


ÁLCÁZOTT HADITECHNIKAI ESZKÖZÖK FELDERÍTÉSI LEHETŐSÉGEI A KÖZELI INFRA-, ILLETVE A LÁTHATÓ FÉNY TARTOMÁNYÁBAN KÉSZÜLT DIGITÁLIS LÉGI FÉNYKÉPEKEN.

Kivonat A legfontosabb áttörés a képfeldolgozás terén az autonóm, gépi képertelmező rendszerek megjelenése (image understanding system IUS) volt. Egy IUS rendszer megvalósítása akkora feladat, mint ha megpróbálnánk a valóságot leképezni. A kezdeti autonóm képanalizáló rendszerek az él detektáláson és mintázat szegmentáláson alapultak. Napjainkban kihasználva az érzékelők adta lehetőségeket (versenyképes ár és szélesebb érzékelési tartomány, jobb felbontó képesség), olyan félautomata rendszereket lehet építeni, amelyekben egy robosztus és gyors előfeldolgozáson keresztül biztosít információt a döntéshozók számára. A tanulmány robosztus előfeldolgozó algoritmus ismertetését tűzte ki célul, a szín alapú képszegmentálásra fókuszálva.

BEVEZETÉS

Az információs technológia fejlődésében a XX. század végét az érzékelők forradalmaként tartják számon, amely az összes elképzelhető mesterséges érzékelő- és beavatkozó eszköz tömeges és olcsó előállítását takarja. A látható fény (0,38-0,76 μ m) és közeli-infra (0,76-1,5 μ m) tartományban használt érzékelő eszközök számítástechnikai alkalmazással kombinálva, hatékony elemző-értékelő rendszer alakítható ki, kiváló terepet biztosítva a gépi látás tudományos eredményeinek a megvalósítására. Épületek, harci és polgári járművek, katonák és egyéb objektumok felismerése több területen is alapvető fontosságú: légi és műholdas felvételek „offline” elemzésénél, és a vadászpilóták pilótáinak harc közben történő segítségénél egyaránt. A repülőterek és rakétasilók detektálására optimalizált algoritmus természetesen teljesen más módon működik, más követelményeknek felel meg, mint a repülőgépek fedélzetén használt „automatikus célpont azonosítók”.



1. ábra. A számítógépes képanalízis alaplépései


A következőkben, általánosságban áttekintem, hogyan működik egy a számítógépes képfeldolgozó algoritmusok. Bár elsőre nem szembetűnő, de e problémák megoldása hasonló lépésekkel történik. Szinte mindig célszerű a képeket egyszerű transzformációkkal, szűrőkkel előfeldolgozni. Az így kapott kép valószínűleg tartalmaz fontos és lényegtelen területeket is. Ezeket a szegmentáció során választjuk szét egymástól. Így megkaptuk a kép számunkra fontos területét, amely ugyan kevesebb de még mindig pixelek ezreit (akár millióit) jelentheti, ami a legtöbb algoritmus számára túl sok feldolgozandó adatot jelent. A sűrű képpont felhőből kezelhető mennyiségű adatot az ún. feature-ök, vagy „vizuális jellemzők” kinyerésével kapunk. Ez legtöbbször vonalak, sarkok vagy egyéb szempontból speciális elemek detektálását jelenti. Így már nem pixelekkel, hanem kezelhető mennyiségű képi jellemzővel kell dolgoznunk. Ezek alapján már megkereshetjük az előre eltárolt adatbázisban a jellemzőkhöz legjobban hasonlító objektumot (felismerés), vagy kiszámíthatjuk a legjobban illeszkedő (mozgás, pozíció) paramétereket. Ne felejtsük el azt sem, hogy a képi jellemzők kinyerése során hamis találatokat is kaphatunk, amiket fel kell ismerni, és ki kell szűrni az adathalmazból. A cikkben egy a Magyar Honvédségben használt eszköz által készített digitális légi fényképen kívánom bemutatni a képanalízis egyes lépéseit.



2. ábra. Mintakép, kiindulási állapot. (SUAV kép)

ELŐFELDOLGOZÁS

Az előfeldolgozás célja, a nyers bemeneti adat előkészítése egyszerű műveletek és szűrők segítségével. Általában a két legfontosabb szempont a felesleges információk eldobása, kiszűrése valamint a bemeneti képeken megjelenő nem lényeges különbségek kiküszöbölése. Ez utóbbira jó példa az automatikus célpontfelismerés: napsütésben (erős kontraszt, világos kép), felhős időben (gyenge kontraszt) és éjszaka (sötét kép) is fel kell ismernünk ugyanazt az objektumot. Éppen ezért a legelső lépés a világosság és a kontraszt azonos szintre állítása, így a későbbiekben ez nem okozhat problémát.



