

Mozgó célpontok vizsgálata radar képsorozatokon jelölt pontfolyamat modellel*

Benedek Csaba¹, Martorella Marco²

¹ Elosztott Események Elemzése Kutatólaboratórium, MTA SZTAKI

1111, Budapest, Kende utca 13-17 benedek.csaba@sztaki.mta.hu

² Dept. of Information Engineering, University of Pisa & CNIT RASS Laboratory

I-56122 Pisa, Via Caruso 16, Olaszország m.martorella@iet.unipi.it

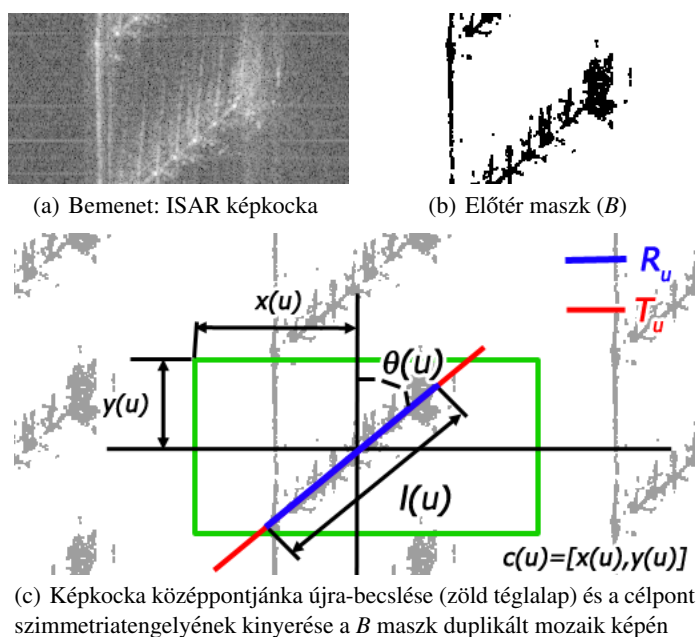
Absztrakt. Cikkünkben bemutatunk egy újszerű, idősorozatok elemzésére alkalmas *jelölt pontfolyamat* modellt hajó és repülőgép célpontok automatikus analíziséhez Inverz Szintetikus Apertúra Radar (ISAR) képsorozatokon. A zajos radarképeken megfigyelhető célpontokat egyszerűsített struktúrával, szakaszok és pontcsoportok halmazával írjuk ki. Eljárásunk kimenetét iteratív sztochasztikus optimalizáció szolgáltatja, amely egy időben felhasználja a mért radar-képek jellemzőit és a célpont egymás utáni képkockákon történő megjelenései között felírható prior geometriai kényszereket. A módszert valódi ISAR képsorozatokon teszteljük.

1. Bevezetés

Hajó és repülőgép célpontok felismerése és mozgásuk elemzése Inverz Szintetikus Apertúra Radar (ISAR) képsorozatokon központi feladat ISAR alapú Automatikus Célpontkövető (ACK) Rendszerekben [4–6]. A távérzékes útján készített ISAR képek gyakran értékes információkkal szolgálnak különböző célpontok osztályozásához különösen nehéz megfigyelési körülmények (például időjárási viszonyok) között is, amikor a hagyományos optikai vagy SAR képalkotási technikák alkalmazhatatlanok [7]. Azonban a felismeréshez használható képi jellemzők robosztus kinyerése és a leíróik időbeli követése nagy kihívást jelent a képek magas zajszintje és alacsony felbontása miatt, így általában a célpontokról is csupán kis részletezettségű felvétel áll rendelkezésünkre (1. ábra). Külön problémát jelent, hogy az ISAR képszintézis folyamatának fizikai tulajdonságai miatt a képsorozat szomszédos kockái is jelentősen különböző zajszintbeli és fókuszáltsági paraméterekkel rendelkezhetnek. Ezek a problémák jelentős detekciós hibákhoz vezethetnek a rossz minőségű képkockákon, félrevezetve az ACK rendszerek osztályozó és eseményfelismerő moduljait. Ha feltételezzük, hogy a célpont merev, tehát fix mérettel és struktúrával rendelkezik, valamint a képfolyam időbeli felbontása megfelelő ahhoz hogy kis elmozdulást várhassunk el az időben szomszédos képek között, akkor felhasználhatunk közeli időpillanatok közötti információt is a detekció finomítására.

