

Teszteset válogatás távolság metrikával

KOVÁCS GÁBOR

Budapesti Műszaki és Gazdaságtudományi Egyetem, Távközlési és Médiainformatikai Tanszék
kovacsg@tmit.bme.hu

Kulcsszavak: teszteset válogatás, sztring szerkesztési távolság, kommunikációs protokollok

E cikk a szerkesztési távolság metrika alapú tesztválogatási módszert [1,2] bővítve egy polinom idejű eljárást mutat be, amelyekkel meghatározható egy kommunikációs protokoll tesztkészletének legkisebb számosságú, legnagyobb belső távolsággal bíró lefedő tesztkészlete. Az eljárás először meghatározza a megtartandó tesztesetek minimális számát, majd második lépésként kiválasztja azt a készletet a legkisebb méretűek közül, amely teszteseteinek távolságösszege a legnagyobb, tehát tesztesetei a legjobban szétszóródnak a protokoll állapotterén.

1. Bevezetés

Az automatikus tesztgeneráló algoritmusok használatának elterjedését leginkább akadályozó tényező az, hogy jelenleg nem megoldható a – formális – modellből származtatott óriási méretű tesztkészletben található redundanciák felderítése. A szükségessé váló tesztválogatás célja a teszteset-halmaz számosságának minimalizálása úgy, hogy a leszűkített készlet még mindig képes legyen kielégíteni olyan kritériumokat, mint például a tesztesetek által definiált útvonalak lefedése [1,2], a hibamoddal megvalósított kódlefedés [3], vagy a teszteset részcélok kielégítése [4].

Tekintettel az automatikusan generált tesztkészletek gigantikus méretére, valamint arra, hogy a válogatási problémák rendszerint NP-teljesek, hatékony közelítések megfogalmazása szükséges. Ilyen közelítés a tesztesetek közötti sztring szerkesztési távolságot figyelembe vevő módszer [1], amely akkor mond két szekvenciát (tesztesetet) hasonlóknak, redundánsnak, ha azok szerkesztési távolsága nem nagyobb egy adott ϵ küszöbszámnál. Ezt a módszert kiegészítendő e cikk megmutatja, hogy a távolság alapú teszteset válogatás polinom időben megoldható.

A probléma első része az adott küszöbszámhoz tartozó legkisebb számosságú tesztkészlet méretének meghatározása, aminek a célja a tesztkészlet méretének lehető legnagyobb mértékű csökkentése. A második részprobléma a tesztesetek szerkesztési távolsága alapján megmutatja a tesztkészletet azon minimális elemszámú részhalmazát, amelyben a tesztesetek leginkább eltérnek egymástól.

A cikk második szakasza összefoglalja az eseményszekvenciák (tesztesetek) közötti távolsághoz kapcsolódó fogalmakat, jelöléseket, definíciókat. A harmadik, illetve a negyedik szakasz egy-egy átalakítást mutat be, mellyel a minimális számosságú, illetve a maximális belső távolságú lefedő tesztkészlet meghatározható, végül pedig áttekinti a bemutatott eljárás általánosíthatóságát.

2. Szekvenciák távolsága

A cikk az egyszerűség kedvéért tesztesetek helyett eseménysorozatokra definiálja az algoritmusokat, amelyek később változtatás nélkül kiterjeszthetők az általánosabb teszteset problémára.

Egy t eseménysorozat, amelyet – például – véletlen sétával állíthatunk elő egy kommunikációs protokoll viselkedését definiáló véges állapotgép alapján, bemeneti (I) és kimeneti (O) események sorozatából áll: $t = x_1 x_2 \dots x_N$, ahol x_i egy esemény az $I \cup O$ halmazból.

Az eseményszekvenciák által definiált módon leképezhetők tömör, a protokoll állapotgépéről is információt hordozó karaktersztringekké úgy, hogy egy-egy karakter tetszőleges számú, de legalább egy, egymás utáni be-, illetve kimeneti eseményt reprezentál [2].

Példa. Legyen az eseménykészlet $I \cup O = \{a, b, c\}$, és legyen a karakter ábécé $C = \{V, W, X, Y, Z\}$. A leképezések halmaza legyen: $\{(a, V), (b, W), (c, X), (aa, Y), (bc, Z)\}$. E leképezés szerint az aa , illetve a bc eseménysorozat lehet egy-egy hurok a protokoll állapotgépeinek egy-egy állapota körül. Ha a T szekvenciakészlet (tesztkészlet) a következő elemekből áll: $T = \{baab, bcbc, aabc, abab\}$, akkor a megfelelő sztringkészlet $S = \{WYW, ZZ, YZ, VWVW\}$ lesz.

