

# Bírálat

Bolla Marianna

*Clustering graphs and contingency tables with spectral methods*

című akadémiai doktori értekezéséről

Bolla Marianna értekezésének fő témája nagy gráfok szerkezetének és spektrális tulajdonságainak kapcsolatának megértése, valamint spektrális módszereket használó algoritmusok építése gráfokkal kapcsolatos feladatok megoldására. A nagyméretű hálózatok témaköre az utóbbi tizenöt-húsz évben az alkalmazott matematika egyik sokat kutatott területévé vált, amit részben az informatikai hálózatok (internet, közösségi hálózatok) kiépülése motivált. Ezeknek a gráfoknak a globális szerkezetének feltárásában az egyik fontos tényező a sűrűbben összekötött részek, klaszterek megtalálása – mind elméleti, mind gyakorlati, algoritmikus szempontból. A dolgozat ilyen jellegű feladatokat old meg a gráf Laplace-mátrixának, illetve modularitásmátrixának spektrumát vizsgálva.

Az első fejezet bevezeti az értekezésben használt alapvető fogalmakat, valamint bemutatja a szerző dimenziócsökkentéssel kapcsolatos eredményeit. Itt tehát az a cél, hogy egy  $n$  csúcsú gráfot (melynek adjacenciamátrixa  $n \times n$  méretű),  $n$  darab, de  $n$ -nél jóval kisebb dimenziós vektorral reprezentáljunk úgy, hogy az egymással összekötött csúcsokhoz tartozó vektorok minél közelebb kerüljenek egymáshoz az alacsonyabb dimenziós térben. Súlyozott gráf esetén pedig minél nagyobb súlya van a két csúcs közötti élnek, annál közelebb kell, hogy kerüljenek, a megoldandó minimalizálási feladatban. A szerző tárgyalja a súlyozott négyzetes mátrixok, illetve a kontingenciátáblázatok esetét, a főkomponens-analízishez hasonlóan megmutatva, hogy különféle, a klasszikustól eltérő (pl. a modularitásmátrixsszal megfogalmazott) feladatokban hogyan kapható meg az optimális reprezentáció a sajátvektorokból. Ezek az általánosítások az alkalmazások szempontjából is figyelemre méltók lehetnek, hiszen például biológiai, genetikai feladatokban előfordulhat, hogy két különböző halmaz közötti kapcsolatokat kell modellezni, illetve hogy nem csak a kapcsolat megléte, hanem annak erőssége is fontos jellemzője a vizsgált rendszernek. Ezen kívül a szerző a modularitás-mátrixnak a gráf szerkezetével való kapcsolatát (pl. független halmazok) is vizsgálja, többek között a Hoffmann-korláttal rokon állításokat bizonyítva. A fő eredményeket bizonyos Hilbert-tér értékű operátorokra is általánosítja, megkeresve a lineáris algebrával, optimalitási tételekkel megfogalmazott eredmények mélyebb, funkcionálanalízis-beli hátterét. A fejezet főbb eredményei tehát a klasszikus eredmények modularitás-mátrixokra vonatkozó analógiái köré csoportosulnak.

A második fejezetben a szerző bizonyos véletlen mátrixok, a blokk-modell spektrumával kapcsolatos eredményeit ismerteti. Ez a véletlen gráf az Erdős–Rényi-gráfnak egy inhomogén általánosítása: a csúcsokat csoportokra osztjuk, majd a csúcspárokat véletlenül, függetlenül kötjük össze, úgy, hogy az egyes élek behúzásának valószínűsége csak attól függ, hogy a végpontok melyik csoportba tartoznak. Mivel erre úgy is gondolhatunk, mint egy fix mátrix perturbációja egy véletlen Wigner-mátrixszal, a (nagyobb) sajátérték elhelyezkedésére, távolságára vonatkozó eredmények (13–17. tételek) a véletlen mátrixok elméletének szempontjából is érdekesek lehetnek. A szerző ebben az esetben sem csupán a négyzetes mátrixokat, hanem a kontingenciátáblázatokot is vizsgálja, ahol a két dimenzió akár jelentősen is eltérhet. Az általánosítással

véletlen gráfoknak olyan tág, rugalmas családját kapjuk, melyek alkalmasak lehetnek többféle valós hálózat modellezésére is. A szerző több egyenlőtlenséget bizonyít a modularitásmátrix sajátértékei és egy, a kontingenciatáblázat diszkrepanciáját mérő mennyiség között, amivel a spektrum és a kombinatorikai struktúrák szerkezete között fennálló kapcsolatok jobb megértését segíti (ahogyan a Cheeger-egyenlőtlenség a klasszikus esetben). Az ilyen jellegű állítások szintén hasznosak lehetnek valós hálózatok modellezése során is.

