

Hierarchikus jelölt pontfolyamat modell objektumpopulációk többszintű elemzéséhez *

Benedek Csaba

Elosztott Események Elemzése Kutatólaboratórium, MTA SZTAKI
1111, Budapest, Kende utca 13-17 benedek.csaba@sztaki.mta.hu

Absztrakt. Cikkünkben bemutatunk egy új valószínűségi eljárást összetett hierarchikus objektum struktúrák kinyerésére nagyfelbontású digitális képekről. A javasolt keretrendszer beágyazott *jelölt pontfolyamat* modellt valósít meg, ami két területen is kiterjeszti a hagyományos pontfolyamat módszereket: (i) objektum-részobjektum kapcsolatok modellezését teszi lehetővé (ii) statisztikai alapon modellezi az összetartozó objektumok csoportjait. A módszert három különböző alkalmazási területen demonstráljuk: beépített területek vizsgálata távérzékelte képeken, járműforgalom felügyelete légi Lidar adatokon és optikai áramkörelemzés.

1. Bevezetés

Napjainkban számos képalkotó eljárással nagy felbontású vizuális mérésekhez juthatunk, amiket különböző alkalmazásokban hasznosíthatunk a távérzékelés területétől a mikroszkópos fényképezésig. A létrejövő digitális képek több értelmezési szinten is tartalmazhatnak hasznos információt a megfigyelt helyszínről, lehetővé téve hogy egy adott mérési szeleten egyaránt vizsgáljuk makró szinten az entitások populációit, és az egyes önálló egységek apró részleteit.

A *jelölt pontfolyamat* modellek (Marked Point Process, MPP) [6, 8, 9] hatékony matematikai eszközök objektumpopulációk analízisére, azonban többnyire egyszintű helyszínelemzésre alkalmasak, hasonló geometriai megjelenésű alakzatok konfigurációinak modellezésén keresztül. Kézenfekvő MPP alkalmazási példák a szakirodalomban madarak [7], vagy épületek [3] számlálása légi fotókon. Egyszerű interakciós kölcsönhatások megjelenhetnek a modellek prior kényszerei között, például az objektumok közötti átlapolódások büntetése, vagy az alakzatok párhuzamos elrendeződésének előírása, ezen az úton azonban csak korlátozott mértékű magas szintű struktúrális információ vehető figyelembe a globális helyszínről.

A korábbi eljárások képek több szintű tartalmi elemzésére régió alapú [11], objektum alapú [4, 5] vagy hibrid [10] megközelítéseket követtek. Ugyanakkor a fenti modelleket specifikus alkalmazási környezetbe, és meghatározott bemeneti adatmodalitásokhoz tervezték, például távérzékelte optikai képek [10, 11] és Lidar pontfelhők [5] elemzéséhez, vagy nyomtatott áramkörök automatikus optikai vizsgálatára μm felbontású képeken [4]. A gyakorlati tapasztalatok ugyanakkor azt mutatják, hogy bonyolult és fáradságos ezeket az összetett, doménfüggő modelleket egy-egy másik alkalmazási

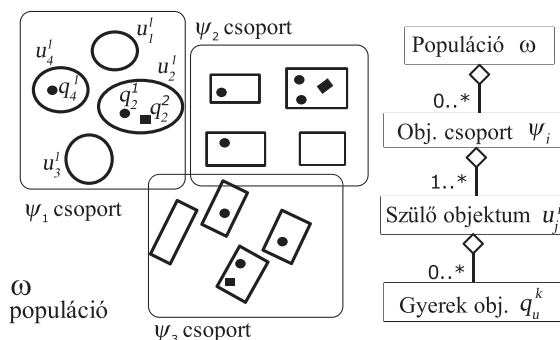
* A bemutatott módszer eredetileg az International Conference on Acoustics, Speech and Signal Processing 2014 nemzetközi konferencián, angol nyelven került közlésre [2]

környezethez igazítani, ami többnyire jelentős modellezői és implementációs munkát is igényel. Ezért cikkünkben egy korábbiaktól eltérő irányt követünk: bevezetünk egy általános háromrétegű MPP keretrendszert, amely konkrét alkalmazások széles körét képes kezelni. A modell strukturális elemeit és az energiaoptimalizációs algoritmust absztrakt szinten definiáljuk és implementáljuk, míg a különböző alkalmazások felé egyszerű interfészeket biztosítunk, lehetővé téve a rugalmas domén-adaptációt. Az új pontfolyamat modellünk két fő újdonságot vezet be:

