

Új típusú, Harris függvény alapú tulajdonságtérkép és ponthalmaz objektumok körvonalának megkeresésére

Manno-Kovács Andrea, Szirányi Tamás

MTA SZTAKI, Budapest, andrea.kovacs@sztaki.mta.hu

Kivonat Ez a cikk az eredeti Harris sarok detektor egy továbbfejlesztését és annak alkalmazását mutatja be objektumok körvonalának detekciójára. ¹ Ehhez a Harris féle sarokdetektor karakterisztikus függvényét módosítva, majd azt parametrikus aktív kontúr eljárások külső erő tagjában jellemzőtérképként alkalmazva megmutatjuk, hogy a fejlesztés lehetővé teszi a nagy görbületű kontúrok pontosabb detekcióját, a térkép lokális maximumaiként kinyert ponthalmaz pedig az aktív kontúr robusztusabb inicializálását segíti.

Az alkalmazott algoritmus kisebb kiegészítéssel felhasználható több objektum egyidejű lokalizálására és megkülönböztetésére, így sikerrel alkalmazható repülő objektumok azonosításának előfeldolgozási lépéseként a gépek detektálására. Mivel az objektumok jellemzően kicsik, körvonaluk zajos, így a tradicionális pontdetektorok nem képesek hatékony eredményt adni, ezért különösen előnyös az általunk javasolt eljárás használata.

A bemutatott módszer hatékonyságát kvalitatív és kvantitatív módszerekkel teszteltük, a kapott eredményeket a felhasználási terület releváns szakirodalmi eljárásaival összevetettük.

Mindezek alapján elmondható, hogy a javasolt fejlesztéssel nagymértékű javulás érhető el a kipróbált területen.

1.. Bevezetés

Korunk egyik legfontosabb képfeldolgozási kihívása az objektumok körvonalának minél pontosabb meghatározása. A feladat egyik lehetséges megközelítése az 1988-ban bemutatott aktív kontúr (AC) módszer [12] alkalmazása, melynek számtalan továbbfejlesztése jelent meg az elmúlt bő két évtizedben [28,6,4,7,26,13,3,19,20]. Az elasztikus modellen nyugvó alapmódszer lényege, hogy a kontúrt közelítő görbét egy energiainimalizálás mozgatja, mely különböző energiataragokból áll. Alapvetően két energiataragról beszélhetünk: a külső és belső energiáról. Amíg a belső energia felelős a közelítő görbe alakjáért, hogy az kellően hajlékony, de ugyanakkor merev is legyen, addig a külső energia a képi tulajdonságokat képviseli és általában a kép intenzitásának gradienseiből

¹ A cikk nem tartalmaz új eredményt, a benne szereplő eredmények a [16,18] referenciákban kerültek publikálásra.

ered. Ez az erő tolja a görbét az optimum (az objektum körvonal) felé. Az alapmódszernek volt néhány hiányossága: nagyon függött a görbe inicializálástól (nem mindenhol konvergált a keresett körvonalhoz) illetve nem tudta megtalálni a konkáv határokat. Ezeket a hátrányokat kiküszöbölendő, [28] bemutatta a GVF (gradient vector flow) módszert, a szerzők egy új külső energiát definiáltak a képből származtatott bináris vagy szürkeárnyalatos éltérkép gradiens vektorjainak diffúziójaként. Habár a pontosság növekedett, az algoritmus még mindig érzékeny volt a zajra, paraméter beállításokra és az inicializálásra.

Az alapmódszer publikálása óta számos javítás született a hiányosságok pótlására. A publikált módszerek alapvetően két csoportba oszthatók: parametrikus [28,4,19,20] és nemparametrikus [6,7,26,13,3] eljárások.

A parametrikus eljárások gyenge pontjai a zaj, paraméter és inicializálási érzékenység, a topológia változások kezelése illetve a nagy görbületű kontúrok megtalálása. Ezzel szemben a nemparametrikus aktív kontúr módszerek nem függenek az inicializálástól, képesek megtalálni a komplex kontúrrészeket (akár nagy görbületről, akár topológiai változásokról van szó), ugyanakkor alkalmatlanok a nyílt határok kezelésére. Ráadásul, a konvergencia sebességük lassabb és sokkal érzékenyebbek a zajra, mint parametrikus társaik.

A parametrikus fejlesztések egyik irányvonala a külső energiát újradefiniálása, hogy a GVF által elért eredmények tovább javuljanak [9,8,19,11,27,30]. Ezeknek köszönhetően sikerült ugyan az érzékenységet csökkenteni, ám a zajos és nagy görbületű sarkok detektálása még mindig gondot okozott. Az ilyen jellegű komplexebb határvonalak pontos detekciója még mindig az egyik legnagyobb kihívás az objektum körvonal keresés témakörében, amit a meglévő módszerek nem képesek hatékonyan kezelni.

A kezdő állapot meghatározása hasonlóan összetett feladat, amihez egyik megoldásként valamilyen extra képi információt (mint [17]-ben a fókuszt) vagy alaki előismeretet [25] használnak fel. Ezek hiányában a kezdeti állapotot nagyon gyakran kézzel szokás bejelölni.

Ebben a cikkben az inicializálási és görbületi érzékenység problémájának megoldására mutatunk be két különböző parametrikus módszerhez egy továbbfejlesztést, melyek a Harris alapú GVF (HGVF) és Harris alapú „vector field convolution” (HVFC) nevet viselik [16]. A továbbfejlesztés alapötletében [15] a Harris féle sarokdetektorhoz [10] nyúltunk vissza, aminek karakterisztikus (sarkossági) függvényét módosítva, az algoritmus alkalmassá válik nemcsak sarkok, hanem élek egyidejű kiemelésére. A módosított tulajdonságtérkép alkalmazhatósága kettős: míg kiemelkedő pontjai alapján automatikusan kijelölhető az alakzat kezdeti kontúrja, maga a térkép felhasználható egy új típusú külső energiát definiálására.

