

EÖTVÖS LORÁND TUDOMÁNYEGYETEM

TERMÉSZETTUDOMÁNYI KAR

Micskó Máté Benedek

**PONTOS ALGORITMUSOK NP-NEHÉZ
FELADATOKRA**

Szakdolgozat

Matematika BSc

Témavezető:

Szabó Dániel Péter

Operációkutatási tanszék



Budapest, 2025

Köszönetnyilvánítás

Nagyon hálás vagyok Szabó Dániel Péternek, a témavezetőmnek a témaötletért, a félév során nyújtott segítségéért és idejéért, amikkel lehetővé tette a szakdolgozatom létrejöttét.

Tartalomjegyzék

1. Bevezetés	4
1.1. Pontos algoritmusok	4
1.2. Data Reduction	5
2. Measure & Conquer	6
2.1. Branch & Reduce algoritmusok	7
2.2. Random lokális keresés	9
2.2.1. Programok	10
3. Directed Multiway Cut	16
3.1. Problémakör	16
3.2. Mingyu Xiao Algoritmus	17
3.3. Javított algoritmus	21
4. Alkalmazás	25
4.1. Minimális domináló halmaz	25
5. Összefoglalás	28

1. Bevezetés

1.1. Pontos algoritmusok

A pontos algoritmusok célja, hogy pontos megoldást találjanak NP-nehéz problémákra a lehető legrövidebb legrosszabb-esetbeli futásidővel. Ezzel a területtel a hatvanas, hetvenes években kezdtek el foglalkozni (Held és Karp 1962; Tarjan és Trojanowski 1977), és az utóbbi években egyre több figyelmet kapott, és kap a mai napig. Több okot is fel lehet sorolni a pontos algoritmusok népszerűségére:

- Vannak gyakorlati alkalmazások, ahol szükséges a pontos megoldás megtalálása.
- Sok problémát nehéz közelíteni, vagy a lehetséges közelítés nem elég jó. Például a maximális független csúcshalmaz számát nehéz $O(n^{1-\varepsilon})$ pontossággal becsülni, tetszőleges $\varepsilon > 0$ konstansra, ha $P \neq NP$.
- Az exponenciális futásidő alapját csökkenteni, például elérni $O(2^n)$ helyett $O(1.9^n)$ futásidőt, növeli az adott időn belül megoldható probléma méretét egy multiplikatív konstanssal. Míg gyorsabb gépek használatával csak (kis) additív konstanst lehet elérni.
- A pontos algoritmusok felépítése és analízise segít jobban megérteni az NP-nehéz problémákat. Létrehoz új és érdekes kombinatorikai és algebrai kihívásokat.

Az egyik legfontosabb technika pontos algoritmusok felépítésére a Branch & Reduce – elágazás és csökkentés –, ami Davis és Putman 1960-as cikkére ([5]) vezethető vissza. Ez a módszer bevezet csökkentési szabályokat, amikkel leegyszerűsíti az elágazáskor keletkező részproblémákat, amiket aztán rekurzívan megold. Ugyanakkor nem használ alsó becslést, mint a Branch & Bound. Utóbbiról a továbbiakban nem lesz szó, mert az az elméleti optimum helyett inkább a tapasztalati problémákra (konkrét esetekben) ad kis futásidőt.

1.2. Data Reduction


Az NP-nehéz feladatok pontos megoldása nagy számítási feladat. Ezért sok egyszerűítést és trükköt, azaz adatcsökkentést vezettek be, amik hatékonyabbá teszik a megoldó algoritmusokat. Az adatcsökkentő szabályok polinom idejű műveletek, amik lecsökkentenek egy problémát úgy, hogy a megmaradó feladat optimális megoldása könnyen kiterjeszthető az eredeti feladat optimális megoldására. Ezek az adatcsökkentési szabályok különösen hasznosnak bizonyultak elágazási algoritmusoknál, ahol jó csökkentések gyorsan megoldható problémákhoz vezetnek. Ilyen módszer a Measure & Conquer is, amit sok más adatcsökkentési szabállyal párhuzamosan használva, a már javított hatékonyságú algoritmuson is lehet javítani.

2. Measure & Conquer

A sokat használt Branch & Reduce algoritmus, mint fent utaltam rá, az eddigi egyik legjobb eszköz az NP-nehéz feladatok pontos megoldására. Azonban kijelenthetjük, hogy az ilyen rekurzív algoritmusok analízise még mindig távol áll attól, hogy szoros alsó határt adjon a legrosszabb futásidőre. Éppen ezért, ennek javítására jött létre a Measure & Conquer, ami a standardhoz képest új mértéket ad a különböző részproblémáknak; ezzel kihasználva az algoritmus sajátosságait egy jobb alsó becslés érdekében.

Nem standard mérték. Az NP-nehéz feladatokra adott leggyorsabb algoritmusok általában bonyolultak; sok-sok nem triviális elágazást és szabályt tartalmaznak, amiket mély esetszétválasztással hoztak létre. Azonban az analízisük annál egyszerűbb. Van egy (standard) mérték a részproblémák méretére (pl.: gráfok csúcsainak vagy élének száma). Ez a mérték ad alsó határt a műveleteknek minden elágazási lépésnél.

A Measure & Conquer ennek a mértéknek a megválasztására fókuszál. Hiszen, ahogy később látni fogjuk, egy jobb mérték képes csökkenteni a futásidőt, akár nagy mértékben is. Ezt használja fel Mingyu Xiao a Directed Multiway Cut probléma megoldásában ([17]), és ennek az algoritmusnak a javításával fogok jobb időkorlátot adni ugyanerre a problémára. Megmutatva, hogy nem csak egy jó algoritmussal, és ahhoz egy jó mértékkel lehet jobb eredményt elérni, hanem olykor egy algoritmuson kicsit változtatva és a mértéken kicsit optimalizálva is. Összehasonlításképpen az eddigi eredmény futásideje $O(1.9967^n)$, míg a javítotté $O(1.9959^n)$. Ez is utal arra, amit [8]-ben megfogalmaztak, hogy még egy okosan választott mérték sem ad biztosan közel optimális analízist ; van helye a további javításoknak.



2.1. ábra. Az F gyökérből induló elágazás.

2.1. Branch & Reduce algoritmusok ([14] alapján)

Egy tipikus Branch & Reduce algoritmus egy F_0 kezdeti problémára a következőképpen jár el. Először végrehajt egy polinom idejű csökkentést $F_0 \rightarrow r(F_0)$, ahol $F := r(F_0)$ megoldását tekintve ekvivalens F_0 -al. Ha ez nem elég F_0 megoldhatóságának eldöntésére, akkor felosztja F -et részproblémákra φ_i szerint, a 2.1 ábrán látható módon. A φ_i elágazásokra igaz, hogy F megoldható ekvivalens azzal, hogy létezik i , amire $F_i := \varphi_i(F)$ megoldható. Az így keletkező T fának a levelei olyan állapotok, amiből a megoldás polinomiális időben kiszámolható, tehát a fa méretéből adódik a futásidő. Az ilyen algoritmusok analízise általában ugyanazzal a mértékkel történik, mint amivel aztán a futásidőt megadják (pl.: a gráf csúcsainak száma). Legyen ez a mérték μ és a probléma mérete $\mu(F) = n$. Ekkor T leveleinek a számát, $l(T)$ -t, elég fölülről becsülni, mert a futásidő $O^*(l(T))$; a levelek számától függ. Legyen $\Phi(F, F_i) = \mu(F) - \mu(F_i)$. Ekkor $\Phi(F) = (\Phi(F, F_i))_{i \in [p]}$ a részproblémák méretváltozásainak vektora, vagyis az *elágazási vektor*. Ezekre az elágazásokra igaz, hogy a keletkező ágakban összesen nem csökken a levelek száma