* A bemutatott módszer eredetileg az IET International Conference on Radar Systems 2012 nemzetközi konferencián, angol nyelven került közzésre [3]

Cikkünkben egy újszerű, idősorozatok elemzésére alkalmas *jelölt pontfolyamat* modellt [2, 3] ismertetünk a célpontkövetés problémájára, ami ISAR képekről kinyerhető különböző jellemzőket kombinál a célpont struktúrájának állandóságát és sima mozgáspályát biztosító prior kényszerek figyelembevételével. Korábbi módszerünkhöz hasonlóan [2], a célpont szimmetria tengelyét és karakterisztikus pontjait nyerjük ki a képekről, azonban fontos újdonság, hogy új adatfüggő és prior jellemzőket használunk az eljárás során, valamint a tengelyillesztés a jellemezőkinyerés lépéseket egymásba ágyazottan optimalizáljuk, kihasználva a különböző struktúraelemek erős kölcsönhatását.



1. ábra: Célpont tengelyének ábrázolása és parametrizációja

2. Problémadefiníció és jelölések

Eljárásunk bemenete 2D ISAR képek szekvenciája, melyek egy hajó vagy repülőgép célpontot tartalmaznak. Az 1(a) ábra egy minta képkockát jelenít meg szürkeárnyaltos képként. Fő célunk az objektum releváns jellemzőinek a mérése, ami kézenfekvő módon esetünkben a tengely hossza és orientációja: a célpont szeletojnját így egy szakasszal modellezzük (1(c) ábra). Bár az ISAR képek kevés információt szolgáltatnak a célpontok szerkezetéről, gyakran észlelhetünk stabil világos pontokat a képeken (*sarokpontok*), melyeket a képsorozat kockáin végigkövethetünk (2(a) ábra). Ezeket a karakterisztikus jellemző pontokat domináns struktúraelemek (például konténerek, kabinok) hozzák létre,

tehát pontos észlelésük és követésük esetén hasznos információt szolgáltatnak a célpont azonosítására.

Jelöljük S -sel az n kockát tartalmazó ISAR szekvencia képeinek pixelrácát, és $s \in S$ -sel egy tetszőleges pixelt. u_t -vel jelölünk egy célpont-jelöltet a t -edik képkockán, $t \in \{1, 2, \dots, n\}$. A célpont tengely szegmensét négy paraméterrel írjuk le: $x(u)$ és $y(u)$ középpont-koordináták, $l(u)$ hossz és $\theta(u)$ orientáció (1(c) ábra). Mindezen túl, $K(u) (\leq K_{\max})$ jellemző *sarokpontot* rendelhetünk egy célponthoz:

$$u \rightarrow (q_1, q_2, \dots, q_{K(u)}),$$

ahol egy adott q_i sarokpont leírását az u "szülő-objektum" tengelyszegmensének koordinárendszerében végezzük, kiszámítva a relatív tengely irányú komponens, $\tau_u(q_i)$ -t, és a tengelytől mért távolságot, $d_u(q_i)$ -t (2(c) ábra). Jelöljük H -val az objektumok terét. Célunk az optimális

$$\omega = \{u_1, u_2, \dots, u_n\} \in H^n$$

célpont szekvencia kinyerése, amit a továbbiakban konfigurációnak is fogunk nevezni.

3. Előfeldolgozás

Megoldásunk első lépése háttérkivonás elvégzése a bemenetként érkező ISAR képeken, ami egy bináris B_t előtérmaszkot eredményez a $t = 1, \dots, n$ indexű képkockákon. Mivel a képszintézis zaja számos hamis előtérpontot eredményezne, Markov Véletlen mezős modellt javasoltunk a szegmentáció elvégzésére, amit gráf vágás alapú technikával optimalizáltunk.

