

Irányított vektormező konvolúció objektum körvonalak keresésére*

Manno-Kovács Andrea

Elosztott Események Elemzése Kutatólaboratórium
MTA SZTAKI, Budapest
`andrea.manno-kovacs@sztaki.mta.hu`

Absztrakt. Az aktív kontúr módszer széles körben alkalmazott, hatékony kontúr kereső eljárás. Ez a cikk a korábban bemutatott Harris alapú Vektormező Konvolúció (HVFC) algoritmus egy továbbfejlesztése, mely a kép jellemzőpontjainak közvetlen környezetéből kinyert gradiens alapú irányinformációt alkalmazza. Az irányinformáció segítségével egy jobb éltérkép alkalmazható az iteratív folyamatban, mely csak a releváns éleket tartalmazza. A bemutatott Irányított HVFC (DHVFC) módszer fő előnye, hogy az irányinformációt kihasználva képes javítani a körvonal detekció pontosságát, még erős háttérzaj és nagy görbületű kontúrok esetén is. A kvantitatív és kvalitatív kiértékelés és más state-of-the-art módszerekkel való összehasonlítás azt mutatja, hogy a most bemutatott irányított detekció képes pontosabb eredményt elérni a meglévő algoritmusoknál.

1. Bevezetés

Az aktív kontúr elmélet alapjait 1988-ban mutatta be Michael Kass [1] alapvetően objektumok körvonalának megkeresésére. Az iteratív módszerben a kontúrt közelítő görbét külső és belső energiák irányítják, előbbi a képi sajátosságokat, utóbbi a görbe tulajdonságait hivatott képviselni. Az alapelmélet bemutatása óta eltelt időben számos fejlesztés, módosítás került publikálásra, kompenzálандó az alapszám hiányosságait. A bemutatott módszerek két csoportba sorolhatók: a parametrikus [2–5] és régió alapú [6, 7] eljárások.

A régió alapú aktív kontúr eljárások előnye, hogy nem érzékenyek a kezdőkontúr kijelölésre, és több, akár komplex objektumot is képesek egyszerre megtalálni. Azonban problémát jelentenek számukra a nyitott élek és a körvonalon belüli intenzitás változás, ráadásul a konvergencia sebességük is lassú.

A parametrikus módszerek általában érzékenyebbek a zajra, paraméter beállításokra és a nagy görbületű kontúrok detekciója is problémás. Ezeket a hátrányokat kiküszöbölendő, különböző algoritmusok születtek [2, 4, 5] a külső energiát újradefiniálásával, hatékonyabban kiemelve a kép jellemzőit.

* Eredeti publikáció: A. Manno-Kovács: "Direction Selective Vector Field Convolution for Contour Detection", in Proc. of IEEE International Conference on Image Processing, Paris, France, 2014.

A nagy görbületű kontúrrészek pontosabb megtalálása vezérelte azt a korábbi munkát [5], melyben a Harris alapú Vektormező Konvolúció (HVFC) algoritmus került bemutatásra. A Harris sarokdetektor [8] karakterisztikus függvényének módosítása került a külső energiatagba, melynek lokális maximumhelyei határozták meg a kontúr automatikus inicializálását. A fejlesztés a Gradiens Vektorfolyam (GVF) algoritmusra is alkalmazható. Az elvégzett kísérletek azt mutatták, hogy a javasolt módszer képes a nagy görbületű kontúrrészek pontosabb detektálására, ellenben nem képes kezelni a háttérzajt. Mivel egy komplexebb háttér esetén a háttérben is jelennek meg lokális maximumok a módosított karakterisztikus függvényben, így a kapott jellemzőtérrépen is hangsúlyosak a háttér ezen részei.