$$l(F) \leq \sum_{i=1}^p l(F_i).$$

Ahol $l(F)$ az F -ből kiinduló részfa leveleinek a száma. Később használni fogom az $l(\mu(F))$ jelölést, ami egy $\mu(F)$ méretű probléma leveleinek a számát jelöli. Továbbá legyen $\tau(\Phi(F))$ a

$$\sum_{i=1}^p x^{-\Phi(F)_i} = 1$$

egyenlet egyetlen pozitív gyöke, ezt nevezzük *elágazási faktornak*. Ez a τ függvény alkalmazható tetszőleges elágazási vektorra. Ekkor a T fában lévő összes elágazásra kapott τ értékek közül a legnagyobb:

$$\tau_{\max}(\mu, T) := \max_{F \in T} (\tau(\Phi(F))),$$

teljesül a [14] cikk 8.2-es lemmája alapján a következő felsőbecslés a levelek számára:

$$l(T) \leq \tau_{max}(\mu, T)^n.$$

Összefoglalva tehát egy Φ távolságfüggvény definiálásával a φ elágazásokra, megkapható egy felső korlát a futásidőre. Ami nem más, mint a T fa által adott $\sum_{i=1}^p x^{-\Phi(F)_i} = 1$ egyenletrendszer legnagyobb gyöke, amit jelöljön λ . Szemléletesen, minél nagyobb $\Phi(F, F_i)$, annál jobban csökkenti a φ_i elágazás a probléma komplexitását. A cél tehát egy olyan Φ választása, aminek a lehető legkisebb értéke is nagy. Ezt formalizálva $\Phi(F) = (\Phi(F, F_i))_{i \in [p]}$ vektor dominálja $\Phi'(F)$ elágazási vektort, ha $\Phi(F) \leq \Phi'(F)$, vagyis $\Phi(F)$ komponensenként nem nagyobb, mint $\Phi'(F)$. Ekkor $\Phi(F)$ legalább akkora futásidőt eredményez, mint $\Phi'(F)$. Tehát a futásidő vizsgálásakor elég megfigyelni egy domináló vektorhalmazt. Hasonló okokból, amikor kicserélünk egy elágazási vektort, egy őt domináló vektorra, akkor egy durva felső becslést kapunk a futásidőre. Ezeknek a tulajdonságoknak fontos szerepe lesz a továbbiakban.

Mint fent említettem, általában a Branch & Reduce algoritmusokban a μ mértéknek egyszerűen azt választják, amivel aztán kifejezik a futásidőt. De bármilyen, akár bonyolult, μ' mérték választható, amire teljesül $\mu' \leq f(\mu)$ valamilyen ismert f függvényre. Ezáltal elérhető egy $O^*(\lambda^{\mu'(F)}) = O^*(\lambda^{f(\mu)(F)})$ időkorlát (ahol F a kiindulási probléma), amiben $f(\mu)$ a kívánt formában van. Vagyis μ jó meghatározása rendkívül fontos. A könnyebb megértés érdekében itt van egy példa. Nézzük a minimális domináló csúcshalmaz problémát, ahol a legkisebb k egész számot kell meghatározni, amire létezik k darab csúcs egy gráfban úgy, hogy a maradék csúcsok mindegyikének legyen szomszédja a k kiválasztott csúcs között. Ennek az NP-nehéz problémának egy sztenderd analízisében $G = (V, E)$ esetén $\mu(G) = |V|$. Nyilván a kívánt futásidő alakja $O^*(2^{\alpha|V|}) = O^*(2^{\alpha\mu(G)})$. De adható tetszőleges μ' mérték, amire $\mu'(G) = f(\mu(G))$, hiszen ekkor $O^*(2^{\mu'(G)}) = O^*(2^{f(\mu(G))}) = O^*(2^{\alpha\mu(G)})$.

A λ kiszámítása. Már szó volt a jó algoritmusok és a jó mértékek fontosságáról, azonban ugyancsak fontos egy gyors és optimális, vagy közel optimális módszer a λ kiszámítására, hiszen ez határozza meg az algoritmus futásidejét.

Tegyük fel, hogy adottak a $\Phi(F_1), \Phi(F_2), \dots, \Phi(F_t)$ különböző elágazási vektorok az algoritmus összes elágazási pontjához és a hozzá tartozó μ . A kezdeti probléma mértéke legyen k . Ekkor tetszőleges λ kielégítő megoldás egy felső korlátot ad a futásidőre (bár nem feltétlenül jót). Egy λ kielégítő megoldás, ha a következő

egyenlőtlenségeket teljesíti:

$$1 \geq \sum_{i=1}^{p_j} \lambda^{-\Phi(F_j)}, \quad \forall j = 1, 2, \dots, t. \quad (2.1)$$

Tehát nem kell az egyenlőséget megkövetelni, az enyhített feltételeket teljesítő λ már felső becslést ad. Ez egy nagyon fontos tulajdonság, innentől ezt az egyenlőtlenséget fogom vizsgálni. Rögzített kitevők mellett ez egy kvázi-konvex programozási feladat [6], ezért létezik egy algoritmus, ami ezt kihasználva hasonló problémákat old meg [7]. Azonban a μ mérték, amit a későbbi algoritmusokban súlyozások fognak meghatározni, ugyancsak optimalizálandó bizonyos feltételek mellett. Ezért ilyen oldalról nehéz megközelíteni a problémát, de nem lehetetlen ([7]). Emellett a jó megközelítés mellett - ami a kvázikonvex megoldók miatt kissé időigényes - elképzelhető egy teljes randomizálás. Ezt a módszert fogom bemutatni és elemezni a következő részben.

2.2. Random lokális keresés

Minden NP-nehéz feladatra van egy triviális algoritmus. Ezért egy bizonyos λ és $\mu(F) = n$ választással egy helyes megoldást kapunk (ami kielégíti az összes egyenlőtlenséget). A módszer lényege, hogy alkalmas paraméterekből és λ -ból kiindulva, véletlenszerűen változtatva λ -t és μ -t (vagyis a benne lévő súlyokat) a $[-d, d]$ intervallumból egyenletesen választott értékkel, kapunk egy új λ -át. Ha ez kisebb, akkor megtartjuk, és feljegyezzük a hozzá tartozó paramétereket is. Ezt ismételve, ha sokáig nem érünk el javítást, csökkentjük d értékét. Ezt a lépést addig iterálva, amíg d elég kicsi nem lesz, eljuthatunk egy lokális minimumhoz. Az algoritmus alapján pszeudokódja az 1 algoritmus. Mivel ez egy lokális keresés, ezért előfordulhat, hogy a kapott megoldás egyáltalán nem optimális. A módszer paramétereit állítva megvizsgáltam az egyes esetek hatékonyságát.

Formalizálás. Tegyük fel, hogy a μ mérték m paramétert használ. Azaz tetszőleges F_j állapotra $\mu(F_j) = p_1(F_j) + p_2(F_j) + \dots + p_m(F_j)$. Ebből $\Phi(F_j)$ – vagyis a mértékek különbsége – is hasonlóan fölírható. Legyen adott egy $\mathcal{F}$ feltételrendszer, amiben tetszőleges feltételek lehetnek a p paraméterekre. A feladat tehát a következő. Minimalizáljuk λ -át, és határozzuk meg a p_j , $j = 1, \dots, m$ paramétereket úgy, hogy a paraméterek teljesítsék $\mathcal{F}$ -et és teljesülnek a 2.1 egyenletek. Mivel a mértéknek kisebbnek kell lennie, mint a sztenderd mérték, ezért feltehetjük, hogy a gráfbeli feladatok esetében minden p_j értéke egy csúcsra nézve legfeljebb 1.

