloha

Vytvorenie trackletu

- zoznam pozícií pohybujúceho sa objektu (po priamke) na snímkach

```
17 --FILENAME RA DEC RA[deg] DEC[deg] X Y MJD MAG ERROR_MAG ADU ERROR_ADU EXP_TIME FILTER TIME[mpc] TIME[tdm]--
18
19 03005A_1_R-0001_m_s_a_m 06 34 22.62335 +11 12 54.87 98.5942639 11.2152412 498.96 534.77 59159.159783461 -07.33 0.166 858.0 358.016 0.1 R 2020 11 06.15978 2020-11-06T03:50:05.241
20 03005A_1_R-0002_m_s_a_m 06 34 26.47402 +11 11 30.15 98.6103084 11.1917079 499.63 534.14 59159.159817292 -07.27 0.157 810.0 318.650 0.1 R 2020 11 06.15981 2020-11-06T03:50:08.164
21 03005A_1_R-0003_m_s_a_m 06 34 30.44493 +11 10 03.83 98.6268539 11.1677296 499.35 534.82 59159.159851157 -07.22 0.170 771.0 330.105 0.1 R 2020 11 06.15985 2020-11-06T03:50:11.090
22 03005A_1_R-0004_m_s_a_m 06 34 34.49119 +11 08 40.19 98.6437133 11.1444982 498.75 534.28 59159.159888485 -07.33 0.168 857.0 362.170 0.1 R 2020 11 06.15988 2020-11-06T03:50:14.001
23 03005A_1_R-0005_m_s_a_m 06 34 38.25908 +11 07 13.45 98.6594128 11.120404 500.87 535.73 59159.159918507 -08.00 0.162 1578.0 642.366 0.1 R 2020 11 06.15991 2020-11-06T03:50:16.909
24 03005A_1_R-0006_m_s_a_m 06 34 42.12367 +11 05 48.52 98.6755153 11.0968117 500.75 534.60 59159.159952569 -07.93 0.199 1492.0 745.245 0.1 R 2020 11 06.15994 2020-11-06T03:50:19.852
25 03005A_1_R-0007_m_s_a_m 06 34 45.96403 +11 04 24.88 98.6915168 11.0735773 502.24 534.28 59159.159986215 -07.92 0.170 1473.0 630.443 0.1 R 2020 11 06.15998 2020-11-06T03:50:22.759
26 03005A_1_R-0008_m_s_a_m 06 34 49.90806 +11 03 00.84 98.7079503 11.050233 501.31 533.89 59159.160020104 -07.27 0.146 811.0 296.887 0.1 R 2020 11 06.16001 2020-11-06T03:50:25.687
27 03005A_1_R-0010_m_s_a_m 06 34 57.71165 +11 00 08.85 98.7404652 11.0024594 502.19 534.77 59159.160087801 -07.86 0.173 1397.0 605.976 0.1 R 2020 11 06.16008 2020-11-06T03:50:31.536
28 03005A_1_R-0011_m_s_a_m 06 35 01.74807 +10 58 44.83 98.7572836 10.9791201 501.02 534.63 59159.160121667 -07.92 0.155 1467.0 570.680 0.1 R 2020 11 06.16012 2020-11-06T03:50:34.462
29 03005A_1_R-0012_m_s_a_m 06 35 05.56995 +10 57 17.55 98.7732081 10.9548748 503.11 534.40 59159.160155937 -07.85 0.155 1384.0 538.392 0.1 R 2020 11 06.16015 2020-11-06T03:50:37.423
30 03005A_1_R-0013_m_s_a_m 06 35 09.54446 +10 55 54.62 98.7897686 10.9318394 502.84 533.36 59159.160189826 -07.94 0.153 1500.0 577.302 0.1 R 2020 11 06.16019 2020-11-06T03:50:40.351
31 03005A_1_R-0015_m_s_a_m 06 35 17.35237 +10 53 03.61 98.8223016 10.8843358 503.35 533.87 59159.160257292 -07.21 0.162 763.0 310.689 0.1 R 2020 11 06.16025 2020-11-06T03:50:46.180
32 03005A_1_R-0016_m_s_a_m 06 35 21.25465 +10 51 37.53 98.838561 10.8604245 504.30 534.44 59159.160291192 -07.38 0.147 892.0 329.704 0.1 R 2020 11 06.16029 2020-11-06T03:50:49.109
33 03005A_1_R-0017_m_s_a_m 06 35 25.28267 +10 50 12.61 98.8553445 10.8368352 502.77 534.36 59159.160325046 -07.98 0.153 1554.0 598.085 0.1 R 2020 11 06.16032 2020-11-06T03:50:52.034
34 03005A_1_R-0018_m_s_a_m 06 35 29.11415 +10 48 46.40 98.871309 10.81289 503.81 535.64 59159.160358993 -07.15 0.162 722.0 293.994 0.1 R 2020 11 06.16035 2020-11-06T03:50:54.967
35 03005A_1_R-0019_m_s_a_m 06 35 33.08194 +10 47 24.10 98.8878414 10.7900286 503.91 533.62 59159.160392639 -07.32 0.140 848.0 299.223 0.1 R 2020 11 06.16038 2020-11-06T03:50:57.874
36 03005A_1_R-0020_m_s_a_m 06 35 36.80111 +10 45 58.88 98.903338 10.7663543 505.42 533.77 59159.160426273 -07.92 0.168 1476.0 623.550 0.1 R 2020 11 06.16042 2020-11-06T03:51:00.780
```