- (i) Az objektumok és objektumrészek hierarchikus kapcsolatát az MPP keretrendszerbe beágyazott szülő-gyermek relációval írjuk le. A gyermek megjelenését közvetlenül befolyásolja a szülő entitás geometriai és spektrális kényszereken keresztül.
- (ii) A (szülő) objektumok populációját partícionáljuk, léterhozva objektum csoportokat vagy más néven konfiguráció szegmenseket. A szekvenciális megközelítésekkel szemben modellünkben az objektumokat párhuzamosan nyerjük ki az optimális szegmensekkel egy közös energiaminimalizációs módszer segítségével. A szegmensekét különbözőképpen definiálható interakciók megengedésével adaptív objektum szomszédosságot hozunk létre.

Cikkünkben bevezetünk egy összetett háromrétegű beágyazott jelölt pontfolyamat modellt (Embedded MPP, EMPP), és a hozzá tartozó energiafüggvény optimalizációjára bemutatjuk a többszörös születés és halál relaxációs eljárás [7, 8] egy új háromszintű változatát. A modellhez ezután három különböző alkalmazási példát is mutatunk a távérzékelés és az optikai minőségvizsgálat területeiről. A kiértékelés során demonstráljuk, hogy a javasolt eljárás megnövekedett dimenziójú populációterekben is hatékony kimeneti konfigurációkat talál.

2. Problémadefiníció és jelölések



1. ábra: EMPP minta populáció három objektumcsoporttal, és különböző geometriájú objektumokkal a szülő, illetve gyermek rétegekben.

A hierarchikus helyszínelemzés megvalósítására javasolt beágyazott jelölt pontfolyamat modell (Embedded Marked Point Process, EMPP) az 1. ábrán látható többre-

tegű struktúrával rendelkezik. A felső szinten a *populáció* (vagy *konfiguráció*) található, ami a leképezett szintér magas szintű modelljének tekinthető. A populáció tetszőleges számú objektumcsoportot tartalmazhat, ahol egy adott csoport egy vagy több szuper (vagy szülő) objektum halmaza. A szuper objektumok - maximálisan adott számú - részobjektumokat (vagy gyermekeket) foglalhatnak magukba.

Az EMPP modell bemenete az S pixelrácson értelmezett digitális kép. Legyen u egy szülő objektum jelölt, amelyet egy előzetesen rögzített alakzatkönyvtárból választott síkidommal modellezünk, például ellipszisek és téglalapok halmazából. Minden objektum esetén definiáljuk a referenciapontjukat, az orientációjukat és további geometriai paramétereiket, például a tengely- vagy oldalhosszokat. Valamennyi u szülőobjektum tartalmazhat egy vagy több gyermekobjektumot, melyek halmazát Q_u -val jelöljük. Itt $Q_u = \{q_u^1 \dots q_u^{m(u)}\}$ ahol $m(u) \leq m_{\max}$, és minden gyermek objektum is a korábban definiált geometriai alakzatkönyvtár egy-egy példánya. $Q_u = \emptyset$ jelöli, ha u szülőnek nincs gyermeke.