2.2.1. Programok

Minden programot pythonban írtam, ami itt megtalálható: [GitHub - notebook](#). Minden itt említett programot a későbbiekben leírt problémákra, és az ott használt algoritmusokkal futtattam. A kapott ábrák is ezen futtatások alapján készültek. A véletlenszerűség miatt, ahelyett, hogy egy programot nagyon sok ideig futtatnék, inkább lefutatom röviden, de sokszor, és nem mindig a kiinduló értékből, hanem az előző futtatást folytatva, az ott kapott értékből. Azaz a befejezett állapotból nagy lépésközzel próbál továbbhaladni a program, ezzel több lehetőséget végigpróbálva.

1. Algorithm Alap algoritmus

```
1: function PERTURB(parameters,  $d$ )
2:   for  $i$  in parameters do
3:      $i = i + \text{random}(-d, d)$ 
4:   end for
5:   return parameters
6: end function
7: function RANDOMSEARCH(parameters,  $d$ ,  $\epsilon$ ,  $\delta$ ,  $\text{maxcnt}$ )
8:   while  $d < \epsilon$  do
9:     newparameters := PERTURB(parameters,  $d$ )
10:    if newparameters teljesíti  $\mathcal{F}$ -et then
11:      parameters = newparameters
12:       $\text{cnt} = 0$ 
13:    else
14:       $\text{cnt} += 1$ 
15:    end if
16:    if  $\text{cnt} > \text{maxcnt}$  then
17:       $d = d \cdot \delta$ 
18:       $\text{cnt} = 0$ 
19:    end if
20:  end while
21:  return parameters
22: end function
```

0. Program. Minden problémánál adott egy triviális megoldás, ami egy triviális exponenciális algoritmusból adódik, amiben minden lehetőséget végigpróbálunk. Az alapötlet, ahogy fent írtam, mindennek az iterációnkénti randomizálása. Ez a módszer azonban egy problémába ütközik. A kiindulási értékek, amiket a triviális megoldásból kapunk, az $\mathcal{F}$ feltételek felső határán vannak, hiszen a standard mértéket használják. Vagyis előfordulhat - ha nem tudunk jelentősen jobb megoldást elérni a triviálisnál -, hogy a program nem tud elindulni, mert az esetek nagy részében van olyan paraméter, ami véletlenül növekedne, főleg a λ , ami az egyenletekben hatványalapul szolgál és a keresett futásidőt adja. Erre lenne egy megoldás, ha $\mathcal{F}$ -et enyhítjük és megengedünk


egynél nagyobb értékeket a paramétereknek (csúcsonként). Mivel azonban általában λ -nak az értéke csak kicsit változik, ez a program a triviálisnál rosszabb megoldást adna. Ahogy a randomizáció során megengedjük, hogy λ túlnőjön a triviális értéken, szinte biztos, hogy ezt meg is teszi, hiszen itt könnyebb találni olyan paramétereket, amik ezzel a λ -val helyes megoldást adnak. Tehát a program érdektelen lépéseket tesz a triviális határon túl, és nem talál jó megoldást (1).

1. Program. Erre megoldás, ha λ -át nem engedjük a triviális határértékén túlra, vagy ami még jobb, csak csökkentést engedünk meg (az 1 kód 3 sorában ha $i == \lambda$, akkor $i = i + \text{random}(-d, 0)$). Ez a program már jelentős javításra képes. Mivel λ csak csökkenhet, ha a λ -t a triviális értékről indítjuk, akkor előfordulhat, hogy nehezen indul el, hiszen a paraméterek még egyáltalán nincsenek beállítva. Ezért jobb nagyobb értékről indítani λ -át kihasználva a randomizáció elágazását. Viszont az enyhített feltételek melletti program itt nem ad jobb eredményt. Ennek az oka az lehet, hogy sokszor a már meglévő eredményből indulunk ki, vagyis ha egyszer elszakad a program a küszöbértékektől, már nem számít, hogy onnan indul.

2. Program. A következő ötlet külön-külön változtatni a paraméterek értékeit. Az első opció minden paramétert a λ nélkül változtatni; ugyanazzal a módszerrel, mint az első programban. Megpróbálni javítani az egyes paramétereket, és csak utána csökkenteni λ -t. Amikor az egyik paraméter elakad, vesszük a következőt. Amikor mindegyik elakad, kisebb lépésközzel újra elindítjuk a folyamatot. Amikor ez a külső lépésköz is elér egy kicsi értéket, megállunk. Ez az ötlet önmagában nem állja meg a helyét. Mivel mindig van összefüggés a paraméterek között, nem tud igazán hatékonyvá válni. Hasonlóan, ha egyszerre kettő paramétert változtat a program, akkor sem ér el jó eredményt. Azonban, főleg sok paraméteres esetben, a hasonló tulajdonságú paramétereket tudja optimalizálni, és ezzel elérni kisebb λ -t. Viszont előfordulhat, hogy az egyik ilyen paramétertömb optimalizálásával a program elér egy olyan lokális minimumot, ahol a többi paramétert már nem lehet változtatni, vagy nem lehet eléggé. Ezért érdemes bevezetni egy szabály enyhítést a sorrendekre vonatkozóan. Vagy ezt is lehet randomizálni. Fontos azonban, hogy a paraméterek kezdőértékei ne a megengedett felső határról induljanak. Ez gond lehet abban az esetben, ha nehéz jó paramétereket találni. Mindegyik esetben az alap kódnak (1) a PERTURB része változik. A 2. sorban ahelyett, hogy minden paraméteren végigmennénk, csak a kívánt specializáció szerint megyünk, és a RANDOMSEARCH függvényben (9. sor) a többféle PERTURB között váltogatunk a megfelelő feltételek szerint.

3. Program. A kész programban ahelyett, hogy korlátoznám a paraméterek változását, módosítom az intervallumot, amiből egyenletesen választottam a paraméterek megváltozásának értékét két iteráció között. Vagyis nem $(-d, d)$ közül sorsolok érté-


ket, hanem (d_1, d_2) közül. Ezeket az értékeket d -ből és kezdetben 0 várható értékű és d szórású normális eloszlásból számolom ki. Majd menet közben változtatom a várható értéket aszerint, hogy milyen irányba léptünk az előző iterációkban az egyes paraméterekkel. Ez a program bizonyult a legpontosabbnak, igaz hasonló eredményeket ért el, mint az 1. program. Ezen kívül az itt leírt konkrét program előtt futtattam egy hiperparaméter-optimalizálást, amivel beállítottam λ kezdőértékét és az összes többi változót: $d, eps, delta, maxcnt$. Ehhez pszeudokód a 2. Algoritmus. Már ez az előzetes futtatás is kiad egy megoldást (2.3 ábra), ami az általam kipróbált néhány problémára pár másodperc alatt megközelítette, vagy elérte a cikkekben nagyjából tízezreléig megadott értékeket, amik a [7] algoritmust használták, ami az iterációnkénti kvázikonvex program megoldás miatt lassabb. A 2.2 és 2.3 ábrákon összehasonlítottam a leírt programokat. Látható, hogy a 0 kivételével mindegyik közel jó eredményt ad. Ezek közül kettőt még egy másik problémára is összehasonlítottam, itt már hosszabb futtatásokkal (ld.: 2.4 és 2.5).




2.2. ábra. A programok eredménye a 3.3 feladatra iterációban skálázott x tengellyel ábrázolva.