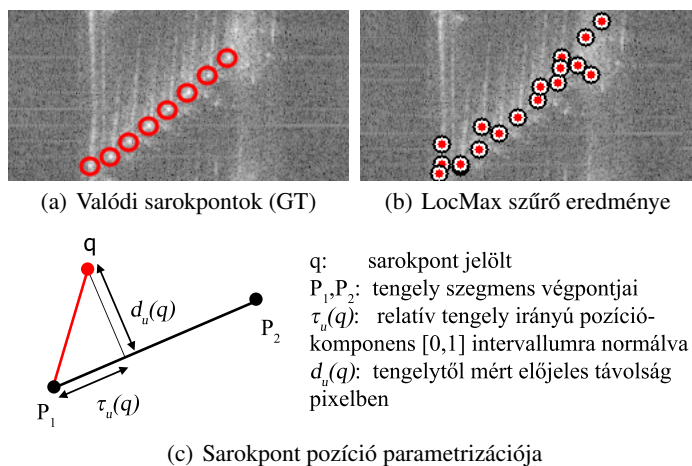
3.1. Kezdeti képkocka regisztráció és tengelyszegmens becslés

Ahhoz, hogy kezdeti becslésünk legyen a célpont tengelyszegmenséről, a tengely legvalószínűbb egyenesét határozzuk meg az előtérmaszk Hough transzformáltjának felhasználásával. Ezen a ponton figyelembe kell vennünk egy praktikus problémát, amit az ISAR képszintézis modul okozhat. A képformációs algoritmus az ISAR képeket térben periodikusnak tekinti mind a függőleges, mind a vízszintes irányban, majd becslést ad az objektum középpontjára, végül a periodikus képből a célpont közepe körüli ablakot vágja ki (helyes kivágás eredménye 2(a) ábrán látható). Ha viszont a célpont középpontját hibásan határozza meg a tőlünk független képformációs lépés, a célpont tengelye "széttörhet" két (vagy négy) részre, amit az 1(a) ábra szemléltet. Megoldásunkban ezért a legnagyobb összefüggő előtér szegmensét az előtérmaszkból képzett duplikált mozaik képen keressük, ami egyben új becslést ad a célpont objektum, és egyben az ISAR képkocka középpontjára (1(c) ábra).

3.2. Sarokpont-jelölt halmaz meghatározása és szűrése

A stabil sarokpontokat nagy amplitúdójú pixelek azonosítják, ugyanakkor a kép zaja, egyes részek defókuszáltsága és a visszaverődések villódzása miatt az amplitúdók jelentősen eltérő értékeket mutathatnak az egymást követő képkockákon, valamint jelentős különbségekre kell számítanunk egy kép különböző sarokpontjait összevetve is.

Ezért globális küszöböléssel nem tudjuk valamennyi sarokpontot elkülöníteni pusztán az amplitúdók összehasonlításával. Megoldásunkban először számos sarokpont jelöltet állítunk, és a következő lépésben a célpont alakzat időbeli állandóságát és szakasz jellegű struktúráját használjuk fel a valódi sarokpontok és a hamis jelöltek megkülönböztetésére. A kezdeti sarokpont jelölteket Lokális Maximum (LocMax) szűrővel nyerjük ki. Ahogy a 2(b) ábra mutatja, ez a szűrő hatékonyan azonosítja a sarokpontokat, de számos hamis riasztást is szolgáltat.



2. ábra: Sarokpont detekciós probléma (a) valódi sarokpontok kiemelése, (Ground Truth, GT), (b) LocMax szűrő eredménye, (c) parametrizáció

A kezdeti sarokpont szűrő két megfigyelést vesz figyelembe:

- Egy célpont jelölt esetén feltételezzük, hogy a sarokpontok közel helyezkednek el a szimmetria tengelyhez.
- Ha két különböző sarokpontot vetítünk a tengelyre, a vetületek nem lehetnek “túl közel” egymáshoz, mivel ez utóbbi jelenség visszhanghatás eredményeként lép fel

