

# Első féléves beszámoló

Kunsági-Máté Sándor

E-mail: kunsagisandor@gmail.com

PhD program: Részecskefizika és csillagászat

Témavezető: Dobos László

A dolgozat címe: Gépi tanulás a csillagászatban

2019. január 21.

## 1. Bevezetés

Az utóbbi években egyre népszerűbbé váltak a gépi tanulási módszerek - ezen belül is az ún. Deep Learning - a tudomány és a mindennapi élet számos területén.

Deep Learning módszereket a csillagászatban manapság leginkább a vöröseltolódást becslő eljárásoknál használják. A fotometrikus vöröseltolódás becslés az egyik legfontosabb feladat a különböző égboltfelmérési programok (SDSS, DES) által mért nagymennyiségű adathalmazok feldolgozásakor. Ezek az adatbázisok többek között különböző színű szűrőkben szolgáltatnak felvételeket galaxisokról. A photo-z módszer során a mérésekből kiredukált színindexek alapján adunk becslést a vöröseltolódásra valamilyen gépi tanulási algoritmus alkalmazásával (pl.: K-nearest neighbors).

## 2. Kutatás az első félévben

A gyakorlatban sokszor előfordul, hogy a galaxisok látóirányába esnek más tejúttrendszerbeli csillagok (előtér csillagok) is. Emiatt a meghatározott színindexek nem csak az adott galaxishoz fognak tartozni, továbbá maga a galaxis sem egyetlen színkomponensből tevődik össze (pl. HII régiók), ezért az integrált magnitúdók használata hibát eredményezhet a fotometrikus vöröseltolódás számításában.

Jelenlegi kutatásom a DES adatbázisában megtalálható galaxisok képeinek színtérbeli szegmentációjára irányul. A fentebb említett problémára megoldást jelenthet, ha a galaxist előbb viszonylag homogén színű, ún. szuperpixelekre osztjuk fel, majd ezekre külön számoljuk ki a színindexeket. Lényegében olyan módszert keresünk, ami képes az adott galaxist különböző csillagpopulációkra bontani. Ezzel az eljárással várhatóan növelni tudjuk majd a photo-z

eljárások pontosságát. Számos képszegmentációs algoritmus ismert a szakirodalomban, mint például [1], [2], [3].

Kutatásom során a Shi& Malik ([2]) képszegmentációs algoritmus használhatóságát vizsgáltam meg, melyhez saját python szkriptet készítettem a különböző paraméterek finomhangolásának érdekében. Az eljárás legfontosabb lépései a következők:

1. egy  $N \times M \times C$  dimenziójú (szélesség  $\times$  hosszúság  $\times$  csatornák száma) bemeneti kép esetén egy  $(N \times M) \times (N \times M)$  dimenziójú  $W$  összekötöttségi súlymátrixot készítünk  
Megj.: ezzel lényegében egy gráfot hozunk létre  $G = (V, E)$ , mely csúcsai ( $V$ ) az egyes pixelek, élei ( $E$ ) pedig a pixelek közti hasonlósági kapcsolatot jellemző súlyok
2. a mátrix egyes elemeit egy úgynevezett súlyfüggvény alapján számoljuk ki, mely során a színtérben egymáshoz közel lévő pixeleket nagyobb súllyal vesszük figyelembe
3. a bemeneti képhez rendelt gráf két részre ( $A$  és  $B$ ) való szegmentálásához az ún. *normalized cut* ( $Ncut(A, B)$ ) mértéket definiáljuk:

$$Ncut(A, B) = \frac{cut(A, B)}{assoc(A, V)} + \frac{cut(A, B)}{assoc(B, V)}$$

, ahol:

- $cut(A, B) = \sum_{u \in A, v \in B} W(u, v)$
- $assoc(A, V) = \sum_{u \in A, t \in V} W(u, t)$


4. ezután megoldjuk a mátrix sajátértékproblémáját, ahol a második legkisebb sajátértékkel rendelkező sajátvektorral ( $v_i, i \in [1, N \times M]$ ) számolunk tovább (bizonyítás a [2] cikkben)
5. a sajátvektort két részre osztjuk egy küszöbérték ( $k$ ) alapján:  $A \in \{v_i < k\}$ ,  $B \in \{v_i \geq k\}$
6. a küszöbértéket folyamatosan változtatjuk egy adott felbontással a  $[min(v), max(v)]$  tartományon, majd a legkisebb  $Ncut(A, B)$  értékkel rendelkező vágást választjuk a szegmentálásnál
7. a kép további felosztásához az algoritmust rekurzív módon ismételtjük