Ez a munka egy új ötletet mutat be a HVFC módszer hátrányainak kiküszöbölésére, a jellemzőpontok közeli környezetéből kinyert irányinformáció felhasználásával. A szakirodalomban van néhány korábbi próbálkozás az irányinformáció használatára, mind régió alapú [7, 9], mind parametrikus [3] esetben. A [7] munka megmutatta, hogy az iránytényező hatékonyan építhető be a klasszikus aktív kontúr egyenletbe, egy jól-definiált minimalizálási problémát adva. A [9] egy új metrikát mutatott be, mely a görbe és gradiens iránya közti eltérést bünteti, egy érintenzitástól függő faktorial szorozva. A Dinamikus Irányított GVF (DDGVF) [3] más módon kezeli az irányokat és csak a pozitív és negatív lépcsőre koncentrál. Ehhez a gradiens x és y irányú részét teljesen külön veszi a külső energiatagban. A módszer fő előnye, hogy képes a különböző irányú éleket kezelni.

Jelen esetben, a többirányú élek (sarkok) a korábban említett Harris alapú éltérkép segítségével jól kezelhetőek. A jellemzőpontok irányinformációja segít csökkenteni a háttérrészek hamis detekcióját, a külső energiatagban szereplő éltérkép irányított továbbfejlesztésével, létrehozva az Irányított Harris alapú Vektormező Konvolúciót (DHFVC). Az algoritmus teljesítményét a Weizmann adatbázison [10] teszteltük, illetve több szakirodalmi módszerrel [4, 5, 3] összehasonlítottuk.


2. Aktív kontúr módszer

Az aktív kontúr alaplódszer [1] célja, hogy a görbe $\mathbf{x}(s) = [x(s), y(s)]$, $s \in [0, 1]$ -vel jelölve) az alábbi energiát minimalizálja:

$$E = \int_0^1 \frac{1}{2} (\alpha |\mathbf{x}'(s)|^2 + \beta |\mathbf{x}''(s)|^2) + E_{\text{ext}}(\mathbf{x}(s)) ds, \quad (1)$$

ahol α az elaszticitási, β a rigiditási súlytényező a belső energiatagban; $\mathbf{x}'(s)$ és $\mathbf{x}''(s)$ az s szerinti első és második deriváltak. E_{ext} a képből kinyert külső energiát jelöli, ami a kép jellemzőit reprezentálja:

$$E_{\text{ext}} = \int \int \mu (u_x^2 + u_y^2 + v_x^2 + v_y^2) + |\nabla f|^2 |v - \nabla f|^2 dx dy, \quad (2)$$



1. ábra: Az iránythatású kontúr detekció fő lépései: (a) az eredeti „hajó” kép a Weizmann adatbázisból; (d) mutatja sárgával a jelöl ROI-t, pirossal a generált jellemzőpontokat; (b)-(c): a HVFC és a továbbfejlesztett DHVFC éltérképek, (e)-(f): a HVFC és DHVFC kontúr detekció eredményei.

ahol μ a regularizációs tényező és ∇ a gradiens operátor. Az f éltérkép az I képből ered, az egyik leggyakrabban használt formája (G_σ egy Gaussi simító függvény σ szórással):

$$f(x, y) = |\nabla(G_\sigma(x, y) * I(x, y))|. \quad (3)$$

2.1. Vektormező konvolúció (Vector field convolution)

A vektormező konvolúció (VFC) módszer [4] a GVF hátrányainak - pl. magas számítási költség, zaj- és paraméter-érzékenység - javítását célozta. Az eljárás újdonsága, hogy a VFC külső energiamező egy vektormező kernel és az éltérkép konvolúciójaként számítható:

$$\mathbf{f}_{\text{VFC}}(x, y) = f(x, y) * \mathbf{k}(x, y), \quad (4)$$

ahol a $\mathbf{k}(x, y)$ vektormező kernel egy kernel középpont felé mutató egységvektor és egy magnitúdó függvény szorzataként áll elő.