A fenti feltevéseket használva, kiválasztunk egy szűrt sarokpont-jelölt halmazt, amit a 3(a) ábra szemléltet. Ezen a ponton az eredmény minősége még meglehetősen gyenge a 2(a) ábrán bemutatott referencia-eredményhez képest: a szűrő nem a megfelelő sarokpont halmazt választotta ki a 2(b) ábra kezdeti jelölthalmazából. A hiba fő forrása a tengely pontatlan kezdeti becslése, ami miatt hamis sarokpont jelöltek illeszkednek a szimmetriavonalra. A probléma kiküszöbölésére olyan megoldást javasoltunk, ami párhuzamosan használ fel jellemzőket a sziluett maszkról és a LocMax szűrő kimene-téből. Amennyiben ugyanis találunk egy olyan részhalmazt a sarokpontjelöltek között, amik szorosan illeszkednek egy l egyenesre, jelentős valószínűséggel mondhatjuk hogy l a célpont tengelye. A tengely újra-becslését tehát a sarokpont jelöltek alapján végezzük

el a RANSAC algoritmus felhasználásával. Miután rendelkezésünkre áll a finomított tengely, ismét elindítjuk a sarokpont szűrő folyamatot, melynek eredménye a 3(b) ábrán látható. Jelentős teljesítmény javulást figyelhetünk meg az első és harmadik képkockán; ugyanakkor továbbra is láthatunk egy hamis találatot (első kocka), a második képkockán pedig továbbra is teljesen hibás a detekció, amit további kényszerek figyelembevételével, időbeli jellemezőket felhasználva lehet csak kiküszöbölni.

4. Idősorozati jelölt pontfolyamat modell

Megoldásunk bayesi megközelítést alkalmaz. Először definiálunk egy adatfüggő Gibbs eloszlást a konfigurációs téren a következőképpen:

$$P_D(\omega) = \frac{1}{\zeta} \cdot \exp(-\Phi_D(\omega)),$$

ahol ζ normalizáló konstans és $\Phi_D(\omega)$ a konfigurációs energia:

$$\Phi_D(\omega) = \sum_{t=1}^n A_D(u_t) + \gamma \cdot \sum_{t=1}^n I(u_t, \omega_t)$$

A fenti formulában $A_D(u_t) \in [-1, 1]$ adatfüggő szingleton potenciál és $I(u_t, \omega_t) \in [0, 1]$ -t interakciós potenciálnak nevezzük, ahol

$$\omega_t = \{u_{t-Z}, \dots, u_t, \dots, u_{t+Z}\}$$

az u_t objektum megjelenés közvetlen időbeli szomszédjaiból álló részsorozat. A γ paraméter pozitív súlytényező a két potenciáltag között. Célunk a legvalószínűbb, Maximum Likelihood (ML) konfiguráció becslése, amit $\Phi_D(\omega)$ minimalizálásával érhetünk el.

4.1. Szingleton potenciálok definíciója

Az $A_D(u_t)$ szingleton potenciál a t -edik képkockán megjelenő objektum jelöltet jellemzi a lokális ISAR képi adat alapján, de függetlenül a többi képkocka tartalmától. A szingleton potenciál két részből áll:

$$A_D(u_t) = \frac{1}{2} (A_D^B(u_t) + A_D^{Sc}(u_t))$$

ahol $A_D^B(u_t)$ a(z objektum)törzs adattag és a $A_D^{Sc}(u_t)$ sarokpont illeszkedési adattag.

A törzs adattag kiszámításához, először jelöljük $L_u \subset S$ -sel az u objektum szimmetriatengelye által fedett pixelhalmazt a duplikált maszk képen. Jelöljük $R_u \subset L_u$ -val az u tengelyszegmense alatt lévő pixeleket (1(c) ábra):

$$R_u = \{s \in L_u \mid d(s, [x(u), y(u)]) < l(u)/2\},$$

és $T_u \subset L_u \setminus R_u$ -val az L_u halmaz olyan pixeleit, amik a tengelyszegmensén kívül esnek, de közel annak végpontjaihoz. A törzs illeszkedést leíró jellemző, $f_D(u)$ olyan

objektum jelölteket jutalmaz, ahol a tengely szegmens alatt (R_u) nagy többségben előtér pixeleket találunk az aktuális képkocka B maszkján, míg a T_u külső terület háttér régiókat takar.

$$f_D(u) = \frac{1}{\text{Ter}\{R_u \cup T_u\}} \cdot \left(\sum_{s \in R_u} B(s) + \sum_{s \in T_u} 1 - B(s) \right)$$

ahol $\text{Ter}\{\cdot\}$ területet jelöl, pixeleken mérve. Ezután a szingleton potenciál törzs adattag részét az alábbi módon származtatjuk:

$$A_D^B(u) = Q(f_D(u, B), d_0),$$

a következő, monoton csökkenő $Q(f, d_0)$ függvényt felhasználva:

$$Q(f, d_0) = \begin{cases} \left(1 - \frac{f}{d_0}\right) & \text{if } f < d_0 \\ \exp(-0.1 \cdot f - d_0) - 1 & \text{if } f \geq d_0 \end{cases}$$

d_0 modellparaméter, amit az érvényes objektumok elfogadási küszöbeként használunk a $f_D(u, B)$ jellemzőtérben.