2. Algorithm Kész algoritmus


```
1: function PERTURB(parameters,  $d$ , balance)
2:    $\lambda = \lambda + \text{random}(\text{parameters})$ 
3:   for  $i$  in parameters  $\setminus \{\lambda\}$  do
4:      $\text{dif}[i] := \text{random}(-d + \text{rnorm}(\text{balance}[i], d), d + \text{rnorm}(\text{balance}[i], d))$ 
5:      $i = i + \text{dif}$ 
6:   end for
7:   return parameters, dif
8: end function
9: function RANDOMSEARCH(parameters, balance, hyperpars)
10:  while  $d < \text{eps}$  do
11:    newparameters := PERTURB(parameters,  $d$ , balance)[0]
12:    if newparameters teljesíti  $\mathcal{F}$ -et then
13:      parameters = newparameters
14:       $\text{cnt} = 0$ 
15:      balance += PERTURB(parameters,  $d$ , balance)[1]
16:    else
17:       $\text{cnt} += 1$ 
18:    end if
19:    if  $\text{cnt} > \text{maxcnt}$  then
20:       $d = d \cdot \text{delta}$ 
21:       $\text{cnt} = 0$ 
22:    end if
23:  end while
24:  return parameters
25: end function
26: function PRETUNE(hyperpars, parameters, balance)
27:  for combination in product(hyperpars) do
28:    newhyper = RANDOMSEARCH(parameters, balance, combination)
29:    if  $\lambda$  in newhyper  $\leq \lambda$  in hyperpars then
30:      hyperpars := newhyper
31:    end if
32:  end for
33:  return hyperpars
34: end function
```



2.3. ábra. A programok eredménye a 3.3 feladatra az optimális paraméterekkel, iterációban skálázott x tengellyel ábrázolva.



2.4. ábra. Teljes futtatások. Az első program fél percig, a harmadik egy percig futott ugyanannyi ismétléssel a 4.1 problémára. A harmadik program egy kicsit jobb eredményt ért el.



2.5. ábra. Az előző futtatás $\lambda = 1.5$ értékről indítva. Itt a 3. program volt gyorsabb.

3. Directed Multiway Cut

3.1. Problémakör

A vágások a gráfelméletben széles körben elterjedtek az alkalmazhatóságuknak köszönhetően. A gráf két pontja közötti minimális vágás megtalálására Ford és Fulkerson adott polinomiális idejű algoritmust. Ez a sokat használt max-flow min-cut - maximális folyam minimális vágás - algoritmus adott okot az általánosításra. A probléma szépségének ellenére a teljesen általános esetet nézve, az évek során kialakult többféle megközelítés mindegyikéről belátták, hogy NP-nehéz. Sőt, némelyikhez még közelítő algoritmust is nehéz adni. A feladat komplexitásából kifolyólag, mivel gyors algoritmusra nincs remény, a cél az exponenciális futásidő leredukálása, és mint látni fogjuk, ehhez a Measure & Conquer kapóra jön.

Ilyen általánosítás a minimális Multicut probléma, ahol adott l darab tetszőleges számú pontpár $\{s_i, t_i\}$ egy irányítatlan gráfban $G(V, E)$ és egy nemnegatív élsúlyozás. A feladat meghatározni egy minimális élhalmazt, amit elvéve a gráfból, a megmaradó gráfban nem marad út s_i és t_i között $i = 1, \dots, l$ -re. Ehhez hasonló a k -Multicut, ahol elegendő (rögzített k -ra) egy olyan minimális súlyú vágást találni, ami legalább k pontpárt választ szét az összes l -ből. A Multicut egyik fontos speciális esetében egy ponthalmaz adott, és olyan vágást keresünk, ami ezek közül bármely két pontot elválasztja. Leggyakrabban ezt a problémát hívják Multiway Cut-nak, azonban ebben a dolgozatban ennek egy másik változatára fogok hivatkozni ezen a néven. Ugyanis nézhetjük azt a problémát is, amikor élek helyett csúcsokat keresünk, és azok eltávolításával akarjuk elválasztani a kijelölt csúcsokat - terminálokat. Mindkét esetben $k \geq 3$ terminálra a feladat NP-nehéz. Érdekes megjegyezni, hogy a csúcsok törlésénél a terminálok nem lehetnek szomszédosak, hiszen ekkor a feladat nem megoldható. Fontos megjegyezni, hogy ebben a feladatban nem engedjük meg a terminálok törlését. Természetesen az itt említett feladatoknak nézhetjük az irányított változatát. Ez azonban még nagyobb kihívást jelent; a Directed Multiway Cut már $k \geq 2$ terminálra NP-nehéz.

Ebben a fejezetben a *Directed Multiway Cut* problémáról lesz szó, ami tehát a következő. Adott egy $G = (V, E)$ irányított gráf és egy $T \subseteq V$ terminálhalmaz. A cél egy minimális $S \subseteq V \setminus T$ halmaz megtalálása, amit ha kitörölünk a gráfból, a megmaradó gráfban nem lesz olyan irányított út, ami egy terminálból egy másik terminálba megy. Erre a problémára sokáig nem volt a triviálisnál jobb algoritmus, de 2024-ben Mingyu Xiao adott egy algoritmust, ami $O(1.9967^{|V|})$ idő alatt megoldást ad. A következőkben ezt az algoritmust vizsgálva, mutatok egy javítást, amivel kicsivel jobb futásidő elérhető. A jobb futásidőt új súlyok bevezetésével érem el. Ez persze felveti azt a kérdést, hogy ilyen vagy ehhez hasonló adatcsökkentési szabályokkal, mint a *Measure and Conquer*, meddig csökkenthető egy pontos, NP-nehéz feladatot megoldó algoritmus futásideje, illetve milyen már kitalált algoritmusok adhatnak jobb futásidőt.

Directed Multiway Cut

Input: $G = (V, E)$ irányított gráf, valamint egy $T = \{t_1, t_2, \dots, t_l\}$ terminálhalmaz, ahol $T \subseteq V$, és egy egész szám k .

Output: Létezik-e olyan $S \subseteq V \setminus T$ csúcsokból álló halmaz, hogy $|S| \leq k$ és az így kapott $G - S$ gráfban nincs út bármely két terminál között T -ben?

Jelölések

A feladatból kifolyólag $G(V, E)$ jelöljön irányított gráfot. Minden él E -ben egy V elemeiből álló rendezett pár. Legyen a csúcsok száma $|V| = n$. Egy $v \in V$ csúcs esetén a kiszomszédokat jelölje $N^+(v) := \{u \in V : vu \in E\}$ és a beszomszédokat ennek megfelelően $N^-(v)$. Egy $V' \subset V$ csúcs-halmaz esetén a jelölés legyen $N^+(V') = \bigcup_{v \in V'} N^+(v) \setminus V'$ és $N^-(V') = \bigcup_{v \in V'} N^-(v) \setminus V'$. Legyen továbbá $U \subset V$ esetén $N_U^\pm(V') = N^\pm(V') \cap U$.

3.2. Mingyu Xiao Algoritmus

Először felszínesen leírom a [17]-ben használt algoritmust.

Keretrendszer. Az algoritmus során végig fenntartunk egy A részhalmazát a csúcsoknak, amire a következő alaptulajdonságok érvényesülnek:

- A -ban pontosan egy terminál van, jelölje ezt t ;

- t -ből minden másik csúcs elérhető A -ban;
- az A -ban lévő csúcsok nem lehetnek benne az S megoldáshalmazban.