Dáta

Dáta pochádzajú z existujúceho systému vo forme .tsv súborov


- Pre každú snímku zo série existuje jeden .tsv súbor
- Jeden riadok reprezentuje objekt - jeho pozíciu a vlastnosti

	A	B	C	D	E	F	G	H	I	
1	cent.x	cent.y	snr	iter	sum	mean	var	std	skew	kurt
2	2.621771218	108.2896679	3.872983346	7	399	3.069230769	13.27423971	3.643383004	1.141573369	
3	3.601214575	629.3947368	4.8	4	930	6.503496503	18.71653698	4.326261317	0.1621238932	
4	4.419413919	317.0164835	4.69041576	3	387	2.480769231	12.98672457	3.603709834	1.993516058	
5	6.415736041	376.2746193	9.327379053	3	1260	7.455621302	185.2495069	13.61063947	3.09808702	
6	28.08823529	965.4232737	5.196152423	3	580	3.431952663	24.47302057	4.947021384	1.965901736	
7	48.2808642	941.1358025	4.69041576	7	451	2.668639053	14.49668921	3.8074518	1.794717769	
8	49.3483965	727.7381516	4.242640687	7	515	3.047337278	16.4501268	4.055875589	1.584614332	
9	50.09885387	667.726361	4.902903378	6	1287	7.615384615	15.02380952	3.876055924	-0.1206207583	
10	50.27936963	702.1733524	4.795831523	5	506	2.99408284	16.02972668	4.003714111	1.696527619	
11	50.28881988	686.2329193	4.902903378	6	1259	7.449704142	16.18941955	4.023607778	0.06461143223	
12	50.76388889	168.8305556	4.8	8	1217	7.201183432	16.36404621	4.045249833	-0.1411101464	
13	51.35324232	114.7491468	4.69485534	4	1209	7.153846154	16.29761905	4.037030969	-0.1782781499	

Generovanie trénovacích dát

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

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



Prvým návrhom riešenia bolo použitie SVM (Support vector machines) na klasifikáciu či sa dané pozície nachádzajú na priamke



Problém

Aj napriek vysokej presnosti klasifikátora (okolo 97 %) nebolo možné identifikovať pohybujúci sa objekt

- Veľký počet permutácií stacionárnych objektov
- Existuje cesta z každého koncového bodu do každého počiatočného

Rekurentná sieť

Pre spracovanie sériových snímok je veľmi vhodná rekurentná neurónová sieť


Dokáže si uchovať závislosti medzi jednotlivými vstupmi a použiť ich pri konštrukcii výsledku

Pre implementáciu bol použitý Pytorch


```
class AlbertNet(nn.Module):  
  
    def __init__(self, hidden_size, input_size=2, num_layers=1):  
        super(AlbertNet, self).__init__()  
  
        self.LSTM = nn.LSTM(input_size=input_size, hidden_size=hidden_size, num_layers=num_layers)  
        self.final = nn.Linear(hidden_size, 2)  
  
    def forward(self, seq):  
        output, (hidden, _) = self.LSTM(seq)  
        output = torch.tanh(output[-1, :, :])  
        pred = self.final(output)  
  
        return pred
```

Trénovanie


Predikovanie koncovej pozície




Predikovanie vektora posunu



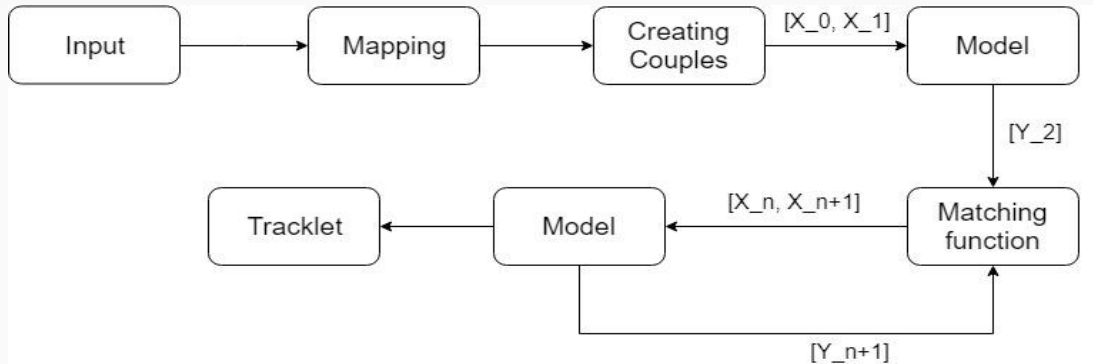
Predikovanie nasledujúcej pozície



Predikovanie vektora posunu



System a testovanie



Pri testovaní na 26 skutočných spracovaných seriách

- Správne určilo 25 trackletov
- Nesprávne určilo 0
- Čiastočne našlo 1

Pokračovanie a možné vylepšenia

- Obmedzená dĺžka sekvencií → Spájanie trajektórií
- Možnosť natrénovať sieť na zložitejšie krivky
- Možnosť použiť na klasifikáciu všetkých objektov aj stacionárnych

Ďakujem za
pozornosť