A kiértékelés során a módszert a Weizmann szegmentációs adatbázison [1] teszteltük, a kapott eredményeket összehasonlítottuk több más algoritmussal, melyek közt mind parametrikus, mind nemparametrikus aktív kontúr eljárások előfordultak. A tesztek azt mutatták, hogy módszerünk képes a kitűzött célok megvalósítására és javulást ér el a nagy görbületű kontúrok detektálásában az inicializálás automatizálása mellett.

Az eredetileg egy objektumra kifejlesztett módszer egy egyszerű kiterjesztéssel alkalmassá válik több objektum egyidejű meghatározására. Így használható több célpontú detektálásra és követésre [18]. Ennek egy alkalmazásaként, repülő objektumokat lokalizáltunk az algoritmussal. A használt képsorozatokban több probléma is nehezíti az azonosítást: a követendő célpontok néha nagyon kicsi méretűek, a háttérben zajok és zavaró hatások fordulhatnak elő, amik a környezetből erednek (pl. felhők, kerozincsíkok, ...), a megvilágítás változik, a kamera remegéséből adódóan időnként az egész kép elmosódott lehet. Továbbá a repülő objektumok alakja igen összetett, tele nagy görbületű kontúrrészekkel, ugyanakkor a körvonal alacsony kontrasztú, esetenként nehezen különböztethető meg a háttértől. Ezek miatt a korábban próbált tradicionális sarkok ill. kiszögellő pont detektorok, kombinálva kontúrkereső módszerekkel, nem tudtak hatékony eredményt felmutatni. Mivel az általunk javasolt Harris detektor alapú továbbfejlesztés éppen ezeket a hátrányokat célozza meg, így nagyobb sikerrel alkalmazható ezeknek a légi objektumoknak a lokalizálására. A lokalizálásra, mint előfeldolgozó lépésre építve a detektált célpontok sikerrel azonosíthatóak és követhetőek.

2.. Aktív kontúr módszer

Az aktív kontúr alaplómódszer [12] 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 energiában; $\mathbf{x}'(s)$ és $\mathbf{x}''(s)$ az s szerinti első és második deriváltak. A rigiditási komponens felel a görbületek (sarkok) detektálásáért, $\beta = 0$ beállítással a görbe bármilyen sarkot képes követni. E_{ext} a képből kinyert külső energiát jelöli, ami a kép jellemzőit reprezentálja. Értéke a releváns képrészleteknél (pl. éleknél, sarkoknál) alacsonyabb, mint a homogén régiókban.

2.1.. Gradiens vektor folyam (Gradient vector flow)

Az alaplómódszer továbbfejlesztéseként [28] egy újfajta külső energiát definiált, mely a képből származtatott bináris vagy szürkeárnyalatos éltérkép gradiens vektorjainak diffúziójából eredt. A belső energiában mind az elaszticitási, mind a rigiditási tag változatlan maradt. A javasolt energiát lehetővé teszi, hogy a görbe (más néven snake) messzebből (homogén területekről) is képes legyen az élre konvergálni. További előny, hogy a módosítással a konkáv kontúrok is detektálhatóak. Az új E_{ext} külső energia:

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



1. ábra: Az eredeti f élkép viselkedése nagy görbületű kontúrra: (a) az eredeti kép, a megfigyelt célterület szürkével kijelölve; (b) a kijelölt terület f éltérképe. A fehér téglalap a nagy görbületű kontúrrészt reprezentáló alacsonyabb f értékeket mutatja; (c) a kijelölt terület f_{VFC} jellemzőtérképe. A fehér téglalap a nagy görbületű kontúrrészt reprezentáló alacsonyabb f_{VFC} értékeket mutatja.

ahol $\mathbf{v}(x, y) = (u(x, y), v(x, y))$ a GVF vektormező, ami minimalizálja E_{ext} -t, μ a regularizációs paraméter, ami az integrandus két része közt egyensúlyoz. Az f éltérkép az $I(x, y)$ képből származtatható, egy általánosan használt formája:

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

ahol G_σ egy Gaussi simító függvény σ a szórás és ∇ a gradiens operátor. Az f éltérkép miatt a módszernek nehézségeket okoz a zajos sarkok illetve a kontrasztgyenge körvonalak megtalálása. Ha megnézzük egy hegyes sarokpont környezetét, akkor látható, hogy nagymértékű intenzitásváltozás csak kevés irányban van. Emiatt a gradiens térkép képzésekor ez a terület nagyon hasonlóan viselkedik, mint egy kontrasztgyenge kontúrpontra: a kontrasztos élekhez képest jóval gyengébb f értékeket produkál. Ez a jelenség látszik az 1. ábra képein, ahol alacsonyabb f értékek vannak a fehér téglalappal kijelölt levél csúcsa körül az 1b. képen. Ennek hatására az iteratív aktív kontúr módszer nem lesz képes pontosan megtalálni az ilyen jellegű csúcsokat (lásd 5. ábra 1. sora).

2.2.. Vektormező konvolúció (Vector field convolution)

A vektormező konvolúció (VFC) módszer [19] egy újfajta külső energiatagot mutatott be, ami a GVF hátrányainak - magas számítási költség, zaj- és paraméter-érzékenység valamint kis konvergálási távolság - javítását célozta. A VFC energiamező a vektormező kernel és az éltérkép konvolúciójaként számítható:

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

ahol $f(x, y)$ a kép alapú éltérkép (3. képlet) és $\mathbf{k}(x, y)$ a vektormező kernel, ami a következő:

$$\mathbf{k}(x, y) = m(x, y)\mathbf{n}(x, y), \quad (5)$$

ahol $m(x, y)$ a magnitúdó az (x, y) pontban és $\mathbf{n}(x, y)$ a kernel közepe felé mutató egységvektor: $\mathbf{n}(x, y) = [-\frac{x}{r}, -\frac{y}{r}]$, ahol r a kernel középpontjától vett távolság.