3. ábra. Mintakép, előfeldolgozás utáni állapot.

SZEGMENTÁLÁS

A képszegmentálás alapvető célja, hogy a képnek olyan reprezentációját adja, amely egyszerűen feldolgozható és elemezhető automatizált módszerekkel. [1] Ez legtöbbször a képen található releváns objektumok elkülönítését és felcímkézését jelenti. A magasabb szintű képtérmezés így jelentősen redukált adatmennyiséggel és egyben jól definiált szemantikával rendelkező reprezentáción végezhető. Három féle szegmentálási eljárást ismertetek a következőkben.

1. Intenzitás alapú szegmentálás


Az egyik legegyszerűbb szegmentálási eljárás szerint az objektumokat az intenzitásuk alapján jelöljük ki, vagyis kijelölünk egy intenzitáshatárt, amely feletti intenzitású pixeleket objektumhoz tartozónak, az alattiakat pedig háttérnek (vagy irrelevánsnak) tekintjük. Hátrány, hogy bonyolultabb, inhomogén környezetben pontatlan szegmentáláshoz eredményez.

Hisztogram-alapú adaptív küszöbérték alkalmazásával általában lehet javítani a szegmentálás minőségén. Ezen eljárások közt találhatóak olyanok, amelyek valamilyen heurisztika alapján állapítják meg a hisztogram jellemzőiből a küszöbértéket. Ezen kívül léteznek olyan eljárások is, amelyek matematikai alapon, valószínűségi modelleket alkalmazva határozzák meg az ideális küszöbértéket.

2. Szín alapú szegmentálás

A szín alapú szegmentálás elgondolása szerint, a releváns objektumokat színük alapján tudjuk elkülöníteni és lokalizálni. Bár bonyolultabb, inhomogén alakzatok és látképek esetén a módszer nem hatékony, számos alkalmazásban megfelelő eredményeket lehet vele elérni; pl.: színes markerek, vagy ismert objektumok kijelölése.

Egy színes kép digitális megjelenítése és tárolása a képpontonkénti (pixel) színintenzitás érték alapján történik. Ezt az intenzitás értéket általában háromdimenziós vektorral írjuk le. Ezen vektortér komponenseinek meghatározása az alkalmazott színtér alapján változhat. A színterek részletes ismertetése a 2. számú felhasznált irodalomban található.



4. ábra. HSV színtér

HSV színtér

A színinformáció számos lehetséges alternatív reprezentációja közül a HSV (Hue, Saturation, Value) színmodellt választottam bővebb vizsgálatra. A modell koncepciója a következő: a H csatorna színtónust, az S csatorna a színtelítettséget, míg a V csatorna a fényességértéket képviseli. Mivel a magas fényességértékű színek jobban elkülöníthetőek, az alacsony fényességértékűek pedig kevésbé, ezért kézenfekvő a lehetséges H, S és V értékek által kifesztített térrészt kúpként ábrázolni (4. ábra).


Az RGB színtérből HSV-be való áttérés egy nemlineáris transzformációval valósítható meg. Az alábbiakban feltesszük, hogy R, G és B [0,255] közti értéket vehet fel, és H-t, S-t és V-t a [0,360], [0,255] illetve [0,255] intervallumon keressük. Továbbá legyen $\min = \min(R, G, B)$, és $\max = \max(R, G, B)$

$$H = \left\{ \begin{array}{l} \frac{60 * (G - B)}{\max(R, G, B) - \min(R, G, B)} + 0, \text{ ha } \max(R, G, B) = R, G \geq B \\ \frac{60 * (G - B)}{\max(R, G, B) - \min(R, G, B)} + 360, \text{ ha } \max(R, G, B) = R, G < B \\ \frac{60 * (B - R)}{\max(R, G, B) - \min(R, G, B)} + 120, \text{ ha } \max(R, G, B) = G \\ \frac{60 * (R - G)}{\max(R, G, B) - \min(R, G, B)} + 240, \text{ ha } \max(R, G, B) = B \end{array} \right\} \quad (1)$$

$$S = \left\{ \begin{array}{ll} 0 & \text{ha } \max(R, G, B) = 0 \\ 1 - \frac{\min(R, G, B)}{\max(R, G, B)} & \text{ha } \max(R, G, B) \neq 0 \end{array} \right\} \quad (2)$$

$$V = \max(R, G, B) \quad (3)$$

A konverzió elvégzésével már megfogalmazhatóak olyan küszöbözési feltételek, amelyek hatékonyan kihasználják az új színtérbeli reprezentáció előnyeit.




5. ábra. Mintakép, szín alapú szegmentálás eredménye.