2.2. Harris alapú vektormező konvolúció (Harris based Vector Field Convolution)

Mivel az f éltérkép (3) nem képes a magas görbületű kontúrrészek hatékony kiemelésére, a korábbi munkában [5] a Harris sarokdetektor által

inspirált, továbbfejlesztett értéképet mutattunk be. Az ötlet alapelve, hogy a nagy görbületű körvonal szakaszok összekapcsolhatóak a sarkokkal, így egy sarokdetektor karakterisztikus függvénye hatékonyan támogathatja az ilyen részek megtalálását. Az eredeti karakterisztikus függvény célja csak a sarokpont kiemelése, így kontúrok esetén ezt módosítani kell. Az f értékép következő változtatását javasolták a szerzők [5]-ben:

$$\mathbf{f}_{\text{HVFC}} = |\nabla(G_\sigma(x, y) * R_{\log\max}(x, y))|(x, y) * \mathbf{k}(x, y). \quad (5)$$

$$R_{\log\max} = \max(0, \log[\max(\lambda_1, \lambda_2)]), \quad (6)$$

ahol λ_1 és λ_2 a Harris mátrix sajátértékei és \log a természetes alapú logaritmus, további részletekért lásd [8].

Az $R_{\log\max}$ függvény lokális maximumhelyeiből generált ponthalmaz jelöli ki a kezdeti kontúr. A ponthalmaz konvex burkából indul el az iteratív kontúrkeresés.

Az $R_{\log\max}$ függvény hátránya, hogy a háttér jellemzőit is felerősíti. Így nagy háttérzaj esetén az \mathbf{f}_{HVFC} térképen a háttérben is magas jellemzőértékek jelennek meg és a görbe nem képes helyesen konvergálni a kontúrhoz (lásd 1(b) és 1(e) képek). Ezt elkerülendő, az \mathbf{f}_{HVFC} térképbe irányinformációt építünk be, aminek segítségével kiemelhetők csak a lényeges kontúrok, illetve továbbra is megmaradnak $R_{\log\max}$ előnyei.

3. Irányított Harris alapú vektormező konvolúció (Directional Harris based Vector Field Convolution)

Az irányítotttsági információ hozzájárulhat egy magasabb szintű jellemző kinyeréséhez, mellyel pontosabbá válhat a detekció. Ehhez minden jellemzőpont környezetében megvizsgáltuk a gradiens irányúságát, hogy megkapjuk a pontot jellemző fő irányt. Jelölje a ∇g_i gradiens vektor nagyságát $\|\nabla g_i\|$ és irányát φ_i^∇ az i . pont esetén. A pont körüli $n \times n$ -es ablakot $W_n(i)$ -vel jelölve (ahol n a felbontástól függ), a φ_i^∇ irányúság a következő:

$$\lambda_i(\varphi) = \frac{1}{N_i} \sum_{r \in W_n(i)} \frac{1}{h} \cdot \|\nabla g_r\| \cdot k\left(\frac{\varphi - \varphi_r^\nabla}{h}\right), \quad (7)$$

ahol $N_i = \sum_{r \in W_n(i)} \|\nabla g_r\|$ és $k(\cdot)$ a kernel függvény, h sáv szélességi paraméterrel. Ekkor az i . jellemzőpont fő iránya:

$$\varphi_i = \operatorname{argmax}_{\varphi \in [-90, +90]} \{\lambda_i\}. \quad (8)$$

Miután az összes jellemzőpont iránya ki lett számítva, a lényeges éleket a Morphological Feature Contrast (MFC) eljárással [11] emeljük ki, mely képes a különálló struktúrák kiválasztására miközben a háttér textúrát összenyomja. Két külön operátorral kezeli a sötét és világos jellemzőket:

$$\psi_{MFC}^+(a) = |a - \rho_{r_2} \tau_{r_1}(a)|^+, \quad (9)$$

$$\psi_{MFC}^-(a) = |\tau_{r_2} \rho_{r_1}(a) - a|^+, \quad (10)$$

ahol τ jelöli a morfológiai zárást, ρ a nyitást, r_1 és r_2 a strukturáló elemek mérete és a a jel ill. kép. Az MFC-nek létezik olyan célzott kiterjesztése, mely a lineáris jellemzők kiemelésére szolgál: miután a textúra részletek el lettek távolítva a ψ_{MFC}^+ és ψ_{MFC}^- operátorokkal, egy következő, lineáris strukturáló elemmel rendelkező ρ_{lin} filtert alkalmazunk. További részletekért lásd [11].