A sarokpont adattag olyan sarokpontokat büntet, melyek az ISAR képen nem lokális maximumban helyezkednek el:

$$A_D^{\text{Sc}}(u) = Q\left(\frac{1}{K(u)} \cdot \sum_{i=1}^{K(u)} \Psi(i, u), d_\Psi\right), \text{ ahol}$$

$$\Psi(i, u) = \begin{cases} 0 & \text{if } q_i \text{ a kép lokális maximumában található} \\ 1 & \text{egyébként} \end{cases}$$

A d_0 és d_Ψ paramétereket tanítóminták alapján állítjuk be [1].

4.2. Az interakciós potenciálok definíciója

Az interakciós potenciálok időbeli információt és geometriai feltevéseket reprezentálnak a modellben. Mivel a megfigyelt objektumok struktúrája statikusnak tekinthető, erős korreláció figyelhető meg a célpont egymás utáni képkockáin mért paraméterei között. Tekintve, hogy az ISAR képalkotási technika tulajdonságai miatt a $c(u)$ középponti koordináta nem hordoz megbízható helyzet-információt, csak a $\theta(u)$ orientáció és $l(u)$ tengelyhossz paraméterek közötti nagy különbségeket büntetjük, valamint a sarokpontok számának és a célpont koordináta-rendszerében mért sarokpont pozícióvektor jelentős eltéréseit.

A prior interakciós potenciál négy adattag súlyozott összegzésével számítható: $I_l(u_t, \omega_t)$ median hosszkülönbség, $I_\theta(u_t, \omega_t)$ median orientáció különbség, $I_{\#s}(u_t, \omega_t)$ median sarokpont szám különbség és $I_{sd}(u_t, \omega_t)$ sarokpont elhelyezkedés különbség.

$$I(u_t, \omega_t) = \delta_l \cdot I_l(u_t, \omega_t) + \delta_\theta \cdot I_\theta(u_t, \omega_t) + \delta_{\#s} \cdot I_{\#s}(u_t, \omega_t) + \delta_{sd} \cdot I_{sd}(u_t, \omega_t)$$

$\delta_l, \delta_\theta, \delta_{\#s}, \delta_{sd}$ tagok pozitívak és $\delta_l + \delta_\theta + \delta_{\#s} + \delta_{sd} = 1$.

Az első három adattagot az aktuális és a hozzá közeli képkockákon mért paraméterkülönbségek median értékeként számoljuk:

$$\begin{aligned} I_l(u_t, \omega_t) &= \min(\text{med}_l(t)/l_{\max}, 1) \\ I_\theta(u_t, \omega_t) &= \min(\text{med}_\theta(t)/\theta_{\max}, 1) \\ I_{\#u}(u_t, \omega_t) &= \min(\text{med}_K(t)/K_{\max}, 1) \end{aligned}$$

ahol a különböző $f \in \{l, \theta, K\}$ célpont paraméterekre:

$$\text{med}_f(t) = \underset{t-Z \geq i \geq t+Z}{\text{median}} |f(u_t) - f(u_i)| \quad (1)$$

míg l_{\max}, θ_{\max} és K_{\max} normalizáló konstansok. Megjegyezzük, hogy az alkalmazott median szűrés robosztusabbnak bizonyult, mint az értékek átlagolása, mivel számolnunk kell kiugró (outlier) detekciókkal, melyek teljesen hibás objektum találatokat eredményeznek egyes képkockákon.