3. Élkiemelés alapú szegmentálás

Az élkiemelés alapú szegmentálás az eddig ismertekkel szemben nem az objektumok homogenitására épít, hanem arra hogy az objektumok közt éles határvonal lép fel. Mint a 6. ábrán látható képen a határvonalak kiemelése alapot ad arra, hogy az objektumokat elkülönítsük egymástól.

Él kép javítása

Az élkiemelési eljárások (melyek bemutatására jelen munkában nem térek rá) kimenete legtöbbször zajos és erősen töredezett. Ennek oka abban keresendő, hogy a képen éles intenzitásváltozás nem csak a (valós világban különálló) objektumok határainál lép fel. Többek közt a felületi normális változása, a felület minőségének vagy mintázatának változása, a megvilágítás térbeli különbségei mind élként kerülhetnek kiemelésre. Még nagyobb probléma, hogy az eredeti képet terhelő esetleges zaj is kiemelésre kerülhet az éldetekció során. Szegmentálási szempontból is fontos, hogy a bemeneti képen megszüntessük a pontszerű zajokat. Mindemellett fontos, hogy az eljárás a használható éleket ne változtassa meg (pl. ne simítsa el). Ennek egy lehetséges megoldása a mediánszűrő, melyet az alábbiakban mutatok be.



6. ábra. Mintakép, Canny szűrés eredménye.

Mediánszűrő

A mediánszűrő a nemlineáris szűrők csoportjába tartozik, azaz nem írható le konvolúciós operátorral. Az eljárás a jelfeldolgozás számos területén elterjedt a fentiekben is említett kedvező zajszűrő tulajdonságai miatt. Képfeldolgozásban való implementációi kétdimenziós, négyzetes ablakot használnak. Az ablakhoz tartozó pixelek intenzitásértékei közül sorrendben a középső kerül az ablak közepénél elhelyezkedő pixelhez hozzárendelésre. Az eljárás implementációjának kritikus része egyrészt az, hogy hogyan található meg hatékonyan a középső intenzitásérték, másrészt pedig az, hogy hogyan használható ki, hogy a képen végighaladva, az ablakok közt átfedés van.



7. ábra. Mintakép, mediánszűrés eredménye.

Feature detekció

Az előfeldolgozott és szegmentált képek már közvetlenül alkalmasak lehetnek arra, hogy bizonyos algoritmusok felismerjék vagy kövessék az azokon látható objektumokat. A gyakorlatban azonban ez kevésbé jellemző, ugyanis még így is képpontok ezreit, netán millióit kell feldolgozni, ami a legtöbb módszer számára még mindig kezelhetetlen mennyiség.

A karakterisztikus jegyek kinyerése képekből már évtizedek óta kutatott terület, így számtalan hatékony, már-már standardnak tekinthető algoritmust ismerünk. A legtöbb módszer a szomszédos képpontok különbségén, azaz a „képfüggvény deriváltján” alapszik. Matematikailag viszonylag jól megfogalmazható, hogy milyen feltételeknek kell teljesülniük az éleken és a sarkokon található képpontokban. Szintén nem nehéz egyenes vonalakat, vonalak metszéspontjait, köröket és egyéb szabályos geometriai formákat megtalálni a képen. Modern alkalmazásoknál – például objektum felismerése és követése – olyan jellemzőket is kinyernek a képekből, melyek nem csupán pozíciójukkal, hanem orientációval vagy mérettel is jellemezhetők (például detektálják az apró pontokat és a nagyobb „korongokat” is, sőt ezek relatív méretét is). Az sem ritka, hogy egészen pontosan meghatározható dolgokat keresünk a képen: szemeket, kézfejet vagy éppen egy rendszámleolvasót. Ilyen esetben akár egészen speciális algoritmusok is rendelkezésre állnak a hatékony feature detekcióra.



8. ábra. Mintakép, Feature detekció eredménye.

Felismerés és Modell illesztés

A karakterisztikus jegyek azonosítása után általában nem több mint néhány száz leíró, avagy descriptor tömöríti magába a feldolgozandó képi információt. Ez már sokkal kezelhetőbb, mint sok millió RGB képpont! Nem meglepő módon a gépi látás különböző alkalmazásai meglehetősen más és más módon dolgozzák fel ezt az információmennyiséget, de a két legnagyobb problémakör kétségkívül a felismerés és a modellillesztés.