Az objektumcsoportosítás általunk javasolt modellje szerint egy adott ω populáció k objektumcsoport (vagy konfigurációszegegens) halmaza, $\omega = \{\psi_1, \dots, \psi_k\}$, ahol egy adott csoport ψ_i ($i = 1 \dots k$) n_i objektum konfigurációja: $\psi_i = \{u_{n_i}^1, \dots, u_{n_i}^{n_i}\}$. Előírjuk, hogy $\psi_i \cap \psi_j = \emptyset \forall i \neq j$, míg a k halmazszám és n_i halmaz számosság paraméterek tetszőleges egész értéket vehetnek fel. Jelölésünk szerint $u \prec \omega$ ha u bármelyik ψ -hez tartozik ω -ban, és legyen $\mathcal{N}_u(\omega)$ $u \prec \omega$ szomszédjainak a halmaza, egy adott $u \sim v$ szomszédossági relációt használva.

Végül Ω -val jelöljük valamennyi lehetséges populáció (azaz globális konfiguráció) halmazát, megengedve, hogy egy adott populáció $\omega \in \Omega$ tartalmazhat tetszőleges számú objektumcsoportot, amelyek magukban foglalhatnak bármennyi szülő illetve gyermek objektumot.

3. EMPP energiamodell

Az EMPP keretrendszer az $\omega \in \Omega$ konfigurációk kiértékelésére egy $\Phi(\omega)$ energiafüggvényt használ, amely figyelembe vesz megfigyelt képi jellemzőket, és a helyszínről rendelkezésre álló prior ismereteket. Így az energiafüggvény egy szingleton (Y) és egy interakciós tagból (I) áll: $\Phi(\omega) = \Phi_Y(\omega) + \Phi_I(\omega)$. Az optimális $\hat{\omega}$ konfigurációhoz a $\Phi(\omega)$ függvény Ω feletti minimalizációjával jutunk.

3.1. Szingleton energiatagok

Az $\varphi_Y(u)$ energiatagot az u objektum lokális adatfüggő leírásához használjuk, ami független a populáció többi objektumának helyzetétől. $\varphi_Y(u)$ felírható a szülő szintű tag $\varphi_Y^p(u)$ és a q_u gyermekekhez tartozó $\varphi_Y^c(u, q_u)$ gyermek szintű tagok összegeként. A gyermek tag függhet a képi méréstől és a szülő geometriájától is, példaként tekintünk egy intenzitáshisztogram jellemzőt a szülő által lefedett képrészleten.

Szülő szinten definiálunk különböző $f(u)$ fitness függvényeket (vagy *jellemzőket*), amik egy adott u objektumhipotézist értékelnek ki a képen. Ezután $\varphi_{Y,f}^p(u)$ *adatfüggő* energiatagokat származtatunk minden f jellemzőhöz, úgy, hogy a jellemző értelmezési

tartományát a $[-1, 1]$ intervallumba vetítjük egy $\mathcal{M}(f, d_0^f)$ monoton csökkenő nemlineáris függvénnyel: $\varphi_f(u) = \mathcal{M}(f(u), d_0^f)$ ahol $\mathcal{M}(\cdot) = 1 - 1/f(u)$ ha $f(u) < d_0^f$, egyébként: $\mathcal{M}(\cdot) = \exp(-f(u) + d_0^f) - 1$. d_0^f az f jellemzőhöz tartozó objektumelfogadási küszöb, amit manuálisan annotált tanító adathalmazon statisztikai becslő eljárásokkal határozzuk meg.

Az u objektum $\varphi_Y^p(u)$ szülő szintű energiáját a $\varphi_{Y,f}^p(u)$ tagokból számoljuk. Először objektum prototípusokat készítünk, előírva egy vagy több jellemzőkényszer teljesülését, melyek φ_f -energiatagjait a maximum operátorral kapcsoljuk össze a prototípus energiafüggvényében. Ez a művelet ekvivalens a logikai ÉS-sel a negatív likelihood tartományban. Egy adott képen több objektum prototípust is felismerhetünk párhuzamosan, amennyiben a prototípus energiákat a minimum operátorral (logikai VAGY) kapcsoljuk össze. Így az összesített $\varphi_Y^p(u)$ szülő szintű adattaghoz logikai függvényeken keresztül juthatunk, melyek alkalmazásfüggő ismereteink alapján megvalósításonként különbözőképpen választhatók meg.