Az A halmaz meghatároz két másik halmazt a következő módon: $B = N^+(A)$ a kiszomszédok halmaza és $R = G \setminus (A \cup B)$ a megmaradó csúcsok halmaza. Az algoritmus a legtöbb lépésben vagy kitöröl egy csúcsot a gráfból, betéve azt a megoldáshalmazba, vagy "megbélyegzi", mint nem megoldás. Az algoritmus lényege, hogy ily módon a csúcsokat R -ből B -be vigye, majd B -ből A -ba, és miután $N_R^+(B) = \emptyset$, vagy kitörli $A \cup B$ -t a gráfból, ha $N^-(A \cup B) = \emptyset$, vagy megfordítja a gráf éleit, ha $N^-(A \cup B) \neq \emptyset$. Ez a standard súlyozással nem lenne jobb a triviális $O(2^n)$ futásidőnél. Ezért a Measure & Conquer módszerrel a csúcsokhoz a tulajdonságaiktól függően, különböző súlyokat rendelünk. Ezeket, az egyszerűség kedvéért fekete, fehér, kék és piros színekkel fogjuk jelölni. Illetve a színeken felül az algoritmus bizonyos lépésekben megjelöl csúcsokat, ezzel ugyancsak módosítva azok súlyát. Így a csúcsok a következő értékekkel a 3.6 táblázat alapján kapnak súlyokat: $\alpha = 0.958234$, $\beta = 0.943555$, $\gamma = 0.901789$. Nagyon fontos a színek jelentése. Feketére azokat a csúcsokat színezzük, amiket kizártunk a megoldáshalmazból; az A -ban és a T -ben lévő csúcsok mind feketék; a B -ben lévő csúcsok lehetnek kék és piros színűek aszerint, hogy van általánosított kiszomszédjuk, vagy nincs.

Jelölje w a gráfban lévő összes csúcs súlyának összegét, $w \leq n$. Továbbá jelölje $l(w)$ egy w súlyú gráf által a keletkező leg több levél számát. Minden egyes elágazási művelethez egy rekurzív összefüggést fogunk felépíteni ezekkel az értékekkel, amikből aztán kiszámolható az alágazási faktor. Ha az algoritmusban előforduló összes elágazási faktor közül a legnagyobb λ , akkor a keresési fa mérete legfeljebb $O(\lambda^w)$.

	feketé	piros	kék	fehér
jelölt	0	γ	γ	β
jelöletlen	0	β	α	1

3.6. ábra. Az eredeti algoritmus színeihez tartozó értékek.

Általánosított kiszomszéd. Egy u csúcs általánosított kiszomszédja v -nek, ha létezik egy $u \rightarrow v$ út, amiben u -n és v -n kívül minden csúcs fekete. A v általánosított kiszomszédainak jele $GN^+(v)$. Ha egy V halmazra használjuk, akkor ismét $GN^+(V) = \bigcup_{v \in V} GN^+(v)$ értjük. Illetve gyakran fog előjönni ugyanennek egy halmazra való megszorítása $GN_R^+(v) = R \cap GN^+(v)$.

Lépések. Mikor egy csúcsot kizárunk a megoldáshalmazból, automatikusan feketére színezzük. Az algoritmus minden művelete után, ha az ellenkezőjét nem állítjuk, $A \cup B$ -re alkalmazzuk a *Színezési Szabályt*: Minden A -ba kerülő csúcsot feketére színezzük; pirosra színezzük egy $v \in B$ csúcsot, ha $GN_R^+(v) = \emptyset$ és kékre, ha $GN_R^+(v) \neq \emptyset$. Mielőtt végrehajtanánk bármelyik fő lépést, a következő csökkentési szabályokat alkalmazzuk.

- Ha A üres, vegyünk be egy tetszőleges $t \in T$ terminált A -ba.
- Ha van egy fekete csúcs B -ben, azt azonnal áttesszük A -ba.
- Ha egy csúcsból nem érhető el egyik terminál sem, vagy egy csúcs nem érhető el egyik terminálból sem, akkor töröljük a gráfból.
- Ha $N^+(A \cup B) = N^-(A \cup B) = \emptyset$, akkor töröljük $A \cup B$ -t a gráfból.

Kilenc lépése van az algoritmusnak. Először A csak egy terminálpontot tartalmaz, $B = N^+(t)$ és $R = V \setminus (A \cup B)$. Az algoritmus addig hajtja végre a lépéseket, amíg $k < 0$ vagy az üres gráfhoz jutunk. Ha nincs megjelölt csúcs $B \cup R$ -ben, akkor végrehajtjuk az 1-4. lépéseket. Ellenkező esetben az 5-9. lépéseket. Most bevezetem a lépéseket, és odaírom az eredeti súlyozással kapott elágazási faktorokat az összehasonlíthatóság kedvéért.

1. Lépés. *Ha van egy $v \in B$, csúcs, amire $|GN_R^+(v)| \geq 3$, akkor elágazunk kétfelé: vagy kitöröljük v -t a gráfból, és k -t csökkentjük 1-el, vagy feketére színezzük v -t.*

Az elágazás értéke nem nagyobb, mint 1.9736.

2. Lépés. *Ha van egy $v \in B$, csúcs, amire $|GN_R^+(v)| = 1$, akkor feltesszük, hogy $GN_R^+(v) = \{u\}$ és elágazunk kétfelé: vagy kitöröljük u -t a gráfból és k -t csökkentjük 1-el, vagy feketére színezzük u -t.*

Az elágazás értéke nem nagyobb, mint 1.9900.

3. Lépés. *Ha van egy $v \in B$, csúcs, amire $|GN_R^+(v)| = 2$, akkor feltesszük, hogy $GN_R^+(v) = \{u_1, u_2\}$ és elágazunk háromfelé: vagy feketére színezzük u_1 -et, vagy kitöröljük u_1 -et a gráfból, feketére színezzük u_2 -t és csökkentjük k -t 1-el, vagy kitöröljük u_1 -et és u_2 -t is, és csökkentjük k értékét kettővel.*

Az elágazás értéke nem nagyobb, mint 1.9967.

4. Lépés. Ha $GN_R^+(B) = \emptyset$ és $N^-(A \cup B) \neq \emptyset$, akkor B összes csúcsát fehérre színezzük, megjelöljük, megfordítjuk a gráf összes élet és frissítjük B -t, úgy, hogy $B = N^+(A)$ legyen az új gráfban.

5. Lépés. Ha van egy megjelölt csúcs $v \in B$, amire $|GN_R^+(v)| \leq 1$ teljesül, akkor v -t tegyük át A -ba.

6. Lépés. Ha van egy megjelölt $v \in B$ csúcs, amire $|GN_R^+(v)| = 2$, akkor tegyük fel, hogy $GN_R^+(v) = \{u_1, u_2\}$ és elágazunk kétfelé: vagy átesszük v -t A -ba, vagy kitöröljük v -t, csökkentjük eggyel k -t és u_1 -et, u_2 -t feketére színezzük.

Ennek az elágazási értéke nem nagyobb, mint 1.5166.

7. Lépés. Ha van egy megjelölt $v \in B$ csúcs, amire $|GN_R^+(v)| = 3$, akkor tegyük fel, hogy $GN_R^+(v) = \{u_1, u_2, u_3\}$ és elágazunk három alrészre: vagy átesszük v -t A -ba, vagy kitöröljük v -t, csökkentjük eggyel k -t és u_1 -et feketére színezzük, vagy kitöröljük v -t és u_1 -et a gráfból, csökkentjük k -t kettővel és u_2 -t, u_3 -at feketére színezzük.

Ennek az elágazási értéke nem nagyobb, mint 1.8453.

8. Lépés. Ha van egy megjelölt $v \in B$ csúcs, amire $|GN_R^+(v)| = 4$, akkor tegyük fel, hogy $GN_R^+(v) = \{u_1, u_2, u_3, u_4\}$ és elágazunk négy alrészre: vagy átesszük v -t A -ba, vagy kitöröljük v -t, csökkentjük eggyel k -t és u_1 -et feketére színezzük, vagy kitöröljük v -t és u_1 -et a gráfból, csökkentjük k -t kettővel és u_2 -t feketére színezzük, vagy kitöröljük v -t, u_1 -et és u_2 -t a gráfból, csökkentjük k -t hárommal és feketére színezzük u_3 -at és u_4 -et.

Ennek az elágazási értéke nem nagyobb, mint 1.9967.

9. Lépés. Ha van egy megjelölt $v \in B$ csúcs, amire $|GN_R^+(v)| \geq 5$, akkor elágazunk kétfelé: vagy kitöröljük v -t és csökkentjük eggyel k -t, vagy átesszük v -t A -ba.