A felismerés – legyen az célpont– a legtöbb esetben nem egy adott objektum felismerését jelenti, hanem egy – akár igencsak terjedelmes – adatbázisban, a legjobban illeszkedő elem megtalálását. A harcjármű felismerés esetében ez azt jelenti, hogy a megtalált leírók sorozatát, azaz feature vector-t kell összehasonlítani az adatbázisban található feature vector-okkal. A gyengébb rendszerek gyenge pontja legtöbbször a nem megfelelő leírók használata, illetve azok sikertelen és pontatlan detektálása. A felismerő rendszerek gyakran használnak tanuló algoritmusokat. Ez azt jelenti, hogy a téves és a sikeres felismerésből is tanul a rendszer, módosítja belső „állapotát”, így a továbbiakban egyre jobb felismerési valószínűséggel fog működni. Ezek a rendszerek nem is feltétlenül igényelnek kezdeti

adatbázist, helyette be lehet őket tanítani. A tanuló rendszerek lelke legtöbbször egy neurális háló, ami – az agyunkhoz hasonlóan – nem más, mint elemi „kapcsolók”, neuronok igen nagy és összetett hálózata. A hálózat bemenete a feature vector (leírók sorozata), kimenete, pedig lehet akár egy, akár több igen/nem kapcsoló. A betanítás szakaszában különböző képeket „mutatunk” a rendszernek, és figyeljük a kimenetet. Ha egy adott hálózati kapcsolat erősítésével sikeresebb a felismerés, akkor erősítjük, ellenkező esetben gyengítjük. Megfelelően nagy számú és tartalmú kép, valamint optimálisan kialakított háló és feature-ök használatával a rendszer képes lesz sikeresen felismerni azokat a képeket is, amelyek nem szerepeltek az eredeti tanítóhalmazban! Jellemzően akkor érdemes ilyen megközelítést alkalmazni, ha nem teljesen világos, hogy mik a karakterisztikus jegyek, milyen tulajdonságok alapján lehet egyértelműen felismerni a cél-objektumot, pl. álcázott haditechnikai eszközök. Természetesen nagyon körültekintően kell alkalmazni ezeket a tanuló algoritmusokat, hiszen sok olyan tényező van, ami befolyásolja a működést.

Az, hogy tudjuk, mi van a képen, azt jelenti, hogy rendelkezünk egy modellel, amely alapján meg tudjuk mondani, hogy kitalált paraméterek illeszkednek-e a mérésekhez, vagy nem. Az autonó felderítő eszköz például tudja, hogy körülbelül hogy néz ki egy adott haditechnikai eszköz többféle látószögből, és ezt össze is tudja hasonlítani a mérésekkel (azaz a légi képekkel). Ezek a feladatok is jellemző leírók detektálásával kezdődnek, az ismeretlen paraméterek kinyerése pedig általában két lépésben történik.

Az első lépésben, ha mód van rá, speciális szabályok alapján megmondjuk, hogy körülbelül mik a helyes paraméterek: nagyjából merre van a keresett fegyverzett, hozzávetőlegesen merre áll a harcjármű stb.

A második lépésben standard matematikai eszközökkel finomítjuk ezt a megoldást, azaz megkeressük azokat a paramétereket, melyek minimalizálják a különbséget a mért jellemzők, és a modell között.

A modellillesztés problémájánál is alkalmazhatóak tanuló módszerek.

ÖSSZEGZÉS

A cikkben áttekintettem, és példákkal szemléltettem a haditechnika eszközök légi felderítési lehetőségeit. A HSV színtérben végzett szegmentálás segítségével egy gyors, hatékony és robosztus előfeldolgozás végezhető a digitális képeken. Egy hasonló algoritmus célhardveres implementációja a szenzorokkal egybe építve alkalmas lehet UAV fedélzeti műszernek is. Az alábbi képen a RQ-7 Shadow 200 UAV látható, mely több mint 27kg fedélzeti műszert képes 7 órán keresztül a levegőbe juttatni, mint pl.: többfajta szenzort és elektronikus felderítő eszközt.



9. ábra RQ-7 Shadow 200 UAV

Az ilyen típusú felderítő eszközökben célhardvert alkalmaznak. Az ilyen típusú célhardver épülhet FPGA (Field Programmable Gate Array) alapra. Az FPGA egy hatékony megoldás mobil rendszerek számára, mert kis fogyasztású, így tovább bírja akár harctéri alkalmazásoknál is. A kis fizikai kiterjedése és könnyű súlya is harci alkalmazhatóságát támasztja alá. A szükséges algoritmusok nagymértékű párhuzamosítására, és valós idejű megvalósíthatóságára ad lehetőséget.

FELHASZNÁLT IRODALOM

- [1] Gonzalez, Woods, „Digital Image Processing”, Addison-Wesley, 1993, 93-104 o.
- [2] SERGYÁN Szabolcs, Color Content-based Image Classification, 5th Slovakian-Hungarian Joint Symposium on Applied Machine Intelligence and Informatics, January 25-26, 2007, 430 o.
- [3] Lawrence O’GORMAN, Practical algorithms for image analysis, Cambridge University Press, 2007