A $\varphi_Y^c(u, q_u)$ gyermek szintű singleton tagok konstrukciója a fentiekhez hasonló módon történik, különböző képi jellemzők \mathcal{M} -leképezésével. Az u objektum teljes singleton energiája a szülő és gyermek szintű tagok összegeként számítható:

$$\varphi_Y(u) = \varphi_Y^p(u) + \sum_{q_u \in Q_u} \varphi_Y^c(u, q_u).$$

A teljes konfiguráció adatfüggő energiája az egyes objektum-energiák összegeként kapható:

$$\Phi_Y(\omega) = \sum_{u < \omega} \varphi_Y(u).$$

3.2. Interakciós energiagagok

Az interakciós tagok geometriai vagy képi jellemző alapú kölcsönhatásokat modelleznek az ω konfiguráció elemei között:

$$\Phi_I(\omega) = \sum_{\substack{u, v < \omega \\ u \sim v}} I(u, v) + \sum_{u < \omega} J(u, Q_u) + \sum_{u < \omega, \psi \in \omega} A(u, \psi).$$

Az $I(u, v)$ tagok klasszikus páros interakciós kényszereket definiálhatnak, erre a leggyakoribb példa (így a később bemutatott példáinkban is használni fogjuk) az átlapolódó objektumok bontetése az ω populációban:

$$I(u, v) = \frac{\text{Area}\{u \cap v\}}{\text{Area}\{u \cup v\}}.$$

A $J(u, Q_u)$ tagok interakciókat modelleznek az összetartozó szülő és gyermek objektumok között, és kapcsolati kényszereket az azonos szülőhöz tartozó gyermekek között. Példaként előírhatjuk, hogy egy adott szülő különböző gyermekei (azaz a *testvérek*) ne lapolódjanak át, és síkdomaik ne lógnak túl a szülőn. Kiköthetjük ezen felül, hogy a testvérek azonos alakzattípusból származzanak, hasonló alaki, szín, méret és orientációs paraméterekkel rendelkezzenek.

Végül az $A(u, \psi)$ energiategyekkel különböző kényszereket definiálhatunk az objektumcsoportok és a szülő objektumok szintje között. Az u objektum és a ψ konfigurációs szegmens illeszkedésének méréséhez készítünk egy $d_\psi(u) \in [0, 1]$ távolságmértéket, ahol $d_\psi(u) = 0$ tartozik a nagyon jó illeszkedéshez. Általánosságban előírjuk, hogy a szegmensek térben összefüggőek, ezért konstans nagy távolságértéket használunk, ha u -nak nincs szomszédja ψ -n belül a \sim szomszédossági reláció alapján: $d_\psi(u) \stackrel{\text{DEF}}{=} 1$, ha $\nexists v \in \psi \setminus \{u\}: u \sim v$.

$A(u, \psi)$ definíciója szerint kis mértékben büntetjük azokat a konfigurációs szegmenseket, melyek csupán egy objektumot tartalmaznak: kis $0 < c$ konstans használva $A(u, \psi) = c$ akkor és csak akkor ha $\psi = \{u\}$. Több objektumot tartalmazó szegmensek esetén a nagy $d_\psi(u)$ távolságértékeket büntetjük egy adott csoporton belül, ugyanakkor favorizáljuk a csoportok között: ha $u \in \psi: A(u, \psi) = d_\psi(u)$; ha $u \notin \psi: A(u, \psi) = 1 - d_\psi(u)$.

4. Optimalizáció

Az optimális objektumkonfiguráció becsléséhez kifejlesztettük a többszörös születés és halál dinamika (MBD) algoritmus [7, 8] háromszintű módosított változatát

Inicializálás: induljunk ki üres populációból $\omega = \emptyset$, állítsuk be a b_0 születési frekvenciát, az inverz hőmérséklet paramétert $\beta = \beta_0$ és a diszkrétizációs lépcsőt $\delta = \delta_0$.