A sarokpont elrendeződés különbségét leíró jellemző, $I_{sd}(u_t, \omega_t)$, a sarokpontok relatív pozícióinak különbségét értékeli ki a közeli képkockákon. A célpont sarokpont vektorát az alábbi módon definiáljuk:

$$\bar{\tau}(u) = (\tau_u(q_1), \tau_u(q_2), \dots, \tau_u(q_{K(u)}))$$

ahol, mint azt korábban a 2. fejezetben bemutattuk, $\tau_u(q)$ a q sarokpont pozíció tengely irányú komponense az u szülő objektumra vetítve.

Tekintsük az u és v célpontokat két különböző képkockán, melyek különböző számú sarokpontot tartalmazhatnak. A $\bar{\tau}(u)$ és $\bar{\tau}(v)$ vektorok különbségét a következőképpen értelmezzük:

$$\begin{aligned} \Theta(\bar{\tau}(u), \bar{\tau}(v)) &= \frac{1}{2} \left(\frac{1}{K(u)} \sum_{i=1}^{K(u)} \min_{j \leq K(v)} |\tau_u(q_i) - \tau_v(q_j)| + \right. \\ &\quad \left. \frac{1}{K(v)} \sum_{j=1}^{K(v)} \min_{i \leq K(u)} |\tau_u(q_i) - \tau_v(q_j)| \right) \end{aligned}$$

Ezután, (1) formulát alkalmazva, a sarokpont elrendeződést leíró tagot kiszámítjuk:

$$\begin{aligned} I_{sd}(u_t, \omega_t) &= \min(\text{med}_{sd}(t)/d_{\max}^{sd}, 1) \text{ ahol} \\ \text{med}_{sd}(t) &= \underset{t-Z \geq i \geq t+Z}{\text{median}} \Theta(\bar{\tau}(u_t), \bar{\tau}(u_i)) \end{aligned}$$

A hatékony számítás kedvéért a $\Theta(\bar{\tau}(u_t), \bar{\tau}(u_i))$ jellemzőt az 1D távolság transzformáció (distance transform) térkép meghatározásával közelítjük az $[0, 1]$ intervallum diszkrétizációját követően.

5. Optimalizáció

A legjobb konfiguráció (objektum szekvencia) közelítéséhez iteratív optimalizációs algoritmust dolgoztunk ki ami az előző fejezetben bemutatott $\Phi_D(\omega)$ konfigurációs energia minimalizálására törekszik. Az algoritmus főbb lépései az alábbiak:

1. Hajtsuk végre az Előzetes detekció és RANSAC alapú újrabecslés lépéseket, a 3. fejezetben részletezett módon, inicializáljuk a konfigurációt a kapott célpont szekvenciával (3(b) ábra): $\omega^{[0]} = \{u_1^{[0]}, u_2^{[0]}, \dots, u_n^{[0]}\}$, állítsuk be az iteráció szám-
lálót $k = 0$, inverz hőmérsékletet $\beta = \beta_0$, finomsági paramétert $\epsilon = \epsilon_0$ és egy
logikai változót $STOP:=false$
2. Iteráljuk a következő lépéseket, amíg $STOP=false$

Valamennyi $t = 1, \dots, n$ képkockára:

- $u := GENERÁLJUNK_RANDOM.OBJEKTUMOT(t)$
- Tekintsük a ω^* konfigurációt, amit úgy kapnánk, ha $\omega^{[k]}$ -ban kicserélnénk $u_t^{[k]}$ -
t u -ra.
- Számítsuk ki az $\omega^{[k]}$ és ω^* konfigurációk energia különbségét:

$$\Delta\Phi_\omega(u, t) = \Phi_D(\omega^*) - \Phi_D(\omega^{[k]})$$

- Származtassunk egy $d_\omega(u)$ kicserélési valószínűséget:

$$d_\omega(u) = \frac{\delta a_\omega(u)}{1 + \delta a_\omega(u)} \text{ ahol } a_\omega(u) = e^{-\beta \cdot \Delta\Phi_\omega(u)}$$

és állítsuk be

$$u_t^{[k+1]} = \begin{cases} u & d_\omega(u) \text{ valószínűséggel} \\ u_t^{[k]} & \text{egyébként} \end{cases}$$