A VFC elmélet előnye, hogy egy, a mezőbe helyezett szabadon mozgó részecske (esetünkben az iteratív görbe egy pontja) a célterület (a kontúr) felé fog elmozdulni. Az $m(x, y)$ magnitúdót célszerű a középponttól vett távolság szerint csökkenő pozitív függvénynek választani, mint például:

$$m(x, y) = (r + \epsilon)^{-\gamma}, \quad (6)$$

ahol γ határozza meg a csökkenés mértékét, ϵ pedig a nullával való osztást előzi meg. Mivel a VFC jellemzőtérkép (4. képlet) szintén az $f(x, y)$ éltérképen alapul, a nagy görbületű illetve a zajos, alacsony kontrasztú kontúrok detektálása itt is gondot okoz (lásd az 1c. képen és a 5. ábra első sorának ötödik képén).

A nagy görbületű sarkok megtalálásának egy lehetséges módja sarokdetektorok alkalmazása, amik egy karakterisztikus függvényt kiszámolva kiemelik a lehetséges sarkokat a képen. Ötletünk alapját a Harris detektor és a parametrikus aktív kontúr módszerek fúziója adta, mivel a Harris detektor igen megbízható és elforgatás invariáns [22]. A hatékony alkalmazáshoz az eredeti karakterisztikus függvényt módosítani kell, hogy ne csak a sarkokat, hanem a kontrasztszegény éleket is egyenletesen kiemelje.

3.. Harris alapú gradiens vektor folyam és vektormező konvolúció

A bemutatott algoritmus első lépésként kiszámítja a módosított Harris karakterisztikus függvényt (továbbiakban Harris függvényt), majd ez alapján kiemeli a jellemzőpontokat. A pontok meghatározzák a kezdeti kontúr, amiből az iteratív parametrikus aktív kontúr algoritmus (GVF v. VFC) elindul. Az aktív kontúr irányító energiában, a külső energiatagban az eddig használt éltérkép helyett egy Harris függvényen alapuló jellemzőtérképet javaslunk, mellyel a nagyobb problémát jelentő kontúrrészek is pontosabban detektálhatóak.

3.1.. Eredeti Harris detektor

Az eredeti Harris sarokdetektor [10] alapelve szerint a sarokpontokban az intenzitás több irányban is nagymértékben változik. Az (x, y) eltolás hatására bekövetkező D változás az alábbi Taylor kifejtéssel közelíthető:

$$D(x, y) = Ax^2 + 2Cxy + By^2, \quad (7)$$

ami átírható:

$$D(x, y) = (x, y)M(x, y)^T. \quad (8)$$

A kifejezésben az M a Harris mátrix:

$$M = \begin{bmatrix} A & C \\ C & B \end{bmatrix}, \quad (9)$$

ahol $A = \dot{x}^2 \otimes w$, $B = \dot{y}^2 \otimes w$, $C = \dot{x}\dot{y} \otimes w$. $\dot{x} = \frac{\partial I}{\partial x}$ and $\dot{y} = \frac{\partial I}{\partial y}$ jelöli az I kép elsőrendű deriváltjainak becslését, \otimes a konvolúciós operátor és w egy Gaussi elmosó ablak.

A 7. képletben írt Taylor kifejtés jól jellemzi a képpont környezetének görbületi tulajdonságait. A 8. képletben szereplő formára való átírás után D egy autokorreláció jellegű függvény lesz, amiben M jellemzi a pont körüli alakzatot. M sajátértékei arányosak az autokorrelációs függvény fontosabb görbületeivel és M elforgatás invariáns leírását adják. Ez a tulajdonság különösen alkalmassá teszi a sajátértékek felhasználását az aktív kontúr külső energiatagjában, mivel a fontosabb görbületek jól jellemzik a pont körüli alaki részleteket.

Az eredeti módszer az alábbi karakterisztikus (sarkossági) függvényt használja a sarokpontok kiemelésére:

$$R = \text{Det}(M) - k * \text{Tr}^2(M), \quad (10)$$

ahol Det és Tr jelölik az M mátrix determinánsát és nyomát, k pedig egy általában 0.04 körüli együttható. R a sarokrégiókban nagy, pozitív; az élrégiókban negatív; a homogén (lapos) régiókban nulla közeli értéket vesz fel, ezért módosítani kell, ha a sarkok és élek egyidejű, egyenletes kiemelésére akarjuk felhasználni.

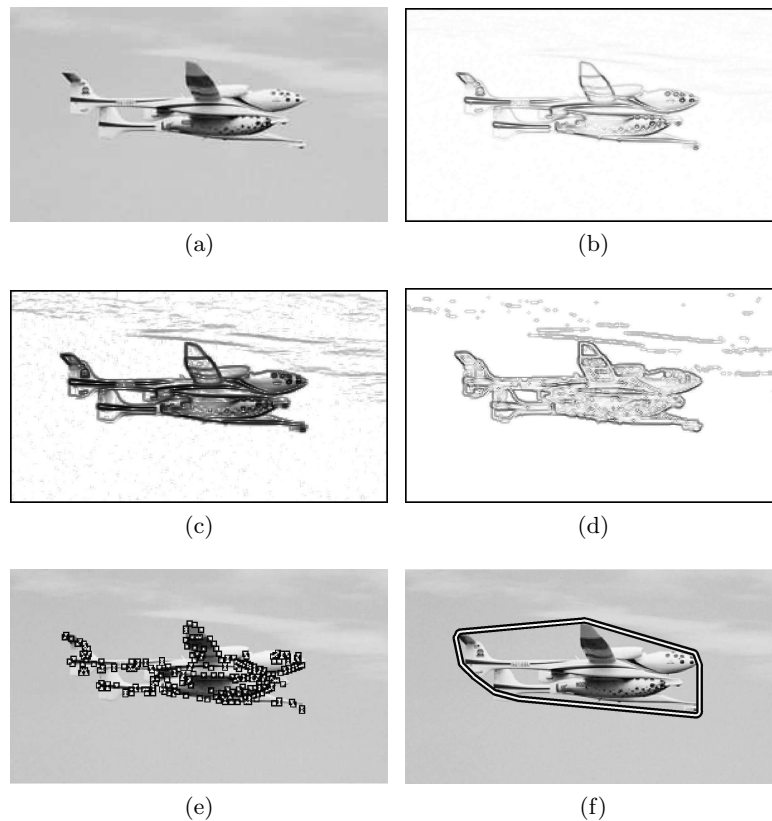
3.2.. Harris alapú jellemzőtérkép

Egy hatékony GVF jellemzőtérkép definiálásához a görbületi viselkedést kell jól jellemezni, ezért az alapötlet az M mátrix sajátértékeinek felhasználása volt. Így, a sajátértékekre alapozva hozunk létre egy új típusú karakterisztikus függvényt, ami képes a kontúrokat kiemelni.