Ennek az elágazási értéke nem nagyobb, mint 1.9967.

Ezeknek a lépéseknek a bizonyítását nem írom le, mert bizonyításuk nem fontos a javításom szempontjából. Elég annyit megfigyelni, hogy ha van megjelölt csúcs $B \cup R$ -ben, akkor mind az 5-9. lépés ezek számát csökkenti. Vagyis miután elfogynak a jelölt csúcsok $B \cup R$ -ben visszatér az algoritmus az 1-4. lépésekhez. Tehát a két része az algoritmusnak "különálló", és külön-külön javítható. Az is megfigyelhető, hogy a lassú lépések a 3., 8., 9. Ezeket figyelembe véve, és azt, hogy az 1., 2., 3. lépések egymást kizáró esetekben alkalmazandók, megpróbálhatjuk gyorsítani a 3. lépést úgy, hogy amikor végrehajtjuk, kicsit nagyobb csökkentünk w -n, viszont

amikor az 1. és 2. lépéseket hajtjuk végre, ellensúlyozzuk ezeket a csökkentéseket egy kis extra munkával (azaz kisebbre véve w csökkenését). Ez az ötlet hasonló az amortizált analízis ötletéhez, ahol - bár legrosszabb esetben lassú az algoritmusunk - beláthatjuk, hogy az algoritmus nagy részében könnyű lépéseket teszünk, és ezek a könnyű lépések ellensúlyozzák a nehezet.

3.3. Javított algoritmus

Ahogy már említettem, az algoritmus első felében a harmadik lépésnek volt a legnagyobb az elágazási faktora, ezért ezen szeretnék csökkenteni. Ehhez három részre bontom ezt a lépést és bevezetek két új változót $\nu = 0.016377, \mu = 0.004020$, a többi érték pedig $\alpha = 0.958218, \beta = 0.944115, \gamma = 0.902332$ kicsit változik. Illetve az átláthatóság kedvéért bevezetek egy új $C \subset R$ halmazt úgy, hogy $C = GN_R^+(B)$. Ekkor definiálható az $R' = V \setminus (A \cup B \cup C)$ megmaradó csúcsok halmaza. Továbbá felteszem, hogy a **3.1.**, **3.2.**, **3.3.** lépések végrehajtása előtt minden $v \in B$ csúcsra, amire $|GN_R^+(v)| = \{u_1, u_2\}$, teljesül, hogy v súlya α , u_1 és u_2 súlya pedig 1, ahogy azt az eredeti algoritmusban elvártuk. Ezt később belátom, hogy továbbra is igaz marad. A harmadik lépését az algoritmusnak tehát lecserélem a következő három lépésre.

10. Tétel. *Az Irányított Multiway Cut probléma megoldható $O(1.9959^n)$ időben.*

3.1. Lépés. *Ha van egy $v \in B$ csúcs, amire $|GN_R^+(v)| = 2$ teljesül, ahol tegyük fel, hogy $GN_R^+(v) = \{u_1, u_2\}$, és $|GN_{R'}^+(u_1)| = 0$, akkor három alrészre osztjuk a feladatot: u_1 -et feketére színezzük, és u_2 súlyát csökkentjük μ -vel; u_1 -et kitöröljük a gráfból, és u_2 -t feketére színezzük; u_1 -et és u_2 -t is kitöröljük a gráfból.*

Bizonyítás. Ennek a lépésnek a helyessége következik abból, hogy az eredeti algoritmus lépése helyes volt, és ez a lépés szűkített feltételek mellett, de ugyanazokra az elágazásokra bomlik. A súlyokat tekintve csak az első ágban van változás az eredeti lépéshez képest, ahol a feketére színezés mellett egy újabb μ -vel csökken az összsúly. Így a következő relációt írhatjuk fel:

$$l(w) \leq l(w - (1 + \mu)) + l(w - 2) + l(w - (2 + \alpha - \beta)),$$

így az elágazás faktora nem nagyobb, mint 1.9950. •

3.2. Lépés. *Ha van egy $v \in B$ csúcs, amire $|GN_R^+(v)| = 2$ teljesül, ahol tegyük fel, hogy $GN_R^+(v) = \{u_1, u_2\}$, $|GN_{R'}^+(u_1)| = 1$ és $GN_{R'}^+(u_2) = \{z\}$, akkor három alrészre*

osztjuk a feladatot: u_1 -et feketére színezzük; u_1 -et kitöröljük a gráfból, és u_2 -t feketére színezzük, és z értéket csökkentjük μ -vel; u_1 -et és u_2 -t is kitöröljük a gráfból.

Bizonyítás. Ennek a helyességét ugyanúgy bizonyíthatjuk, mint az előzőt. A súlyokat tekintve most a második ágban lesz nagyobb a csökkenés az eredetihez képest. Mégpedig a fekete színezés és törlés 2-je helyett $2 + \mu$ -vel fog csökkenni az összsúly, hiszen z egy fehér csúcs volt. Tehát a következő egyenlőtlenséget kapjuk:

$$l(w) \leq l(w - 1) + l(w - (2 + \mu)) + l(w - (2 + \alpha - \beta)),$$

amiből az elágazási faktor nem nagyobb, mint 1.9959. •

3.3. Lépés. Ha van egy $v \in B$ csúcs, amire $|GN_R^+(v)| = 2$ teljesül, ahol tegyük fel, hogy $GN_R^+(v) = \{u_1, u_2\}$, $|GN_{R'}^+(u_1)| \geq 2$, akkor három alrészre osztjuk a feladatot: u_1 -et feketére színezzük, és v súlyát csökkentjük ν -vel; u_1 -et kitöröljük a gráfból, és u_2 -t feketére színezzük; u_1 -et és u_2 -t is kitöröljük a gráfból.

Bizonyítás. Ez a lépés is helyes a fentiek miatt. A súlyokat tekintve az első ág változik az eredetihez képest. Ebben az ágban a csökkenés ν -vel nő, hiszen az eddig kék v csúcsot még csökkentjük ν -vel és $\nu < \alpha$ miatt v súlya pozitív marad. Az egyenlőtlenség

$$l(w) \leq l(w - (1 + \nu)) + l(w - 2) + l(w - (2 + \alpha - \beta))$$


lesz, így az elágazási faktor nem több, mint 1.9894. •

Látható, hogy ez a három lépés helyettesíti az eredeti algoritmus 3. lépését, hiszen a v csúcs szomszédaira, ha $GN_R^+(v) = \{u_1, u_2\}$, akkor vagy $|GN_{R'}^+(u_1)| = 1$ és $|GN_{R'}^+(u_2)| = 1$ teljesül, vagy $|GN_{R'}^+(u_1)| \neq 1$, mivel u_1 és u_2 között nem teszünk különbséget, így $|GN_{R'}^+(u_1)| = 0$ vagy $|GN_{R'}^+(u_1)| \geq 2$.

Viszont ahhoz, hogy ez a módszer tényleg javítsa a futásidőt, feltettem a következő lemmát.

11. Lemma. 3.1, 3.2, 3.3 lépések végrehajtása előtt a $v \in B$ kiválasztott csúcsra, amire $|GN_R^+(v)| = \{u_1, u_2\}$, teljesül, hogy v súlya α ; u_1 és u_2 súlyai pedig 1.