Főprogram: iteráljuk a következő három lépést:

- **Születés:** látogassuk meg sorban az S kép pixeleit. Valamennyi s pixelnél δb_0 valószínűséggel generáljunk egy új u objektumot s középponttal és véletlenszerűen választott geometriai paraméterekkel. Az újonnan generált u objektumhoz, vagy hozzunk létre egy új ψ üres konfigurációs szegmenst, adjuk u -t ψ -hez és ψ -t ω -hoz; vagy adjuk u -t egy eddig is létező objektumcsoporthoz az objektum környezetét megvizsgálva [1].

- **Halál:** tekintsük az aktuális ω objektum konfigurációt és rendezzük az objektumokat $\varphi_Y(u) + J(u, Q_u) + A(u, \psi)|_{u \in \psi}$ értékeik alapján, csökkenő irányban. Az objektumokat vizsgáljuk meg ebben a sorrendben, és minden egyes u -ra számítsuk ki az alábbi értéket $\Delta\Phi_\omega(u) = \Phi_{\mathcal{D}}(\omega/\{u\}) - \Phi_{\mathcal{D}}(\omega)$, amely az u törlésével létrejövő potenciális energia változást határozza meg. A halálzási arány így:

$$d_\omega(u) = \Gamma(\Delta\Phi_\omega(u)) = \frac{\delta \exp(-\beta \cdot \Delta\Phi_\omega(u))}{1 + \delta \exp(-\beta \cdot \Delta\Phi_\omega(u))}$$

Ezután töröljük u -t ω -ból $d_\omega(u)$ valószínűséggel. Amennyiben valamelyik ψ objektumcsoport kiürül, távolítsuk el a populációból.

- **Csoportok újra-rendezése:** Javasoljunk véletlenszerűen csoportegyesítés, csoportbontás és objektum átsorolás lépéseket. Valamennyi javasolt M lépéshez számoljuk ki a hozzátartozó energiaköltséget $\Delta\Phi_\omega^M$, majd hajtsuk végre a lépést $\Gamma(\Delta\Phi_\omega^M)$ valószínűséggel.

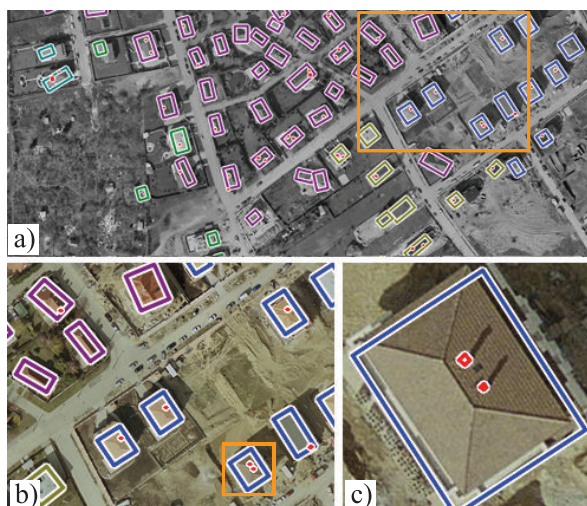
- **Gyermekek rendezése:** Valamennyi $u \prec \omega$ objektum esetén: (i) adjunk véletlenszerűen új gyermekobjektumokat Q_u -hoz (ii) rendezzük Q_u -t $\varphi_d^c(u, q_u)$ alapján csökkenő sorrendben (iii) ebben a sorrendben mindegyik $q_u \in Q_u$ -hoz számoljuk ki a $d_u^c(q_u)$

eltávolítási valószínűséget hasonlóan a szülő rétegben alkalmazott stratégiához, azonban csupán a gyermek szintű szingleton és interakciós energiátagok figyelembevételével. (iv) távolítsuk el q_u -t Q_u -ból $d_u^c(q_u)$ valószínűséggel.