Jelölje λ_1 és λ_2 az M mátrix sajátértékeit (9. képlet). A sajátértékek alapján az alábbi esetek különböztethetők meg: λ_1 és λ_2 értéke is nagy a sarokrégiókban, csak az egyikük nagy az élrégiókban és mindkettő értéke kicsi a homogén régiókban. Ha a sarok- és élrégiókat tekintjük, mindkettőben van legalább egy nagy értékű komponens, így a $\max(\lambda_1, \lambda_2)$ függvénnyel szétválaszthatók a homogén és inhomogén régiók. Ahhoz, hogy a jellemzőtérkép kiegyensúlyozott legyen, a karakterisztikus függvény dinamikáját csökkenteni kell oly módon, hogy az eredeti értékek közt fennálló nagysági viszony továbbra is megmaradjon (izometrikus transzformáció). A természetes alapú logaritmus (\log) teljesíti ezeket a feltételeket: kiegyensúlyozott kimenetet ad mind a sarok, mind az él jellegű kiszögellésekre. Következésképp, az alábbi $R_{\log\max}$ karakterisztikus függvényt [14] javasoljuk az alaki jellemzők leírására:

$$R_{\log\max} = \max(0, \log[\max(\lambda_1, \lambda_2)]). \quad (11)$$

A sarok- és élrégiókra teljesül, hogy $\max(\lambda_1, \lambda_2) \gg 1$. Az $R_{\log\max}$ függvény értékkészlete a pozitív tartomány kell hogy legyen, ha aktív kontúr módszer jellemzőtérképeként alkalmazzuk, így a 11. képletben szereplő külső \max függvény szerepe a homogén régiók (kis λ -k) negatív értékeinek nullával való helyettesítése. A javasolt $R_{\log\max}$ függvény egy példája látható a 2c. képen.



2. ábra: Az R_{logmax} karakterisztikus függvény hatása: (a) az eredeti kép (b) az eredeti, f intenzitás alapú GVF éltérkép; (c) a javasolt, invertált R_{logmax} karakterisztikus függvény (d) a javasolt f_{HGVF} Harris alapú GVF jellemzőtérkép (12. képlet); (e) az R_{logmax} lokális maximumaiként kinyert jellemzőpontokat mutatja; (f) a jellemzőpontok konvex burkaként kapott kezdőkontúr.

Így, a javasolt R_{logmax} karakterisztikus függvényen alapuló továbbfejlesztett jellemzőtérkép:

$$f_{HGVF}(x, y) = |\nabla(G_\sigma(x, y) * R_{logmax}(x, y))|. \quad (12)$$

Ez a függvény lesz a Harris alapú GVF (HGVF) aktív kontúr algoritmus külső energiatagjában alkalmazva. Az f_{HGVF} alapján a Harris alapú VFC (HVFC) módszer jellemzőtérképe pedig a következőképp alakul:

$$\mathbf{f}_{HVFC} = f_{HGVF}(x, y) * \mathbf{k}(x, y). \quad (13)$$

Az eredeti és javasolt jellemzőterképek összehasonlítása a 2. ábrán látható. Amíg az eredeti, intenzitáson alapuló f éltérkép nem képes pontosan kiemelni a kontrasztszegény kontúrrészeket és éles (nagy görbületű) sarkokat (lásd 2b. kép), addig az újonnan javasolt $f_{\text{HG VF}}$ (2d. kép) képes ezeket a problémás területeket jobban kihangsúlyozni.

3.3.. Kezdeti kontúr

A kezdőkontúr pontjai (jellemzőpontok) az $R_{\log \max}$ (11. képlet) lokális maximumaként kerülnek kiszámításra. Jelölje $b_i = \{[x_i - 1, x_i + 1] \times [y_i - 1, y_i + 1]\}$ a $p_i = (x_i, y_i)$ pixel középpontú ablakot, amiben a lokális maximumot keressük. p_i a \mathbf{P} -vel jelölt jellemzőpont halmaz eleme, ha teljesíti az alábbi feltételt:

$$\mathbf{P} = \left\{ p_i : R_{\log \max}(p_i) > T_1 \text{ AND } p_i = \operatorname{argmax}_{q \in b_i} R_{\log \max}(q) \right\}. \quad (14)$$


p_i egy jellemzőpont, ha a hozzátartozó $R_{\log \max}$ függvényérték meghalad egy T_1 küszöböt és ez egy lokális maximum a b_i ablakban. Mivel a küszöb képenként változik, így kiszámításához az adaptív Otsu módszert [21] alkalmazzuk. Mivel a jellemzőpontok az éleken és sarkokon helyezkednek el, így alkalmasak a kezdőkontúr kijelölésére. Eztán a kezdőkontúr a \mathbf{P} ponthalmaz konvex burkaként kerül meghatározásra (lásd 2f. ábra). A konvex burok használata a kontúr inicializálására nem új ötlet [24,29], a kontribúciónk maga a kiterjesztett Harris alapú ponthalmaz, aminek alapján az objektumot lokalizáljuk.