Két sztring közötti szerkesztési távolság [5] az egyik a másikba alakításához szükséges karakterbeszúrás, karaktertörlés, illetve karakterátírás műveletek minimális száma, szerkesztési költsége, ha e műveletek nem egyéngyiek. A számítás komplexitása a két sztring hosszával arányos. A távolság egy metrika, azaz nemnegatív, szimmetrikus, és teljesül rá a háromszög egyenlőtlenség.

E definíció alapján az eseményszekvenciákból képezett sztringkészlethez konstruálható egy D távolságmátrix, ahol a d_{ij} elem a sztringkészlet i -edik és j -edik eleme közötti szerkesztési távolság. A távolság fogalma miatt a D mátrix szimmetrikus, és főátlójában 0 értéket tartalmaz. Az elemek értékei e cikkben az egyszerűség kedvéért egészek, [2] alapján azonban racionális értéket is felvehetnek.

Példa. Legyenek a sztringműveletek egységnyi költségűek. Folytatva az előző példát, az S készlet első (WYW) és második (ZZ) eleme csak 3 sztringművelettel alakítható át egymásba. Az első (WYW) és harmadik (YZ) eleme között a távolság 2 egység, mert az első sztring első W karakterét törölve és a második W -t Z -re átírva a harmadik sztringet kapjuk. Az első (WYW) a negyedikbe ($VWVW$) az első V törlésével és az Y V -vé való átírásával alakítható át két lépésben. A második (ZZ) a harmadikba (YZ) egy átírás művelettel átvihető. A második (ZZ), illetve a harmadik (YZ) sztring távolsága a negyedikétől ($VWVW$) 4.

A távolságmátrix tehát:

$$D = \begin{pmatrix} 0 & 3 & 2 & 2 \\ 3 & 0 & 1 & 4 \\ 2 & 1 & 0 & 4 \\ 2 & 4 & 4 & 0 \end{pmatrix}$$

Ha két eseményszekvencia (teszteset) a protokoll állapotterének azonos részét járja be hasonló úton, akkor a köztük lévő szerkesztési távolság „kicsi” lesz, és fordítva, a „nagyon eltérő” eseményszekvenciák – jó eséllyel – az állapotter más-más részeit járják be. Ha két teszteset az állapotter azonos részét ellenőrzi, akkor az egyik redundánsnak tekinthető és eldobható.

E megfontolás alapján definiálható egy ε -közelítés [1,2]: a T tesztkészlet ε -lefedése a T tesztkészletnek, ahol T' T egy részhalmaza, ha T minden t eleméhez található T' -ben egy t' elem, amelyre t és t' szerkesztési távolsága nem nagyobb, mint ε . Vagyis T tesztkészlet tetszőleges eleme előállítható a leszűkített T' tesztkészlet egy eleméből maximum ε költségű szerkesztési lépéssel. A definíció következménye, hogy tetszőleges két T' -beli elemre azok távolsága nagyobb, mint ε .


3. A minimális számosságú lefedő készlet mérete

Az elsődleges cél a tesztválogatás során a tesztkészlet méretének lehető legnagyobb mértékű csökkentése. Ehhez az egymást ε -lefedő tesztesetek halmazából a legkisebb elemszámú T' részhalmazt kell kiválasztanunk, amely az összes T -beli elemet ε -lefed.

A tesztkészletek viszonya az 1. ábrán látható. A teljes T tesztkészletet a külső téglalap jeleníti meg, amiből keressük az ellipszissel jelölt T' részkészletet. A tónusozott terület azon teszteseteket jelöli, amelyek az ε távolságnál közelebb vannak egymáshoz (egymást ε -

1. ábra

Az eredeti tesztkészlet és a lefedő készlet viszonya



lefedő tesztesetek halmaza). T' egy részhalmazának elemei nem fedhetők le más tesztesettel, ezért mindenképpen elemei lesznek a kiválasztott T' -nek, ezt a fehér terület jelöli. Ezen kívül T' egy T'' részhalmaza ε -lefed a teljes T halmazt. T'' és ezáltal T' mérete akkor lesz a legkisebb, ha minden egyes T'' -beli elemhez a lehető legtöbb független T -beli elemet rendeljük.