A morfológiai kiemelés után a kapott élhangsúlyos (háttérsökkentett) I_{MFC} képet az $R_{\log\max}$ -szal összevonva egy olyan térképet hozunk létre, melyben csak az olyan $R_{\log\max}$ -beli jellemzőket tartjuk meg, melyek lényeges I_{MFC} -beli struktúrákhoz kapcsolódnak. Így a továbbfejlesztett R_{MFC} éltérkép egyesíti a HVFC algoritmus nagy görbületű detekciós képességét a nagy háttérzaj kezelhetőségével (1(c) ábra). A DHVFC módszer javasolt éltérképe a következő:

$$\mathbf{f}_{DHVFC} = |\nabla(G_\sigma(x, y) * R_{MFC}(x, y))| * \mathbf{k}(x, y). \quad (11)$$

Az iteratív görbeillesztés a VFC és HVFC módszerekkel megegyezően történik (lásd [5]).

4. Kiértékelés

A javasolt módszert a Weizmann adatbázison [10] teszteltük kvantitatívan, ami 100 darab, egy-egy objektumot tartalmazó képből áll. Ebben a kísérletben a DHVFC módszert a HVFC [5] és VFC[4] eljárásokkal hasonlítottuk össze. A kiértékelés második részében kvalitatív kiértékelést végeztünk két olyan képen, melyet [3]-ban használtak, és az eredményeket a DDGVF [3] VFC és HVFC algoritmusokkal vetettük össze. Mind a kvantitatív, mind a kvalitatív kiértékelésben a kezdeti ROI-t egy ellipszissel jelöltük ki, és a kezdeti kontúr a ROI-ből kinyert jellemzőpontok konvex burka volt a VFC, HVFC és DHVFC módszerek esetén.

A különböző paraméter beállításokból adódó eltéréseket elkerülendő, ugyanazokat a paramétereket használtuk mindhárom (VFC, HVFC, DHVFC) eljárás iteratív szakaszában, [4] ajánlásait követve.

Az 1. táblázat a Recall (Felidézés), Precision (Pontosság), F-mérték mérőszámokat mutatja a VFC, HVFC és DHVFC módszerekre. Míg a DHVFC átlagos pontossága hasonló a másik két eljáráséhoz, addig az F-mérték és felidézés mérőszámai meghaladják a két szakirodalmi módszerét.