A \mathbf{P} ponthalmaz konvex burka a legszűkebb olyan konvex részhalmaza \mathbf{P} -nek, ami befoglalja \mathbf{P} összes pontját:

$$H_{\text{konvex}}(\mathbf{P}) = \left\{ \sum_{i=1}^k \alpha_i p_i : p_i \in \mathbf{P}, \alpha_i \in \mathbb{N}, \alpha_i \geq 0, \sum_{i=1}^k \alpha_i = 1, k = 1, 2, \dots \right\}. \quad (15)$$

Véges ponthalmaz konvex burkának kiszámítására számos eltérő számítási igényű automatikus algoritmus létezik. Saját implementációnkban a MATLAB beépített függvényét használtuk, ami a „Qhull” algoritmust [2] használja. Ha n -nel jelöljük a \mathbf{P} halmaz pontjainak számát és h -val a kiszámított burok pontjainak számát, akkor a burok számítási igénye $O(n \log h)$.

Az általunk javasolt algoritmus a tradicionális GVF és VFC módszerek menetét követi, de a kiszámított konvex burokból ($H_{\text{konvex}}(\mathbf{P})$) indítja az iteratív kontúr keresést és a külső energiatagban az új $f_{\text{HG VF}}$ és f_{HVFC} jellemzőterképeket használja a sima f éltérkép helyett (lásd 2. képlet). Ezért az algoritmus működése, paraméter beállításai igen hasonlóak lesznek az eredetihez. A jellemzőterkép kiszámításához a Gaussi elmosó függvény ablakméretét (lásd 2.1. fejezet) kell meghatározni előzetesen, mely a térkép simaságáért felel. Kísérleteinkben $\sigma = 0.2$ beállítást használtunk a zaj nélküli képek esetén és $\sigma =$



3. ábra: Több objektum szétválasztása. (a): Canny éltérkép; (b): A két objektum szétválasztott pontjai.

1.5-öt a zajos képekhez. Ezen a paraméteren kívül a javasolt térkép kiszámítási módszer a tradicionális aktív kontúr algoritmus paramétereit használja, így a paraméter érzékenység hasonlóan alakul, mint a GVF és VFC elemzésekben [28,19].

3.4.. Több objektum detektálása

Előfordulhat, hogy egyszerre nem egy, hanem több objektum van a képen, aminek a körvonalát szeretnénk meghatározni. Ennek az esetnek a kezelésére egy egyszerű megoldást adunk most, ami képes szétválasztani a \mathbf{P} ponthalmaz által közösen reprezentált objektumokhoz tartozó részhalmazokat [18].

A szétválasztási folyamat során az azonos objektumhoz tartozó pontokat a Canny éltérképen [5] való összekötöttségük alapján rendeljük össze. Ha van a két pontot összekötő él az éltérképen, akkor a két pont ugyanazon objektumhoz tartozik. Az alábbi gráf reprezentációval formalizáljuk az összefüggést: adott a $\mathbf{G} = (\mathbf{P}, \mathbf{N})$ gráf a \mathbf{P} pont- és \mathbf{N} élhalmazzal. A \mathbf{P} ponthalmazt a 14. egyenlet definiálja, az \mathbf{N} élhalmazt a pontok éltérképen való összekötöttsége alapján határozzuk meg.

Jelölje E a kép dilatált Canny éltérképét (lásd 3a. kép), ahol a detektált élek 1, a háttér 0 értékű. Két adott $p_i, p_j \in \mathbf{P}$ csúcs összekötött \mathbf{N} -ben, ha a következő feltételek teljesülnek:

1. $E(p_i) = 1$; p_i élpont E -ben.
2. $E(p_j) = 1$; p_j élpont E -ben.
3. Létezik E -ben egy csupa 1-ekből álló véges út p_i és p_j között (azaz p_i és p_j összekötött E -ben).

Miután ezeket a feltételeket minden pontra végignéztük, a \mathbf{G} gráf \mathbf{N} élhalmaza kialakult. A \mathbf{G} gráf K független részgráfból fog állni, jelölje ezek közül a k -at \mathbf{G}^k , pontjainak halmazát \mathbf{P}^k :

$$\mathbf{P}^k = \{p_1^k, \dots, p_{N_k}^k\}, \quad (16)$$

ahol N_k a \mathbf{G}^k -ban levő pontok száma. Ekkor az alábbi teljesül a \mathbf{P}^k ponthalmazokra:

$$\mathbf{P} = \bigcup_{k=1}^K \mathbf{P}^k; \quad \mathbf{P}^i \cap \mathbf{P}^j = \emptyset \quad \forall i, j. \quad (17)$$

Azok a részgráfok, melyek csak néhány pontot tartalmaznak, túl kicsik ahhoz, hogy valós objektumot reprezentáljanak, és valamilyen zajt jelölnek. Így azokat a \mathbf{G}^k részgráfokat, melyek n küszöbnél kevesebb pontot tartalmaznak ($N_k < n$), elhagyjuk. A kísérletek során $n = 4$ küszöböt alkalmaztunk. A szűrés után fennmaradó ponthalmazok K' objektumot jelölnek:

$$\mathbf{P}' = \bigcup_{k=1}^{K'} \mathbf{P}^k. \quad (18)$$

A 3b. képen látható a két objektumot reprezentáló, szétválasztott ponthalmaz.

4.. Eredmények és kiértékelés

A kiértékelés során végeztünk mind kvantitatív, mind kvalitatív méréseket. Előbbihez a Weizmann intézet szegmentációs kiértékelő adatbázisának [1] kiválasztott képeit használtuk fel. Méréseinkhez mindkét esetben olyan képeket válogattunk, melyen az objektum kontúrja nehezen detektálható, kontúrszegény éleket, nagy görbületű kontúrrészeket tartalmaz vagy zajos (5. ábra). Az általunk javasolt módszerek teljesítményét az eredeti parametrikus GVF és VFC alapmódszerekkel és az ACWE (active contour without edges) [7] nemparametrikus módszerrel egyaránt összehasonlítottuk.


A tesztek során a különböző módszerek nyilvános MATLAB forráskódjait használtuk fel egyéb optimalizálás nélkül. A paraméterek kiválasztásához a hivatkozott referenciák útmutatását követtük.