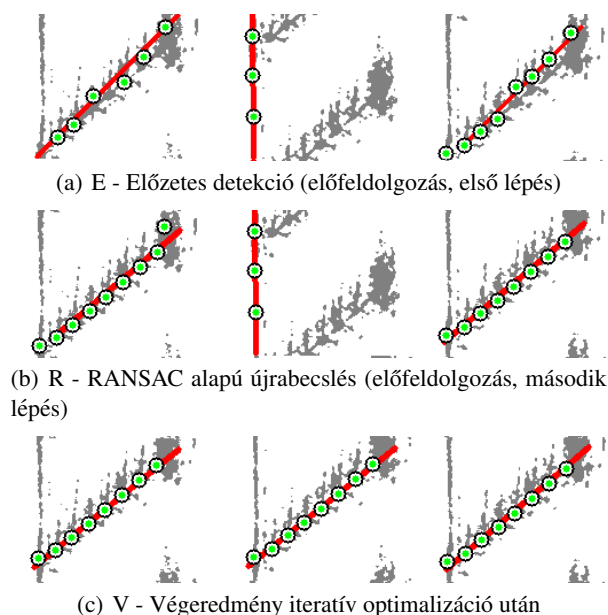
3. $k := k + 1$, növeljük β -t és csökkentjük δ -t geometriai sémával.
4. Ha a folyamat konvergált: $STOP:=true$. GOTO 2. lépés

Lépés →	Normalizált tengely paraméter hiba			Sarokpont detekció (F mérték %)			Átlagos sarokpont poz. hiba pixelben		
	E	R	V	E	R	V	E	R	V
SEQ1	0.32	0.28	0.05	44	83	98	13.1	3.4	0.2
SEQ2	0.11	0.08	0.02	88	94	99	1.3	0.9	0.5
SEQ3	0.09	0.11	0.06	88	84	94	3.1	4.2	1.5
SEQ4	0.08	0.06	0.04	93	93	96	2.8	2.5	2.1
SEQ5	0.21	0.16	0.09	93	94	96	0.7	0.6	0.4

1. táblázat: Kvantitatív eredmények az öt tesztszekvenciára. E/R/V kezdőbetűk munkafolyamat három lépését jelölik (Előzetes, RANSAC and Végző, optimalizált), hasonlóan a 3 ábrához

6. Kiértékelés


Módszerünket hat ISAR képszekvencián teszteltük, melyek különböző hajó (5) és repülőgép (1) célpontokat tartalmaznak. A hajókról készült tesztadat összesen 123 kiértékelt képkockát foglal magában (18-30 kocka szekvenciánként), és 1014 valódi sarokpontot (8 vagy 9




3. ábra: Kimeneti eredmények a SEQ1 adathalmaz három képkockáján, a munkafolyamat egyes lépéseit követve. 8 valódi sarokpont helyes detekciója látható.

sarokpont képkockánként). Kvantitatív kiértékelés céljából manuálisan generáltunk referenciaadatot (Ground Truth, GT) mind a tengelyszegmensekhez, mind a sarokpont kandidánsokhoz valamennyi tesztsorozat valamennyi képkockáján. Háromféle hibamértéket definiáltunk. A *Normalizált tengely paraméter hibát* úgy határozzuk meg, hogy összeadjuk a középpont és a tengelyhossz hibáit normalizálva a GT célpont hosszával, valamint az orientációs hibát 90° -kal normalizálva. A *Sarokpont detekciós mérték* kiszámításhoz megszámoljuk a helyes pozitív, hamis negatív, és hamis pozitív sarokpontokat (megfelelő illeszkedéshez a detektált és GT sarokpont távolsága egy adott küszöb alatti kell, hogy legyen). Ezt követően, megadjuk a detekció F-mértékét, ami a precizitás (precision) és a visszahívási ráta (recall rate) harmonikus közepe százalékban megadva. A harmadik jellemző az *Átlagos sarokpont pozíciós hiba*, amit pixelben mérünk. Az 1. táblázat bemutatja a kiértékelési számokat a munkafolyamat három szakaszát követően E/R/V (hasonlóan a 3. ábrán látottakhoz). Megfigyelhetjük, hogy a bemutatott módszer hatékonyan kezeli mind az öt tesztszekvenciát (SEQ1-SEQ5). A kezdeti detekcióhoz képesti javulás különösen a SEQ1 szekvencián jelentős (3. ábrán is bemutatott sorozat), ami nehéz tesztesetet tartalmaz. A javulás szintén figyelemre méltó SEQ2-3 sorozatokon, míg SEQ4-5 könnyebb szekvenciák, ahol a kezdeti detekció is hatékony, a javulás így kisebb.