A harmadik fejezetben először a modularitási mátrix spektrumának és a homomorfizmus-sűrűségeen alapuló gráflimesz-fogalomnak a viszonyát vizsgálja a szerző, többek között egy folytonossági tételt bizonyítva. Ezután ugyenebben a témakörben egy sejtést fogalmaz meg, mely a gráfkonvergenciát karakterizálná többek között a modularitási mátrix spektrumának, illetve az előző fejezetben szereplő diszkrepancia jellegű mennyiségeknek a segítségével (a sejtést a szerző egy, a disszertáció megszületése óta készült munkájában megcáfolta). Végül egy EM-típusú algoritmust javasol egy speciális véletlengráf-modell paramétereinek becslésére, azaz egy statisztikai feladatot old meg egy sokparaméteres, sűrű gráfban.

A dolgozat témaválasztása időszerű, a nagy hálózatok klaszterezettségével és spektrumával kapcsolatos kérdéseket sokan vizsgálják napjainkban. A dolgozatban a szerző (és néhol társszerzők) nevével jelzett tételeket új eredménynek fogadom el. Az értekezés jól felépített, és egységes képet ad a gráfok és kontingenciatáblázatok spektrumának elméletéről, illetve a lehetséges alkalmazásokról. A dolgozatban bemutatott számos eredmény közül sok olyan van (különösen a második fejezetben), amely önmagában is érdekes lehet a gráfok spektrálméletében. Ezzel párhuzamosan a szerző folyamatosan szem előtt tartja az alkalmazások szempontjait, az eredmények többségét jól körülírható, modellezési feladatokban előforduló eredmények motiválják. A bizonyítások során alkalmazott módszerek helyenként inkább klasszikusak, esetleg már ismert tételekre épülnek, máshol azonban több ötletet, mélyebb módszereket, kifinomultabb technikákat is igényelnek. A bőséges irodalomjegyzék és rengeteg megfelelő hivatkozás ellenére a dolgozatban nem találtam a szorosan kapcsolódó "community detection" témakör véletlen blokk-modellre vonatkozó fontos új eredményeire vonatkozó említést (például [4]). A második fejezetben érdemes lett volna kitérni arra, hogy az értekezésben ismertetett eredmények hogyan kapcsolódnak ehhez a friss kutatási irányhoz. A harmadik fejezetben javasolt becslési eljárással kapcsolatban jó lett volna részletesebben látni a valós adatokon, valós hálózatokon való eredményeket (akár azt is, hogy milyen méretű, milyen jellemzőkkel rendelkező hálózatokon történt az ellenőrzés), hiszen ezek lényeges információkat tartalmazhatnak az algoritmus alkalmazhatóságáról – ami ebben az esetben a cél lenne.

Összességében az értekezés eredményeit az akadémiai doktori fokozat követelményeinek megfelelőnek tartom, és javaslom a nyilvános védés kitűzését.

## **Kérdések.**

1. Az első fejezetben javasolt eljárások alkalmazását az értekezésben bemutatott képszegmentációs feladaton kívül sikerült-e más feladatokban is megvalósítani? Ha igen, mik a megközelítés előnyei az adott feladatban, és milyen nehézségek

adódnak a megvalósítás során?

2. A 2.3. szakaszban szereplő „multiway discrepancy” mennyiségnek (25. definíció) van-e valamilyen kapcsolata a gráfok vágás-normájával, illetve a jumble normával (lásd [2])?
3. Van-e valamilyen kapcsolat az értekezés második fejezetében szereplő, illetve az [1] survey cikk 3.4., illetve 4.6. szakaszában ismertetett eredmények között? Az értekezésben szereplő eredményekből esetleg lehet-e következtetést levonni a rekonstruálhatóság kritikus értékére?
4. A harmadik fejezet harmadik részében szereplő  $\alpha$ -modellhez hasonlóan tekinthetnénk egy olyan véletlen gráfot, melyet egy speciális grafonból, egy lépcsős függvényből sorsolunk (a [3] cikkben definiált értelemben). Módosítható-e a dolgozatban szereplő EM-algoritmus úgy, hogy ennek a véletlen gráfnak a paramétereinek becslésére adjon egy jó eljárást? Ha nem, mi lenne ennek a fő akadálya?

## Hivatkozások

- [1] E. Abbe. Community detection and stochastic block models: recent developments. Kézirat. arXiv:1703.10146.
- [2] D. Kunszenti-Kovács, L. Lovász and B. Szegedy. Multigraph limits, unbounded kernels, and Banach space decorated graphs. Kézirat. arXiv:1406.7846.
- [3] L. Lovász and B. Szegedy. Limits of dense graph sequences, *J. Combin. Theory Ser. B* **96** (2006), no. 6, 933–957.
- [4] E. Mossel, J. Neeman and A. Sly. Reconstruction and estimation in the planted partition model, *Probab. Theory Related Fields* **162** (2015), no. 3-4, 431–461.

Budapest, 2017. április 18.

Backhausz Ágnes  
Eötvös Loránd Tudományegyetem