Készítsünk a D mátrix alapján egy 0 vagy 1 elemeket tartalmazó A mátrixot úgy, hogy ha az i -edik szekvencia ε -lefed a j -edik szekvenciát, vagyis ha távolságuk nem nagyobb ε -nál, akkor legyen $a_{ij} = 1$. A T'' készlet minimális számosságát az A mátrix rangja (lineárisan független sorainak, illetve oszlopainak száma) adja meg.

Példa. Az előző szakasz példájában szereplő D mátrixhoz tartozó A mátrix a következő, ha $\varepsilon = 2$:

$$A = \begin{pmatrix} 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \end{pmatrix}$$

Az A mátrix rangja 2, tehát T'' kételemű. Mivel nincs olyan teszteset, ami nem ε -lefedhető más tesztesettel, azaz nincs csak 0-t tartalmazó sor, illetve oszlop A -ban, a lefedő T' is kételemű lesz. A példa két megoldása a $\{WYW, ZZ\}$ és a $\{YZ, VWVW\}$ készlet, amelyek kölcsönösen lefedik egymást.

Mivel a távolság definíciója szimmetrikus, minimális számosságú ε -lefedő T'' tesztkészletpár mindig létezik, ha $A \neq 0$, különben, azaz a legrosszabb esetben, T ön-maga a megoldás. Előfordulhat az is, hogy nem csak egy ilyen T'' pár létezik, ezért a megoldások között egy további kritérium alapján is különbséget tehetünk, különbséget kell tennünk.

4. Maximális belső távolságú lefedő készlet

Azt már tudjuk, hogy mekkora annak a tesztkészletnek a minimális mérete, amely képes kielégíteni az ε -lefedést. A tesztkészlet-optimalizáció második lépése ezek közül kiválasztja azt a minimális elemszámú tesztkészlet jelöltet, amelyik a lehető legnagyobb mértékben szórja szét a teszteseteket a protokoll állapotterén, vagyis megkeresi azt a megoldást, amelyre a T' készleten belüli szekvenciák közötti távolságok összege maximális. A megoldandó optimalizálási probléma tehát:

$$\max \sum_{\forall t'_i, t'_j \in T'} d(t'_i, t'_j)$$


ahol d a távolságfüggvény, valamint t'_i és t'_j T' -beli elemek, azaz távolságuk nagyobb, mint ε .

A probléma ekvivalens a következő folyamproblémával [6]. Nyilvánvalóan minél több elemet tartalmaz a T' tesztkészlet, annál nagyobb lehet a maximális távolságösszeg, ezért legyen T' elemszáma pontosan k , a 3. szakaszban megtalált minimális számosság értéke. Legyen C egy a D távolságmátrix méretével megegyező méretű kapacitásmátrix, amely elemei 0 vagy 1 értéket vehetnek fel. Legyen $G = (V, E, C, D)$ egy a C és D

mátrixokkal paraméterezett páros irányított gráf, ahol a csomópontok halmaza öt részre osztható $V = B \cup J \cup \{s, s^*, t\}$.

Tartozzék a D mátrix minden egyes sorához a $B = \{l_1, l_2, \dots, l_T\}$ bal oldali csomóponthalmaz egy eleme, valamint minden egyes oszlopához a $J = \{r_1, r_2, \dots, r_T\}$ jobb oldali csomóponthalmaz egy eleme. Vezessen a bal oldali csomóponthalmaz i -edik csomópontjából (l_i) c_{ij} kapacitással és d_{ij} költséggel irányított él a jobb oldali csomóponthalmaz j -edik csomópontjába (r_j). Legyen s összekötve az s^* csomóponttal egy k kapacitású és 0 költségű irányított él által. Legyen s^* összekötve B összes csomópontjával egységnyi kapacitású, 0 költségű irányított éllel. Vezessen irányított él J minden csomópontjából t -be szintén egységnyi kapacitással valamint 0 költséggel. Az így konstruált G gráf a 2. ábrán látható.