Konvergencia teszt: amíg a folyamat nem konvergál, növeljük a β inverz hőmérsékletet, csökkentjük a diszkretizációs lépcsőt δ geometriai sémával, és lépünk vissza a születés lépésre.

5. Alkalmazások

Ebben a szakaszban a javasolt EMPP három különböző alkalmazását mutatjuk be. Mindegyik alkalmazás esetén definiálnunk kell a doménfüggő f jellemzőket és a jellemző-integrálás szabályait a szülő $\varphi_Y^p(u)$ és a gyermek szintű $\varphi_Y^c(u)$ adattagok kiszámításához (3.1.. szakasz). Ezen felül meg kell határoznunk a $J(u, Q_u)$ gyermek-szülő interakciókat és az objektumcsoportokba tartozás szabályait a $d_\psi(u)$ objektum-konfigurációs szegmens távolság definiálásán keresztül (3.2.. szakasz).



2. ábra: Beépített területek analízise három különböző szinten megjelenítve. Az épületcsoportokat különböző színek jelölik (lila: *vörös háztetős régió*, többi szín: orientáció alapú objektumcsoportok); piros markerek jelölik a detektált kéményeket.

5.1. Beépített területek analízise légi és műholdképeken

Modell elemek: a szülő objektumok téglalap alakú épületek vagy épületrészek. A gyermek objektumok magas struktúraelemek a tetőn, főként kémények vagy antennák, melyeket szintén téglalapokkal modellezünk. A konfigurációs szegmensek összetartozó épületcsoportok (példák a 2a ábrán láthatók).


Szülő szintű szingletonok (φ_Y^p): két objektumprototípust használunk: az első nagy gradiensértékeket ír elő a képen az épületjelölt téglalapok szélei alatt, valamint detektálható árnyékokat az épületek mellett; a második prototípus kiugró (tipikusan piros) tetőszíneket keres, amelyek a háttértől jól elkülönülnek [3].

Gyermek szintű szingletonok (φ_Y^c): a kémények és antennák színben eltérnek a tetők többi részétől, valamint árnyékokat vetnek a tetőre (2c. ábra).

Szülő-gyermek interakciók $J(u, Q_u)$: Átfedésmentes gyermekeket várunk el hasonló orientációval. A gyermek síkidomját a szülő téglalap magában foglalja (2c. ábra).

Objektum-csoport távolság $d_\psi(u)$: a csoportok hasonló (kiugró) tetőszín vagy hasonló téglalap orientáció alapján jönnek létre [1]. $d_\psi(u)$ a normalizált szín/orientáció-különbség az u objektum és a ψ csoporton belül számított átlag között (2a,b ábrák).

Alkalmazás: várostervezés, illegális vagy a környezetből kiugró megjelenésű beépítések, épületek észlelése. Engedély nélküli vagy szabálytalan kémények detekciója.



3. ábra: Városi forgalomfelügyelet Lidar pontfelhők alapján: a) járművek és forgalmi csoportok b) kiválasztott régió a felismert szélvédőkkel c) egy jármű intenzitástérképe, d) eredmény a c) példán

5.2. Városi forgalomfelügyelet légi Lidar pontfelhők alapján

Előfeldolgozás: a Lidar pontfelhőket jármű és háttér osztályokba soroljuk, majd a pontok osztálycímkéit és intenzitásértékeit a talajsíkra vetítjük [5].

Modell elemek: a szülő objektumok járműveket, a gyermekek szélvédőket modelleznek (mindkét esetben téglalapok). Az egyes csoportokat a forgalmi szempontból összetartozó objektumok alkotják, például egy parkolóban álló autók, vagy egy közlekedési lámpánál sorban várakozó járművek (3a ábra).

Szülő szintű szingletonok (φ_Y^p): a jellemzők egyrészt az u téglalapja által lefedett járműként szegmentált (projektált) pontok aránya a téglalap területéhez képest, illetve a befoglalt pontok átlagos intenzitása. Másrészt figyelembe vesszük a háttérpontok fedési arányát u közvetlen környezetében [5].