Bizonyítás. Ennek a belátásához felhasználok azt, hogy az 1, 2, 3.1, 3.2 és 3.3 lépések tetszőleges sorrendben végezhetőek, szabadon választott csúcsokon. Ennek az oka, hogy mielőtt átvált az algoritmus az 5-9. lépésekre - mivel minden lépés legalább egy csúcsot eliminál - a B halmaz elemei mind pirosak lesznek a lépések



3.7. ábra. A gráf ábrázolása a színezett csúcsokkal. Ha ezen az ábrán a v csúcsra lép az algoritmus, akkor a 3.2. lépést hajtja végre.

sorrendjétől függetlenül. Nincs kitüntetett szerepe egyik lépésnek sem. Vagyis feltehetjük, hogy a 3.1 és a 3.2 lépések után az algoritmus mindig a 2 lépést, a 3.3 lépés után mindig az 1 lépést hajtja végre. Ez láthatóan mindig lehetséges, hiszen pont így változnak v kiszomszédai. Továbbá azt is feltehetjük, hogy az 1 és 2 lépéseket éppen a megváltozott súlyú csúcsokra alkalmazzuk. Ezzel elérve, hogy a μ -vel, vagy ν -vel történő változtatások azonnal eltűnjenek a gráfból. Részletesebben, tegyük fel, hogy az algoritmus során valamikor v -re végrehajtjuk valamelyik 3. lépést. Ekkor $|GN_R^+(v)| = 2$, és vagy a 3.1. és 3.2. lépések során egy szomszédja marad, aminek az értéke 1 helyett $1 - \mu$ lesz, vagy a 3.3. lépés miatt v értéke α helyett $\alpha - \nu$ lesz, és legalább 3 szomszédja lesz. Az első eset után a 2. lépéssel v szomszédját vagy feketére színezzük, vagy töröljük a gráfból, de mindkét esetben 0 értéke lesz a csúcsnak. A második esetben az 1. lépéssel most magát v -t nullázzuk, hiszen vagy feketére színezzük, vagy töröljük. Azaz tényleg feltehetjük, hogy mielőtt az algoritmus valamelyik 3. lépést tenné, nem talál μ -vel, vagy ν -vel csökkentett csúcsot. •

Ezzel a trükkkel tehát elértük, mivel $\mu, \nu > 0$, hogy a $|GN_R^+(v)| = 2$ esetet gyorsabban oldja meg az algoritmus. Ugyanakkor az 1 és 2 lépések a leírtak alapján a következőképpen romlanak:

1. Lépés. *Az elágazás mint fent (1)*

Bizonyítás. Mikor v -t töröljük, vagy feketére színezzük, annak az értéke legalább $\alpha - \nu$ az eredeti α helyett, vagyis a következőképpen módosul a súlyokra felírható változás:

$$l(w) \leq l(w - (\alpha - \nu)) + l(w - (3 - \nu - 2\alpha)),$$

aminek az értéke 1.9957

•

2. Lépés. Az elágazás, mint fent (2)

Bizonyítás. Mikor u_1 -et töröljük, vagy színezzük feketére, annak az értéke legrosszabb esetben $1 - \mu$ az eredeti 1 helyett, vagyis a következőképpen módosul a súlyokra felírható összefüggés:

$$l(w) \leq l(w - (1 - \mu)) + l(w - (1 - \mu + \alpha - \beta)),$$

aminek az értéke 1.9959

•

Tehát beláttuk, hogy a megadott paraméterekkel az algoritmus első fele gyorsítható, és itt érdemes megemlíteni, hogy az eredeti cikkben megadott értékekkel az algoritmus 8 és 9 lépésének is az elágazási faktora a felső határon volt, viszont az új értékek ezen is javítottak, igaz, ugyancsak a felső határon vannak a faktorok (ld: 3.9 ábra).

	fekete	piros	kék	fehér
jelölt	0	γ	γ	β
jelöletlen	0	β	α	1

$\xi = \mu, \nu$ módosítás	fekete	piros	kék	fehér
jelölt	0	$\gamma - \xi$	$\gamma - \xi$	$\beta - \xi$
jelöletlen	0	$\beta - \xi$	$\alpha - \xi$	$1 - \xi$

3.8. ábra. A javított algoritmus csúcsainak értékei.

6. Lépés elágazási faktora: 1.5162
7. Lépés elágazási faktora: 1.8447
8. Lépés elágazási faktora: 1.9959
9. Lépés elágazási faktora: 1.9959

3.9. ábra. A nem változtatott lépések elágazási faktorai.

4. Alkalmazás

A Measure and Conquer fontos része az algoritmusban szereplő elágazási vektorokból kiszámolni az elágazási faktorokat, hiszen ezek adják a futásidőt. Vagyis fontos a λ meghatározásának a módja is. A 2.2 fejezetben adott módszert ezért megnéztem egy másik feladatra is, méghozzá pont a [8]-ben szereplő MSC algoritmusra. Ezzel az algoritmussal a probléma $O^*(2^{0,610n}) = O^*(1.5263^n)$ időben megoldható polinomiális térben.

4.1. Minimális domináló halmaz

Ez egy sokak által vizsgált , és széles körben használt probléma, amire [8] óta születtek közelítő és gyakorlati megoldások is. Újabb pontos algoritmus, hasonlóan a Measure and Conquer módszer használatával, csak rá 2 évre [16]-ben Bodlaendernek sikerült, aki egy $O(1.4969^n)$ idejű megoldást adott.

Az MDS probléma a következő. Adott egy $G(V, E)$ gráf. Az $U \subset V$ egy domináló halmaz, ha minden $v \in V$ csúcs vagy elem U -nak, vagy szomszédos egy U -beli csúccsal. A feladat megtalálni egy minimális U domináló részhalmazt. Ehhez a problémához hasonló az MSC, azaz minimális halmazfedés probléma. Itt adott egy U univerzum és egy $\mathcal{S}$ halmaz U részhalmazaiival. $\mathcal{C} \subset \mathcal{S}$ egy halmazfedés, ha $\bigcup_{S \in \mathcal{C}} S = U$, ahol feltehető, hogy $\bigcup_{S \in \mathcal{S}} S = U$. A feladat egy tartalmazásra minimális $\mathcal{C}$ halmazfedést megtalálni. Az MDS könnyen redukálható egy MSC-re. Vegyünk a gráfnak megfelelő $|V| = n$ elemű univerzumot, ahol az elemek a csúcsokat reprezentálják és minden csúcshoz azt a részhalmazt, ami önmagából és a szomszédaiból áll. Ennek a megoldására adott [8] egy algoritmust, aminek az elágazási vektorai a következők:

$$l(w) \leq l(w - \Delta w_{OUT}(t)) + l(w - \Delta w_{IN}(t)) \quad (4.2)$$

ahol t egy éppen vizsgált $S \in \mathcal{S}$ halmaz lehetséges felépítései a következőképpen;

r_i jelölje S -ben az i gyakoriságú elemek számát, vagyis azoknak az elemeknek a számát, amik i elemében megtalálhatóak $\mathcal{S}$ -nek, és $r_{\geq i}$ a legalább i gyakoriságú elemek összegét. Ekkor $t = (|S|, r_2, \dots, r_6, r_{\geq 7})$, mert a cikkben belátták, hogy elegendő vizsgálni $3 \leq |S| \leq 7$ eseteket, és azon felül nem fontos megkülönböztetni minden esetet, mert ezek dominálják a többit. Definiáljuk 4.2 hiányzó értékeit:

$$\begin{aligned} -\Delta w_{OUT}(t) &= \alpha_{|S|} + \sum_{i=2}^6 r_i \Delta \beta_i + \Delta w'_{|S|, r_2}, \\ -\Delta w_{IN}(t) &= \alpha_{|S|} + \sum_{i=2}^6 r_i \beta_i + r_{\geq 7} + \Delta \alpha_{|S|} \left(\sum_{i=2}^6 (i-1) r_i + 6 \cdot r_{\geq 7} \right). \end{aligned}$$