Az eljárás finomításakor a legfontosabb lépés a súlyfüggvény definiálása. Az  $i$  és  $j$  pixelek közötti súly nagysága legyen a következő:

$$W_{ij} = e^{-\frac{\|F(i) - F(j)\|_2^2}{\sigma}}$$


Itt az  $F$  az úgynevezett "feature" vektort jelöli, mely elemei például lehetnek az egyes színindexek. Mivel a színeket alapvetően az egyes színszűrők különbségeiből határozzuk meg, ezért az SDSS-nél jobb minőségű DES képeken jelenlévő zaj is jelentős relatív zajt okoz a színtérben. Ennek kezelésére az egyik megoldás az lehet, ha az egyes súlyokat a relatív

zaj értékekkel súlyozzuk (vagyis a  $\sigma$  jelentse a relatív zajt). Az alábbi képeken láthatjuk a súlyozás jelentős hatását a sajátvektoron (1. ábra):



1. ábra. Bal oldalon: bemeneti kép, középen: sajátvektor a relatív zajjal való súlyozás nélkül, jobb oldalon: sajátvektor a relatív zaj figyelembevételével  
Megj.: csak a fehér körvonallal körbevett régióra alkalmaztam az algoritmust


Az így kapott sajátvektort felhasználva a következőt kapjuk az optimális vágásra (2. ábra):



2. ábra. A galaxis két illetve négy részre való szegmentálása

A bal oldali képen jól látható, hogy a pirossal körbevett terület pixelei közel megegyező, kék színűek. A központi fényes bulge és a külső sötétebb régiók pedig azért kerültek egy superpixelre, mivel a súlyfüggvényben a színindexekbeli távolságot vesszük figyelembe és nem a fényesség szerint szegmentálunk. Ennek legfőbb oka, hogy az azonos színű, de eltérő méretű csillagpopulációk fényességben különbözhetnek egymástól.

Ha az algoritmust mégegyszer megismételjük a jobb oldali ábrát kapjuk. Itt már dominánsabb a zaj, viszont a belső régióban spirálszerkezethez hasonló szegmentációt kapunk, ami már a hasonló csillagpopulációk elhelyezkedéséről adhat információt. A következőkben (3. ábra) a négy szegmenshez tartozó pixelek eloszlását láthatjuk a szín-szín diagramokon (G,R,I,Z szűrők felhasználásával), ahol az egyes adatpontok színe a 2. ábra jobb oldali képének színkódolásával konzisztens.



3. ábra. A szegmensek pixeleinek eloszlása a szín-szín diagramokon

Jól látható, hogy a piros és sárga színhez tartozó szegmensek egy viszonylag kompakt halmazt képeznek a diagramokon. A kék és zöld pontok viszont jobban elszórtak, ami a kisebb jel/zaj aránynak köszönhető.

### 3. Tervezett feladatok

A Shi&Malik algoritmus alapvetően kontrasztos képekre működik jól, így a bemeneti DES képek megfelelő transzformálása javíthat a módszer hatékonyságán. Ellenkező esetben más képszegmentációs algoritmusokat is meg fogok vizsgálni (pl. K-means klaszterezésen alapuló módszerek). A következő félév elejére várhatóan elkészül az optimális szegmentációs algoritmus. Ezt követően egy nagyobb adathalmazra meghatározzuk az egyes szegmensek színindexeit, melyet aztán egy neurális hálózat bemeneteként használunk fel. Mivel az SDSS adatbázissal ellentétben a DES nem szolgáltat spektroszkópiai úton mért vöröseltolódás értékeket, így a két adatbázis egymással átfedő részét fogom használni a neurális hálózat tanítására.

### 4. Elvégzett kurzusok a félévben

- Csillagászati Adatbázisok (FIZ/2/108E), oktató: Dobos László
- High Energy Astrophysics (FIZ/2/118), oktató: Werner Norbert
- Physics of the Solar Atmosphere (FIZ/2/071E), oktató: Petrovay Kristóf

### 5. Oktatási tevékenység a félévben

- Programozási alapismeretek (progalapf17va), csütörtöki laborgyakorlatok

## Hivatkozások

- [1] P. Perona and W. T. Freeman. A factorization approach to grouping. In H. Burkardt and B. Neumann, editors, Proc ECCV, pages 655-670, 1998.
- [2] J. Shi and J. Malik. Normalized cuts and image segmentation. In Proc. IEEE Conf. Computer Vision and Pattern Recognition, pages 731-737, 1997.
- [3] G.L. Scott and H. C. Longuet-Higgins. Feature grouping by relocalisation of eigenvectors of the proximity matrix. In Proc. British Machine Vision Conference, pages 103-108, 1990.