4.1.. Kvantitatív kiértékelés a Weizmann adatbázis [1] használatával

A kvantitatív kiértékelés során a – „ground truth”-szal rendelkező – adatbázisból 23 tesztképet választottunk ki, melyek nagy görbületű vagy kontrasztgyenge kontúrrészeket tartalmaztak (lásd 4. ábra). A célterületet egy ellipszissel jelöltük ki, a kezdeti kontúrt a 3.3. fejezetben ismertetett módon számítottuk, minden iteratív algoritmus ebből indult ki. A legpontosabb eredmény eléréséhez az optimális paramétereket a kapcsolódó referenciák ajánlásai alapján határoztuk meg. Ahogyan egy korábbi publikáció [20] is említi, mivel az adatbázis képeinél gyakori a nagymértékű intenzitásváltozás az objektumon belül, így az ACWE módszer tesztelésére nem alkalmas.

Így a kvantitatív kiértékelés során csak a GVF, HGVF, VFC és HVFC módszerek teljesítményét hasonlítottuk össze.

A kvantitatív mérések során az F-mértéket használtuk, ami a pontosság és felidézés értékek súlyozott, harmonikus közepe:



4. ábra: A részletes, kvantitatív kiértékelés eredményei. A függőleges tengely az elért F-mértéket mutatja az egyes képek és módszerek esetén, a vízszintes tengely a Weizmann adatbázis [1] kiértékelésre kiválogatott képeit sorszámozva. A különböző színű oszlopok a különböző módszerek által elért eredményeket jelölik: a sötétszürke a GVF [28], a fehér a VFC [19], a világosszürke a HGVF (javasolt) és a fekete a HVFC (javasolt).

$$F = \frac{2 \cdot \text{pontosság} \cdot \text{felidézés}}{\text{pontosság} + \text{felidézés}}. \quad (19)$$

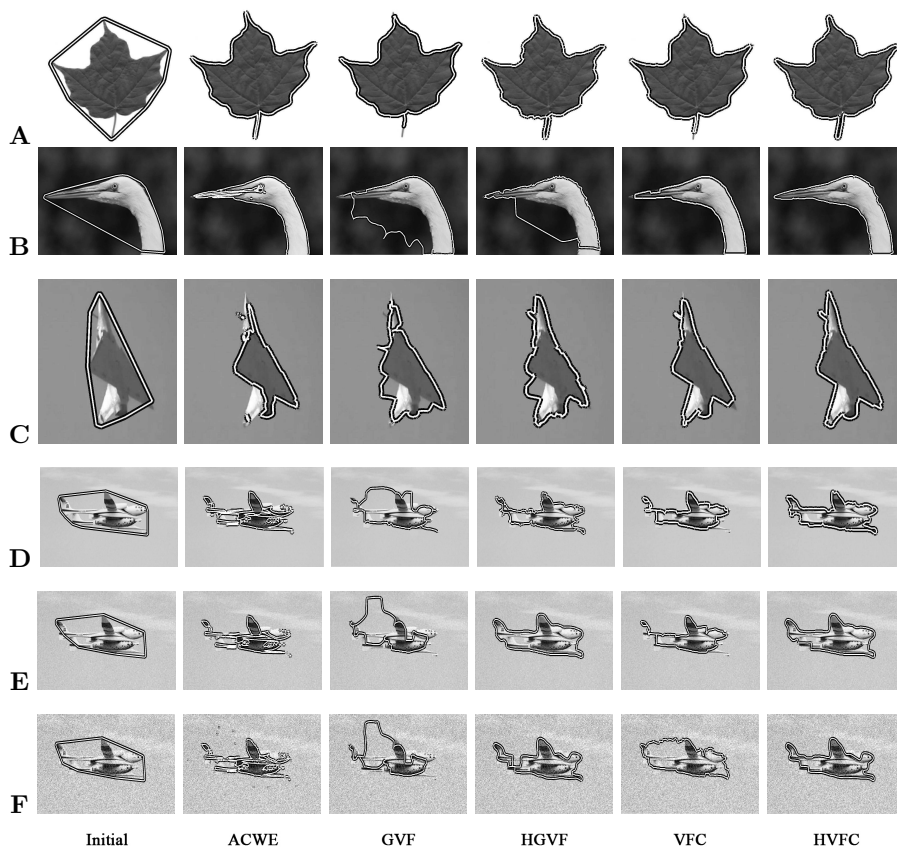
Az 4. ábrán láthatóak a képenként elért eredmények, minden algoritmusra külön-külön. Összesítve az eredményeket, az átlagosan elért F-mérték (átlag \pm szórás) a különböző algoritmusokra:

GVF: 0.79 ± 0.09 ; HGVF: **0.87 ± 0.08** ; VFC: 0.86 ± 0.07 és HVFC: **0.91 ± 0.06** . Fontos megemlíteni, hogy a javasolt HGVF és HVFC módszerek magasabb F-mértéket értek el, mint az eredeti, klasszikus megfelelőjük.

4.2.. Kvalitatív eredmények kiválasztott képeken

Ezekben a tesztekben specifikus képeket választottunk ki, hogy a különböző módszerek teljesítményét összehasonlítsuk (5. ábra). A kvalitatív eredmények mellett a futási időket is mértük, ezek az 1. táblázatban láthatók. Mivel a futási idő függ a kép méretétől, így az egyes képek méretét szintén feltüntettük a táblázatban. A futási időket Intel(R) Core(TM) i7 CPU-n mértük, MATLAB R2010b környezetben.

Az ACWE [7] (active contour without edges) nemparametrikus módszer, mely a „level-set” reprezentációt követi, így a gradiens alapú élkép helyett intenzitás homogenitási kényszerek irányítják. Míg a módszer sikeresen megtalálja a nagy görbületű kontúrrészeket (lásd **A** kép, 5. ábra első sora), addig az objektum belsejében levő intenzitásváltozásokat és nyitott kontúrokat nem képes kezelni.



5. ábra: Példák a kontúrdetekcióra: Az első oszlop a kiszámolt kezdőkontúr. A második, harmadik, negyedik, ötödik és hatodik oszlopok az ACWE [7], GVF [28], HGVF (javasolt), VFC [19] és HVFC (javasolt) módszerek által elért eredményeket mutatják.