Gyermek szintű szingletonok (φ_Y^c): a szélvédő üvegek elnyelik a lézersugarakat, ezáltal a pontfelhőben lyukakat, vagy alacsony intenzitású régiókat okoznak a jármű objektumon belül (3c,d ábra).

Szülő-gyermek interakciók $J(u, Q_u)$: a szélvédő alakzatát befoglalja a szülő objektum, a szélvédő téglalap modelljének orientációja merőleges az autó főtengelyére (3b,d ábra).


Objektum-csoport távolság $d_\psi(u)$: orientáció távolság u és a $\psi(u)$ csoporton belüli átlag között. Kanyarodó utak esetén az orientáció relatívan számítható az út széléhez képest [5].

Alkalmazás: automatikus forgalomfigyelés és forgalomirányítás. A kinyert szélvédőkonfigurációk felhasználhatók járműtípusok osztályozására, vagy a járművek haladási/parkolási irányának a becslésére. (3b. ábra).

5.3. Nyomatott áramkörök automatikus optikai hibaanalízise

Cél: az áramköri elemek (ÁE) helyzetének és alakjának pontos kinyerése egyedileg készített nyomatott áramköri lapokon (NYÁK), az *üregesedés*, mint speciális forrasztási hiba detekciója [4].

Modell elemek: a szülő objektumok különböző alakú ÁE-k, a gyermek objektumok az észlelendő üregek, koncentrikus ellipszisekkel modellezve [4]. A hasonló funkcionalitású, közeli ÁE-k tartoznak egy csoportba [1] (4a ábra).



4. ábra: NYÁK analízis eredménye. Az ÁE-eket azonos alak és orientáció alapján csoportosítottuk, az ÁE-eken belül detektáltuk az üregeket.

Szülő szintű szingletonok (φ_Y^p): Az ÁE-k világos objektumok sötét háttér előtt a NYÁK képeken. Az ÁE régiók és a körülvevő háttérterületek kontrasztjának a méréséhez az intenzitáshisztogramok Bhattacharya [8] távolságát számítottuk ki.

Gyermek szintű szingletonok (φ_Y^c): az üregek belső régióiban mérjük az intenzitáshisztogram csúcsát, valamint kiszámoljuk a belső régió és a középső környűri kontrasztját, és a középső és a külső környűri közötti intenzitáskontrasztot (4c ábra) [4].

Szülő-gyermek interakciók $J(u, Q_u)$: minden ÁE-hez maximum egy gyermek tartozhat, melynek síkidomát le kell hogy fedje a szülő ÁE.

Objektum-csoport távolság $d_\psi(u)$: egy adott ÁE csoporton belül az objektumoknak azonos alakzatúnak kell lenniük és szigorú rács-rendeződési elveket kell követniük. Ezért $d_\psi(u) = 1$ amennyiben u alakzatának a típusa nem egyezik meg a ψ csoportban található alakzatokéval, egyébként $d_\psi(u)$ az u ÁE orientációjának és a ψ csoportban megfigyelt átlagos ÁE-orientációnak a normalizált különbsége.

Alkalmazás: egyedi NYÁK-ok automatizált funkcióanalízise és hibavizsgálata optikai módszerekkel.

6. Kiértékelés

A módszerünket valós adathalmazon teszteltük mindhárom alkalmazáshoz köthetően, különböző példák láthatók az eredményekre a 2-4 ábrákon. A paramétereket minden esetben egy kisebb teszhalmazon állítottuk be [1]. A kiértékeléshez megszámláltuk a valós pozitív, hamis pozitív és hamis negatív (hiányzó) találatokat mind szülő mind gyermek szinten, és kiszámoltuk a detekció F-mértékét (a precizitás és a visszahívás harmonikus közepe). Szintén megszámláltuk a hibás objektumcsoporttal rendelkező találatokat, felhasználva operátorok által végzett mintacsoportosításokat.