Módszerünk hajókon kívül más típusú célpontok elemzésére is alkalmas. Kipróbáltuk a modell hatékonyságát repülőgép célpont analízisére (AIRPLN tesztsorozat), itt azonban a szakasz modell (mint szimmetria szegmens) helyett kereszt alakú struktúra írja




4. ábra: Repülőgép sziluett az ISAR kép alapján, és az illesztett kereszt alakú modell



(a) Bemeneti szekvencia



(b) Előzetes detekció



(c) Végeredmény

5. ábra: A modell eredménye repülőgép célpont megfigyelése esetén: az *előzetes detekciós* lépés és az optimalizáció eredményeként kapott *végeredmény* összehasonlítása az AIRPLN teszt-szekvencia 4 képkockáján

le hatékonyan az objektum szkeletonját, mivel a szárnyak is láthatók az ISAR képeken (4. ábra). Ennek megfelelően az adatfüggő szingleton tagokat ($A_D(u_t)$) is ki kellett terjeszteni, fedési tényezőket előírva a szárny szegmensek és a sziluettmaszk kapcsolatára is. Figyelembe véve azonban, hogy gyakran az egyik szárny takarásban van a radar előtt, a jobb és bal szárny fitness jellemzőit külön-külön határoztuk meg és a maximumukat vettük a szingleton energia számításánál. Eredmények 4 egymást követő képkockára az 5 ábrán láthatók, az előzetes detekció és az optimalizált végeredmény között hasonló minőségi javulás figyelhető meg, mint azt korábban a hajó sorozatoknál is láthattuk.

7. Összegzés

Cikkünkben hajó és repülő célpontokról készült ISAR képsorozatok automatikus analízisét végeztük el energiaminimalizációs módszert felhasználva. Robosztus modellt javasoltunk az objektumok szimmetriatengelyének és jellemző sarokpontjainak együttes kinyerésére és követésére. Kísérletekkel bemutattuk, hogy zajos képsorozatok esetén a bevezetett idősorozati jelölt pontfolyamat modell jelentősen javítja a képkockánkénti detekció eredményét.

Köszönetnyilvánítás

A kutatómunkát részben az Európai Védelmi Ügynökség (EDA) Array Passive ISAR Adaptive Processing (APIS) című projektje finanszírozta. Az első szerző munkáját az MTA Bolyai János Kutatási Ösztöndíja és az OTKA #101598 posztdoktori projekt is támogatta.

Irodalom

1. C. Benedek, X. Descombes, and J. Zerubia. Building development monitoring in multitemporal remotely sensed image pairs with stochastic birth-death dynamics. *IEEE Trans. Pattern Anal. Mach. Intell.*, 34(1):33–50, 2012.
2. C. Benedek and M. Martorella. ISAR image sequence based automatic target recognition by using a multi-frame marked point process model. In *IEEE Geoscience and Remote Sensing Symposium*, pages 3791–3794, Vancouver, Canada, 2011.
3. C. Benedek and M. Martorella. Ship structure extraction in ISAR image sequences by a Markovian approach. In *IET International Conference on Radar Systems*, Glasgow, UK, 2012.
4. T. Cooke. Ship 3D model estimation from an ISAR image sequence. In *Proc. IEEE International Radar Conference*, pages 36–41, Huntsville, Alabama, USA, 2003.
5. T. Cooke, M. Martorella, B. Haywood, and D. Gibbins. Use of 3D ship scatterer models from ISAR image sequences for target recognition. *Elsevier DSP*, 16:523–532, 2006.
6. D. Pastina and C. Spina. Multi-feature based automatic recognition of ship targets in ISAR. *IET Radar, Sonar Navigation*, 3(4):406–423, 2009.
7. V. Zeljkovic, Q. Li, R. Vincelette, C. Tameze, and F. Liu. Automatic algorithm for inverse synthetic aperture radar images recognition and classification. *IET Radar, Sonar Navigation*, 4(1):96–109, 2010.