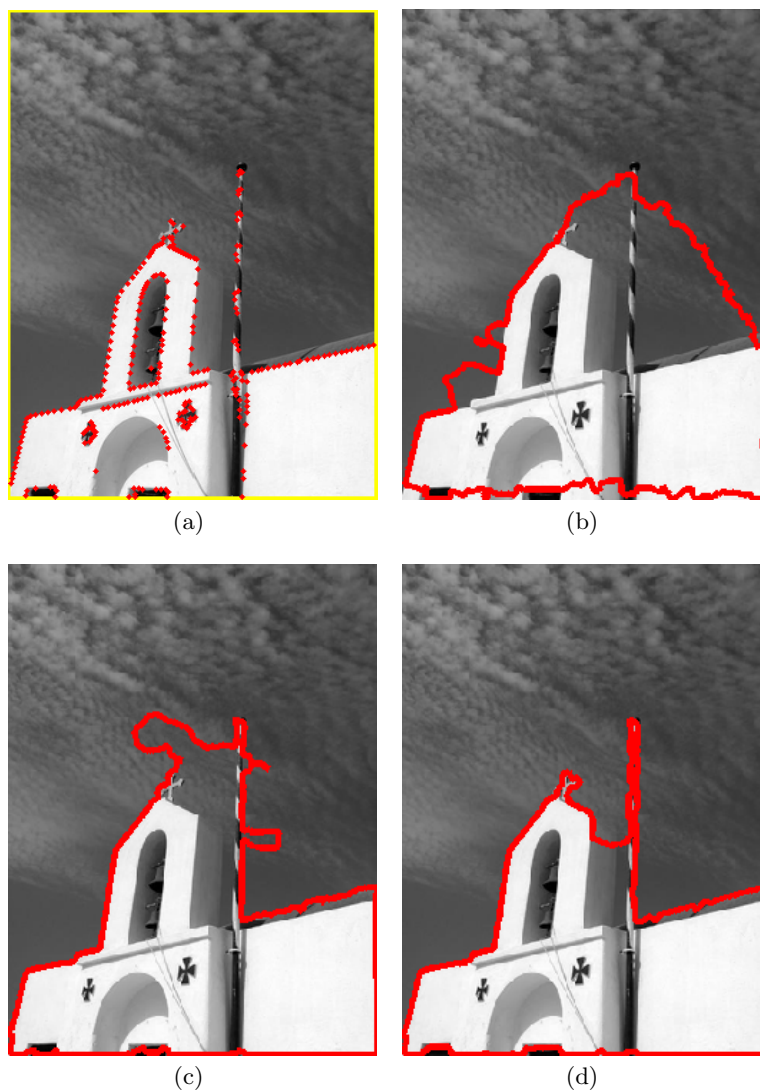
A 2. ábrán a Weizmann adatbázis egy mintaképe látható a különböző technikák által elért eredménnyel. Ebben az esetben nem lett a ROI manuálisan

Algoritmus	F-mérték	Felidézés	Pontosság
VFC	0.79 ± 0.14	0.72 ± 0.20	0.92 ± 0.08
HVFC	0.82 ± 0.14	0.74 ± 0.19	0.96 ± 0.07
DHVFC	0.85 ± 0.13	0.82 ± 0.18	0.92 ± 0.08


1. táblázat: A Weizmann adatbázison mért átlag F-mérték, Felidézés, Pontosság (közép ± szórás) a VFC [4], HVFC [12] és a javasolt DHVFC algoritmusok esetén.

kiválasztva, az algoritmust a kép egészére futtattuk, melyet a 2(a) képen sárgával jelöltünk. Az elért eredmények alapján elmondható, hogy a javasolt DHVFC módszer sikeresen ötvözi a HVFC és az irányítottság előnyeit és hatékonyságban felülmúlja a két másik módszert.

A 3. ábrán a VFC, HVFC, DDGVF és DHVFC eljárások összehasonlítása látszik az „APC” és „paprika” képekre. Fontos megjegyezni, hogy a manuálisan



2. ábra: Mintakép a Weizmann adatbázisból: (a) a ROI sárgával, a jellemzőpontok pirossal jelölve; a detekció eredménye: (b) VFC; (c) HVFC; (d) DHVFC.



3. ábra: Kvalitatív kiértékelés a [3]-ból kiválasztott képekre: Az első oszlop mutatja a bejelölt ROI-t; aztán az algoritmusok eredményei: második oszlop a VFC [4], harmadik a HVFC [12], negyedik a DDGVF [3], ötödik a DHVFC (javasolt) módszer.