A *beépített terület* adathalmaz 69 épülete tartalmazott 66 kéménnyel vagy antennával. A detekció eredménye 95%-os volt szülő és 73%-os gyermek szinten, a Helyes Csoport (HCs) arány 91% volt.

A *forgalmi* adatokon 92%-os objektumdetekciót és 93% HCs arányt mértünk 170 megfigyelt járművön, az észlelt szélvédőpozíciók 82%-ban bizonyultak helyesnek.

Végül a *NYÁK* adathalmazon mind a 98 áramköri elemet helyesen detektáltuk és klasszifikáltuk, míg a gyermek szintű üregdetekciós eredmény 89%-os volt.

7. Konklúzió

A bemutatott kísérleti eredmények megközelítés szinten igazolták, hogy a javasolt EMPP modell képes jelentősen különböző, valós életből származó problémákat egyaránt hatékonyan kezelni, egy rugalmasan kibővíthető Bayesi keretrendszerrel nyújtva a képi tartalom több szintű interpretációjára. További munkáink az eljárás robusztusságának az analízisére és a nagy mértékben automatizált paraméterbecslésre fognak irányulni.

Köszönetnyilvánítás

A kutatómunkát részben az Európai Űrügynökség (ESA) PECS-HU program keretében hirdetett DUSIREF című projektje finanszírozta. A szerző munkáját az MTA Bolyai János Kutatási Ösztöndíja és az OTKA #101598 posztdoktori projekt is támogatta.

Irodalom

1. C. Benedek. A two-layer marked point process framework for multilevel object population analysis. In *International Conference on Image Analysis and Recognition (ICIAR)*, volume 7950 of *Lecture Notes in Computer Science*, pages 160–169. Póvoa de Varzim, Portugal, 2013.
2. C. Benedek. Hierarchical image content analysis with an embedded marked point process framework. In *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 5110–5114, May 2014.
3. 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.
4. C. Benedek, O. Krammer, M. Janóczki, and L. Jakab. Solder paste scooping detection by multi-level visual inspection of printed circuit boards. *IEEE Trans. on Industrial Electronics*, 60(6), 2013.
5. A. Börcs and C. Benedek. Extraction of vehicle groups in airborne lidar point clouds with two-level point processes. *IEEE Trans. on Geoscience and Remote Sensing*, 53(3):1475–1489, March 2015.
6. F. Chatelain, X. Descombes, F. Lafarge, C. Lantuejoul, C. Mallet, R. Minlos, M. Schmitt, M. Sigelle, R. Stoica, and E. Zhizhina. *Stochastic geometry for image analysis*. Digital Signal and Image Processing. Wiley-ISTE, 2011.
7. S. Descamps, X. Descombes, A. Bechet, and J. Zerubia. Flamingo detection using a multiple birth and death process. In *IEEE International Conf. on Acoustics, Speech and Signal Processing*, pages 1113–1116, Las Vegas, NV, 2008.
8. X. Descombes, R. Minlos, and E. Zhizhina. Object extraction using a stochastic birth-and-death dynamics in continuum. *Journal of Mathematical Imaging and Vision*, 33:347–359, 2009.
9. A. Gamal Eldin, X. Descombes, and J. Zerubia. A novel algorithm for occlusions and perspective effects using a 3D object process. In *IEEE International Conf. on Acoustics, Speech and Signal Processing*, pages 1569 – 1572, Prague, Czech Republic, 2011.
10. J. Porway, Q. Wang, and S. C. Zhu. A hierarchical and contextual model for aerial image parsing. *International Journal of Computer Vision*, 88(2):254–283, 2010.
11. G. Scarpa, R. Gaetano, M. Haindl, and J. Zerubia. Hierarchical multiple Markov chain model for unsupervised texture segmentation. *IEEE Trans. on Image Processing*, 18(8):1830–1843, 2009.