2. ábra Az ekvivalens folyamprobléma



Ez egy maximális költségű maximális folyamprobléma, ahol az s -ből t -be irányuló maximális folyam értéke k . A maximális folyam bizonyos c_{ij} értékeket 1 -re állítva kijelöli T -t. Minden B -beli csomópontból maximum egy kimenő él kerül kiválasztásra, és minden J -beli csomópontra maximum egy bejövő él kerül kiválasztásra. Tehát a folyam D minden sorából, illetve oszlopából maximum egy elemet jelöl meg úgy, hogy a megjelölt elemek összege maximális.

Vagyis az optimalizálási probléma átfogalmazva:

$$\max \sum_{i=1}^T \sum_{j=1}^T c_{ij} d_{ij}, \text{ ahol}$$

$$\forall j: \sum_{i=1}^T c_{ij} \leq 1,$$

$$\forall i: \sum_{j=1}^T c_{ij} \leq 1 \text{ és}$$

$$\sum_{i=1}^T \sum_{j=1}^T c_{ij} = k.$$

A problémát [7]-ben k -számosságú hozzárendelési problémának (k -cardinality Assignment Problem, k -AP) nevezték el, és bebizonyították, hogy polinom időben megoldható.

Példa. Az már az előző szakaszból tudjuk, hogy $k = 2$ az $\varepsilon = 2$ esetben. Az egyik megoldás szerint $c_{14} = c_{23} = 1$, a másik szerint $c_{32} = c_{41} = 1$, és minden más elem C -ben 0 . Mivel a maximális távolságösszegre mindkét megoldás

esetén 3 -at kapunk ($c_{14} * d_{14} + c_{23} * d_{23} = 1 * 2 + 1 * 1 = 3$, $c_{32} * d_{32} + c_{41} * d_{41} = 1 * 2 + 1 * 1 = 3$), két egyenértékű megoldás létezik: $\{baab, bcba\}$ és $\{aabc, abab\}$.

5. Összefoglalás

A minimális számosságú ε -lefedő tesztkészlet megtalálása a cikkben leírt módon visszavezethető lineáris függetlenség vizsgálatára. Így meghatározható a legkisebb elemszámú olyan tesztkészlet mérete, amely legfeljebb egy előre meghatározott ε szerkesztési költséggel átalakítható a teljes tesztkészletté. A legkisebb méretű és a protokoll állapotterén leginkább szétszórott lefedő tesztkészlet megtalálása ekvivalens egy polinom időben megoldható maximális költségű minimális folyamproblémával.

Míg az eseménysorozatok sztringekké alakíthatók át, a mindennapi gyakorlatban használt tesztesetek fákkal reprezentálhatók. Ez a cikkben bemutatott átalakítást az egyes adatobjektumok közötti szerkesztési távolságának számítási módja nem érinti, így az – változtatás nélkül – alkalmazható fákra is. Ugyanakkor megjegyzendő, hogy a tesztesetek leírására alkalmazható gyökérrel rendelkező, bejárési sorrend nélküli címkézett fák közötti szerkesztési távolság meghatározása szintén NP-teljes [8].

Irodalom

- [1] Vuong S.T., Curgus J.: Test coverage metrics for communication protocols. In proceedings of the IWPTS. Leischendam, The Netherlands, 1991.
- [2] Feijs L.M.G., Goga N., Mauw S., Tretmans J.: Test Selection, Trace Distance and Heuristics. In proceedings of Testing Communication Systems XIV, pp.267–282., Berlin, Germany, 2002.
- [3] Kovács G., Le Viet D., Wu–Hen–Chang A., Pap Z., Csopaki G.: Applying Mutation Analysis to SDL Specifications. In proceedings of SDL-Forum, Stuttgart, Germany, 2003.
- [4] Csöndes T., Kotnyek B., Szabó J. Z.: Application of Heuristic Methods for Conformance Test Selection. European Journal of Operational Research, 2001.
- [5] Wagner R.A., Fischer M.J.: The String-to-String Correction Problem. Journal of the ACM, 21(1):168–173, 1974.
- [6] Cormen T.H., Leiserson C.E., Rivest R.L., Stein C.: Új algoritmusok. Scolar Kiadó, Budapest, 2003.
- [7] Dell' Amico M., Martello S.: The k -cardinality Assignment Problem. Discrete Applied Mathematics, 76:103–121, 1997.
- [8] Zhang K., Statman R., Shasha D.: On the editing distance between unordered labeled trees. Information Proc. Letters, 42(3):133–139, 1992.