Ilyen esetekben a háttértől élesen eltérő, nagyobb homogén régiókhöz konvergál (5. ábra **B**, **C**, **D** képei).

Ahogy már a korábbiakban is kifejtettük (lásd 2.1. fejezet), a GVF-nek nemcsak a nagy görbületű és kontúrszegény élek detekciója jelent gondot, de a távol kijelölt kezdőkontúr is. Ha a keresendő objektum körvonala nagy konkáv részeket tartalmaz, a kijelölt kezdővonal a konvex burok számítás miatt távol eshet a valódi kontúrtól, így a módszer hajlamos lokális energiaminimumba ragadni. Az általunk javasolt HGVF eljárás javítja az eredeti módszer teljesítményét azzal, hogy képes jobban kiemelni a kontrasztszegény és nagy görbületű kontúrokat, így az **A** képen látható levél csúcsait és szárát, illetve a **D** képen levő repülőgépet

1. táblázat: A különböző aktív kontúr algoritmusok futtatási ideje az 5. ábra **A** – **D** képeire. KK oszlop a kezdőkontúr kiszámításához szükséges időt jelöli.

Kép (méret)	Futási idő [másodperc]					
	KK	ACWE	GVF	HGVF	VFC	HVFC
A (200 × 216)	0.36	13	5.8	5.6	3.7	4.8
B (300 × 200)	0.44	66	6.2	6.7	4.2	5.1
C (335 × 364)	0.85	68	9.4	11	6.3	6.9
D (300 × 170)	0.38	12	3.9	4.3	3.2	3.7

2. táblázat: Zajjal szembeni robusztusság vizsgálata az 5. ábra **D**, **E** és **F** képeire növekvő Gaussi zaj esetén. A táblázat az egyes képek esetén a zaj mértékét (SNR) és a kapott F-mértéket (19. képlet) tartalmazza.

SNR	F-mérték				
	ACWE	GVF	HGVF	VFC	HVFC
∞ (D kép)	0.66	0.64	0.89	0.79	0.93
5 dB (E kép)	0.58	0.53	0.88	0.78	0.87
0.5 dB (F kép)	0.60	0.52	0.86	0.74	0.87

körvonalát is nagyobb pontossággal detektálja. A javulás ellenére, ha a kontúr nagyobb konkavításokat tartalmaz (**B** és **C** képek), a HGVF nem képes a kontúrhoz konvergálni.

A VFC eljárás előnye, hogy a GVF-nél kevésbé érzékeny a kontúr inicializálásra, a kiszámított vektormező kernel miatt. Így az algoritmus képes az inicializálástól messzebb eső körvonalakhoz konvergálni (mint **B** kép esetén), de a nagy görbületek és alacsony kontrasztú élek problémája a gradiensképen alapuló jellemzőterkép hátrányai miatt itt is megjelenik (2.2. fejezet).

A javasolt HVFC módszer egyesíti magában a VFC előnyös konvergáló képességét és a továbbfejlesztett, Harris függvény alapú jellemzőterkép pozitív tulajdonságait, így képes a korábbi módszereknél pontosabban detektálni az objektumok komplex határait is.



6. ábra: Több objektum szétválasztása. A képeken a szétválasztott pontok alapján lokalizált (téglalappal körbevett) objektumok láthatók.

Az 5. ábra **E** és **F** különböző jel-zaj viszonyú (signal-to-noise ratio, SNR) képein a javasolt módszerek robusztusságát teszteltük. A kvantitatív kiértékeléshez a **D**, **E** és **F** képeket hasonlítottuk össze, ugyanazon paraméter beállítások mellett. **D** az eredeti, zaj nélküli kép, **E** képen 5 dB az SNR, **F** képen 0.5 dB az SNR. Ahogy 5. ábrán látható a javasolt módszerek teljesítménye a zaj ellenére nem romlik látványosan, az alakzatok körvonalát képesek nagyjából megtartani, az elért F-mértékek a 2. táblázatban láthatók.

4.3.. Kvalitatív kiértékelés több objektum esetén

A kiértékelés utolsó részében a 3.4. fejezetben ismertetett, több objektumot kezelő algoritmust teszteltük. Ebben a részben nem a körvonal megkeresésére irányult a hangsúlyt, hanem arra, hogy a bemutatott módszer képes-e a különböző objektumokhoz tartozó ponthalmazokat szétválasztani és ez alapján az objektumokat helyesen lokalizálni [18]. Tesztünkhöz repülő objektumcsoportokat ábrázoló képeket választottunk, mivel itt teljesült, hogy az objektumok gyakran tartalmaznak kontrasztgyenge, nagy görbületű körvonalakat, illetve a háttérben megjelenő felhők, kerozincsíkok szintén nehezítik a helyes lokalizálást. Ezért a tradicionális pontdetektorok sokszor nem képesek hatékonyan kiemelni ezeket az alakzatokat. Ahogy a 6. ábrán is látszik, az általunk javasolt ponthalmaz hatékonyan reprezentálja az objektumokat illetve a több objektumra bemutatott szeparáló algoritmus képes jól szétválasztani és lokalizálni a különböző objektumokat.

5.. Konklúzió

Ebben a cikkben egy új típusú tulajdonságtérképet mutattunk be, mely hatékonyan alkalmazható parametrikus aktív kontúrok eljárások (GVF és VFC) külső energiatagjában. A javasolt jellemzőtérkép a Harris sarokdetektor karakterisztikus függvényének módosításán alapul, mely képes a sarok- és élregiók egyidejű, egyenletes kiemelésére. Így az aktív kontúr módszerek külső energiatagjában alkalmazva, lehetővé válik a nagy görbületű illetve kontrasztszegény körvonalak pontosabb detektálása. A jellemzőtérkép kiemelkedő pontjai automatikusan meghatározzák a kezdeti kontúr, amiből az iteratív eljárás kiindul, ily módon növelve a robusztusságot.