Az $\alpha_2, \alpha_3, \alpha_4, \alpha_5, \beta_2, \beta_3, \beta_4, \beta_5$ értékeket szeretnénk meghatározni. $\alpha_1 = \beta_1 = 0, \alpha_6 = \alpha_7 = \beta_6 = \beta_7 = 1$ (és minden további 1) rögzítjük. Ezeket a súlyokat

$$\mu(\mathcal{S}) = \sum_{i \geq 1} \alpha_i n_i + \sum_{j \geq 1} \beta_j m_j$$

használjuk, ahol n_i az i elemszámú $S \in \mathcal{S}$ halmazok száma, m_j pedig a j gyakoriságú $u \in U$ elemek száma. Itt látható, hogy $0 \leq \alpha_i \leq 1, 0 \leq \beta_j \leq 1$ esetén, minden i, j -re, a μ mérték kisebb az eredeti MDS feladat csúcsszámának kétszeresénél, hiszen $|U| = |\mathcal{S}| = n$. Vagyis ezzel a mértékkel kapott MSC futásidő négyzete egy jó MDS futásidő. Meghatározva a maradék értékeket $\Delta \beta_i = \beta_i - \beta_{i-1}$ és

$$\Delta w'_{|S|, r_2} = \begin{cases} 0 & \text{ha } r_2 = 0; \\ \beta_2 + \alpha_2 & \text{ha } r_2 = 1; \\ \beta_2 + \alpha_3 & \text{ha } r_2 = 2; \\ \beta_2 + \alpha_2 + \alpha_3 & \text{ha } r_2 = 3, |S| = 3; \\ \beta_2 + \alpha_4 & \text{ha } r_2 \geq 3, |S| \geq 4; \end{cases}$$

ahol feltettük, hogy $\alpha_i \leq \alpha_{i+1}, \beta_i \leq \beta_{i+1}$ és $\Delta \alpha_i \geq \Delta \alpha_{i+1}$ minden $i \geq 2$ esetben megkapjuk az optimalizálandó feladatot.

Mindezeket a feltételeket figyelembe véve lefuttattam a 3 programot, és hosszas futtatás után sikerült szinte ugyanazt a cikkben kapott $\lambda \leq 1.2352\dots$ értéket megkapni: $\lambda \leq 1.235208\dots < 2^{0.305}$ a 4.10 táblázatban szereplő súlyokkal.

i	α_i	β_i
2	0.378537	0.398000
3	0.757048	0.765424
4	0.910186	0.926858
5	0.976292	0.984472

4.10. ábra. Az α_i és β_i súlyok értékei $i = 2, \dots, 5$ esetén 3 futtatása alapján.

5. Összefoglalás

Az egyre gyorsabb számítógépeknek köszönhetően - azon túl, hogy egyszerű algoritmusokkal képes jó eredményeket elérni - a Measure & Conquer egy rendkívül jó adatcsökkentési módszer, mert megfelelő számolási módszerekkel gyorsan talál új eredményt. Igaz, meg kell említeni, hogy ezek a javítások is végesek. Hosszas futtatással a 3.2 feladatra a 3. programmal csak minimális javítást sikerült elérnem a [17] eredményéhez képest; a $\alpha = 0.958234, \beta = 0.943555, \gamma = 0.901789$ értékekkel $\lambda = 1.996632$ jó megoldás, viszont a $\alpha = 0.958232, \beta = 0.943557, \gamma = 0.901787$ értékekkel a $\lambda = 1.996631$ is jó megoldás. Ezen túl, az elért új eredmény (10) bizonyítja, hogy bonyolultságát tekintve egyszerű módosításokkal is el lehet érni új eredményeket a módszernek köszönhetően.

Irodalomjegyzék

- [1] Adi Avidor and Michael Langberg. The multi-multiway cut problem. *Theoretical Computer Science*, 377(1):35–42, 2007.
- [2] Amotz Bar-Noy, Toni Böhnlein, David Peleg, Yingli Ran, and Dror Rawitz. Sparse graphic degree sequences have planar realizations. In *Proceedings of the MFCS 2024*. Schloss Dagstuhl – Leibniz-Zentrum für Informatik, 2024.
- [3] Kristóf Bérczi, Tamás Király, and Daniel P Szabo. Multiway cuts with a choice of representatives. *arXiv preprint arXiv:2407.03877*, 2024.
- [4] E. Dahlhaus, D. S. Johnson, C. H. Papadimitriou, P. D. Seymour, and M. Yannakakis. The complexity of multiway cuts (extended abstract). In *Proceedings of the Twenty-Fourth Annual ACM Symposium on Theory of Computing*, STOC '92, page 241–251, New York, NY, USA, 1992. Association for Computing Machinery.
- [5] Martin Davis and Hilary Putnam. A computing procedure for quantification theory. *J. ACM*, 7(3):201–215, July 1960.
- [6] David Eppstein. Quasiconvex programming, 2004.
- [7] David Eppstein. Quasiconvex analysis of multivariate recurrence equations for backtracking algorithms. *ACM Trans. Algorithms*, 2(4):492–509, October 2006.
- [8] Fedor V. Fomin, Fabrizio Grandoni, and Dieter Kratsch. A measure & conquer approach for the analysis of exact algorithms. *J. ACM*, 56(5), August 2009.
- [9] Serge Gaspers and Mathieu Liedloff. A branch-and-reduce algorithm for finding a minimum independent dominating set in graphs. In Fedor V. Fomin, editor, *Graph-Theoretic Concepts in Computer Science*, pages 78–89, Berlin, Heidelberg, 2006. Springer Berlin Heidelberg.
- [10] Serge Gaspers and Gregory B. Sorkin. Separate, measure and conquer: Faster polynomial-space algorithms for max 2-csp and counting dominating sets. *ACM Trans. Algorithms*, 13(4), December 2017.

- [11] Ernestine Großmann, Kenneth Langedal, and Christian Schulz. A comprehensive survey of data reduction rules for the maximum weighted independent set problem, 2024.
- [12] Hua Jiang and Zhifei Zheng. An exact algorithm for the minimum dominating set problem. In *IJCAI*, pages 5604–5612, 2023.
- [13] Jarod Kintz. Amortized analysis. 2018.
- [14] O. Kullmann. New methods for 3-sat decision and worst-case analysis. *Theoretical Computer Science*, 223(1):1–72, 1999.
- [15] Zhifeng Sun. Multicut survey. Technical report, Technical report, 2008. URL [http://www.ccs.neu.edu/home/austin/papers ...](http://www.ccs.neu.edu/home/austin/papers...), 2008.
- [16] Johan M.M. van Rooij and Hans L. Bodlaender. Exact algorithms for dominating set. *Discrete Applied Mathematics*, 159(17):2147–2164, 2011.
- [17] Mingyu Xiao. Solving Directed Multiway Cut Faster Than 2^n . In Timothy Chan, Johannes Fischer, John Iacono, and Grzegorz Herman, editors, *32nd Annual European Symposium on Algorithms (ESA 2024)*, volume 308 of *Leibniz International Proceedings in Informatics (LIPIcs)*, pages 104:1–104:13, Dagstuhl, Germany, 2024. Schloss Dagstuhl – Leibniz-Zentrum für Informatik.
- [18] Patric R.J. Östergård. A fast algorithm for the maximum clique problem. *Discrete Applied Mathematics*, 120(1):197–207, 2002. Special Issue devoted to the 6th Twente Workshop on Graphs and Combinatorial Optimization.

Alulírott Micskó Máté Benedek nyilatkozom, hogy szakdolgozatom elkészítése során az alább felsorolt feladatok elvégzésére a megadott MI alapú eszközöket alkalmaztam:

Feladat	Eszköz	Hely	Megjegyzés
Python kód generálás	gpt-4-turbo	Notebook	
Ábra készítés	gpt-4-turbo	1,3.9,4.10	Csak formázáshoz

A felsoroltakon túl más MI alapú eszközt nem használtam.