kijelölt ROI és a DDGVF módszer eredménye (első és negyedik oszlopok) közvetlenül a [3] cikkből lettek átemelve, ez okozza a kisebb vizuális eltérést. A kvalitatív eredmények alapján elmondható, hogy az „APC” kép esetén a háttérzaj problémát okoz a VFC és HVFC algoritmusok számára, de a DDGVF és DHVFC képes a körvonal eredményesebb megtalálására. Mégis, a jármű finomabb részleteit (mint a jobb felső sarok körül rész) a DDGVF nem képes pontosan követni. A DHVFC az egyetlen eljárás az összehasonlítottak közül, mely képes ezeket a nagy görbületű részeket is hatékonyan detektálni. A 3. ábra második képén (második sor) a DDGVF és DHVC szintén jobban teljesít a VFC és HVFC-nél. Míg azonban a DDGVF a zöltség hátsó (szár mögötti sötétebb) részét kihagyja, a DHVFC képes megtalálni azt. Hasonlóan az objektum alsó részén, a DDGVF által generált kontúr nem a paprika vonalát követi, hanem a szomszédos objektum száraára fut rá, de a DHVFC algoritmus a helyes kontúrt követi.

5. Következtetések

Ebben a munkában egy új, irányított éltérképet mutattunk be, mely eredményesen alkalmazható parametrikus aktív kontúr eljárásokban. A módszer újdonsága, hogy a jellemzőpontok szűk környezetében található irányinformációt terjeszti ki, hogy egy továbbfejlesztett jellemzőtérképet adjon a rendelkezésre álló HVFC algoritmus számára, mellyel lehetséges a pontosabb detekció, még nagy háttérzaj esetén is. A javasolt DHVFC módszer eredményesebben teljesít a meglévő vektormező alapú technikáknál és az irányinformáció egy újfajta értelmezését veti fel parametrikus aktív kontúrok esetén. A további munka ennek az új értelmezésnek a hatékonyabb kihasználására koncentrál.

Irodalom

1. Kass, M., Witkin, A.P., Terzopoulos, D.: Snakes: Active contour models. *Int. J. of Computer Vision* **1** (1988) 321–331
2. Xu, C., Prince, J.L.: Gradient vector flow: A new external force for snakes. In: *Proc. of IEEE Conf. on Comp. Vis. and Patt. Rec.* (1997) 66–71
3. Cheng, J., Foo, S.: Dynamic directional gradient vector flow for snakes. *IEEE Trans. on Image Processing* **15** (2006) 1563–1571
4. Li, B., Acton, T.: Active contour external force using vector field convolution for image segmentation. *IEEE Trans. on Image Processing* **16** (2007) 2096–2106
5. Kovacs, A., Sziranyi, T.: Harris function based active contour external force for image segmentation. *Pattern Recognition Letters* **33** (2012) 1180–1187
6. Chan, T.F., Vese, L.A.: Active contours without edges. *IEEE Trans. on Image Processing* **10** (2001) 266–277
7. Melonakos, J., Pichon, E., Angenent, S., Tannenbaum, A.: Finsler active contours. *Pattern Analysis and Machine Intelligence, IEEE Transactions on* **30** (2008) 412–423
8. Harris, C., Stephens, M.: A combined corner and edge detector. In: *Proc. of the 4th Alvey Vision Conf.* (1988) 147–151
9. Gallego, G., Ronda, J., Valdes, A.: Directional geodesic active contours. In: *Image Processing (ICIP), 2012 19th IEEE International Conference on.* (2012) 2561–2564
10. Alpert, S., Galun, M., Basri, R., Brandt, A.: Image segmentation by probabilistic bottom-up aggregation and cue integration. In: *Proc. of the IEEE Conf. on Comp. Vis. and Patt. Rec.* (2007) 1–8
11. Zingman, I., Saupe, D., Lambers, K.: Detection of texture and isolated features using alternating morphological filters. In: *Proc. of the Int. Symp. on Mathematical Morphology.* (2013)
12. Kovács, A., Szirányi, T.: Improved force field for vector field convolution method. In: *Image Processing (ICIP), 2011 18th IEEE International Conference on.* (2011) 2853–2856