Jövőbeli célunk az algoritmus 3 dimenziós kiterjesztése. Mivel magának a Harris sarokdetektornak is igen új a 3D-s reprezentációja [23], így a kiterjesztés további részletes kutatást és kiértékelést igényel.

Köszönetnyilvánítás

A szerzők köszönetet mondanak az összehasonlításhoz használt algoritmusok nyílt hozzáférésű MATLAB kódjaiért. A munkát az OTKA 76159-es azonosítójú pályázata támogatta.

Hivatkozások

1. Alpert, S., Galun, M., Basri, R., and Brandt, A. (2007). Image segmentation by probabilistic bottom-up aggregation and cue integration. In *Proc. of IEEE Conf. on Computer Vision and Pattern Recognition*, pages 1–8.
2. Barber, C. B., Dobkin, D. P., and Huhdanpaa, H. (1996). The quickhull algorithm for convex hulls. *ACM Trans. Math. Softw.*, 22(4):469–483.
3. Bresson, X., Esedoglu, S., Vandergheynst, P., Thiran, J.-P., and Osher, S. (2007). Fast global minimization of the active contour/snake model. *J. of Mathematical Imaging and Vision*, 28(2):151–167.
4. Brigger, P., Hoeg, J., and Unser, M. (1997). B-spline snakes: A flexible tool for parametric contour detection. *Internat. J. Comput. Vision*, 22(1):61–79.
5. Canny, J., (1986). A computational approach to edge detection. *IEEE Trans. Pattern Anal. Machine Intell.*, 8(6):679–698.
6. Caselles, V., Kimmel, R., and Sapiro, G. (1997). Geodesic active contours. *Internat. J. Comput. Vision*, 22(1):61–79.
7. Chan, T. F. and Vese, L. A. (2001). Active contours without edges. *IEEE Trans. Image Process.*, 10(2):266–277.
8. Cheng, J. and Foo, S. (2006). Dynamic directional gradient vector flow for snakes. *IEEE Trans. Image Process.*, 15(6):1563–1571.
9. Chuang, C. and Lie, W. (2004). A downstream algorithm based on extended gradient vector flow field for object segmentation. *IEEE Trans. Image Process.*, 13(10):1379–1392.
10. Harris, C. and Stephens, M. (1988). A combined corner and edge detector. In *Proc. of 4th Alvey Vision Conf.*, pages 147–151.
11. Jifeng, N., Chengke, W., Shigang, L., and Shuqin, Y. (2007). NGVF: An improved external force field for active contour model. *Pattern Recognition Lett.*, 28(1):58–63.
12. Kass, M., Witkin, A. P., and Terzopoulos, D. (1988). Snakes: Active contour models. *Internat. J. Comput. Vision*, 1(4):321–331.
13. Kimmel, R. and Bruckstein, A. M. (2003). Regularized laplacian zero crossings as optimal edge integrators. *Internat. J. Comput. Vision*, 53(3):225–243.
14. Kovacs, A. and Sziranyi, T. (2010). High definition feature map for GVF snake by using Harris function. In *Proc. of Conf. on Advanced Concepts for Intelligent Vision Systems*.
15. Kovacs, A. and Sziranyi, T. (2011). Improved force field for vector field convolution method. In *Proc. of IEEE International Conf. on Image Processing*.

16. Kovacs, A. and Sziranyi, T. (2012). Harris function based active contour external force for image segmentation. In *Pattern Recognition Lett.*, 33:1180–1187.
17. Kovacs, L. and Sziranyi, T. (2007). Focus area extraction by blind deconvolution for defining regions of interest. *IEEE Trans. Pattern Anal. Machine Intell.*, 29(6):1080–1085.
18. Kovacs, L., Kovacs, A., Utasi, Á. and Szirányi, T. (2012). Flying target detection and recognition by feature fusion. *Optical Engineering*, 51(11):117002-1–13.
19. Li, B. and Acton, T. (2007). Active contour external force using vector field convolution for image segmentation. *IEEE Trans. Image Process.*, 16(8):2096–2106.
20. Mishra, A. K., Fieguth, P. W., and Clausi, D. A. (2011). Decoupled active contour (DAC) for boundary detection. *IEEE Trans. Pattern Anal. Machine Intell.*, 33(2).
21. Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Trans. Syst., Man, Cybern.*, 9(1):62–66.
22. Schmid, C., Mohr, R., and Bauckhage, C. (2000). Evaluation of interest point detectors. *Internat. J. Comput. Vision*, 37(2):151–172.
23. Sipiran, I. and Bustos, B. (2011). Harris 3D: A robust extension of the Harris operator for interest point detection on 3D meshes. *The Visual Computer*, 27(11):963–976.
24. Sirakov, Nikolay M. (2006). A new active convex hull model for image regions. *J. Math. Imaging Vis.*, 26(3):309–325.
25. Sundaramoorthi, G. and Yezzi, A. (2007). Global regularizing flows with topology preservation for active contours and polygons. *IEEE Trans. Image Process.*, 16(3):803–812.
26. Vasilevskiy, A. and Siddiqi, K. (2002). Flux maximizing geometric flows. *IEEE Trans. Pattern Anal. Machine Intell.*, 24(12):1565–1578.
27. Wang, Y., Liu, L., Zhang, H., Cao, Z., and Lu, S. (2010). Image segmentation using active contours with normally biased GVF external force. *Signal Processing Lett.*, 17(10):875–878.
28. Xu, C. and Prince, J. L. (1997). Gradient vector flow: A new external force for snakes. In *Proc. of IEEE Conf. on Computer Vision and Pattern Recognition*, pages 66–71.
29. Zamani, Fatemeh and Safabakhsh, Reza. (2006). An unsupervised GVF snake approach for white blood cell segmentation based on nucleus. In *Proc. of The 8th International Conference on Signal Processing*.
30. Zhu, G., Zhang, S., Zeng, Q., and Wang, C. (2010). Gradient vector flow active contours with prior directional information. *Pattern Recognition Lett.*, 31:845–856.