

Májsegmentálás osztott valószínűségi modell alkalmazásával kontrasztos MR képeken*

Ruskó László, Bekes György, Kovács Ferenc, Blaskovics Tamás

GE Hungary Healthcare Division, 6725 Szeged, Szikra u. 2, Magyarország

Absztrakt. A 3D-s orvosi képeket feldolgozó klinikai szoftverek egyik hasznos funkciója az anatómiai szervek vagy szövetek szegmentációja. A szegmentációval kiemelt területek segítik az orvost a diagnózis felállításában, a terápiás kezelés meghatározásában és a beteg későbbi megfigyelése során. A máj klinikai kezeléséhez szükséges a máj kontúrja, érhalózata, az anatómiai szegmentumai és a májon belüli elváltozások szegmentálása. Ahhoz, hogy ezen információk a rendelkezésre álljanak, olyan 3-dimenziós képalkotó eszközöket használunk, mint a számítógépes tomográf (CT) vagy a mágneses rezonancia vizsgálat (MRI). Kontrasztanyag hozzáadásával kiemelhetők a szervek, léziók és az érhalózat struktúrája, valamint ezek határai. A kontrasztanyag MRI máj képek szegmentációja során a következő problémákkal kell számolnunk: a májat más szervek is körülveszik, amelyeknek intenzitásértéke a májhoz hasonló; az egészséges májszövet heterogén intenzitás eloszlást mutat; valamint a májszövet és a léziók kontrasztanyag felvétele változó. Továbbá számolnunk kell az MR felvétel során képződött műtermékekkel is. Célunk egy gyors és pontos máj szegmentáció kifejlesztése MR képekre, ami széles körben felhasználható orvosi alkalmazásokban.

Kulcsszavak: automatikus szegmentáció, máj szegmentáció, MR, valószínűségi modell.

1 Bevezetés

A máj CT-vel történő szegmentációjáról már számos módszert publikáltak. Ezek többsége a level-set [1], régiónövelés [2], vagy deformálható alakzat [3] algoritmusok valamilyen változatai, amik kiterjeszthetők alak [4], valószínűségi [5], vagy intenzitás [6] modellel. Egyes módszerek [4, 3, 6] alak modelleket használnak, melyeket lokális intenzitás vagy alak statisztikákkal egészítenek ki. Ezek a módszerek hatékonyan kezelik a máj változó intenzitását, de a CT jellemző tulajdonságaira támaszkodnak (pl. a máj intenzitása egy jól meghatározott intenzitás tartományban van), ami megnehezíti a módszer MR modalitásra történő adaptálását. Továbbá a komplex alak modellek használata jelentősen megnöveli a módszer futási idejét. Furukawa és társai [1] valamint Rikxoort és társai [5] valószínűségi modellt alkalmaznak, ami jelentősen

* Original article: L. Ruskó, Gy. Bekes. Liver segmentation for contrast-enhanced MR images using partitioned probabilistic model. International Journal of Computer Assisted Radiology and Surgery. 1861-6410. 2010.

javítja a level-set és a voxel osztályozási módszerek hatékonyságát. Az alkalmazott valószínűségi modell modalitás független, ennek ellenére ezek a módszerek nem tudják hatékonyan kezelni az MR-es vizsgálatára jellemző májon belüli nagy intenzitásváltozást. A [2] módszernél alacsony számítási igényű módszert alkalmaznak, mely egy olyan régiónövelési algoritmus, ami előzetes anatómiai információkat is használ, hogy elkerülje az alul- és túlszegmentálást. Ez az algoritmus gyors, de a máj nagyobb lézióit hajlamos alul szegmentálni. Teljes szervre kiterjedő globális intenzitás statisztikákat használ, ezért ez a koncepció változtatás nélkül nem alkalmazható MR képeken. Li és társai [7] egy automatikus megközelítést írnak le, ami a level-set és a watershed módszereket ötvözi. Bár eredményeik szerint ez az algoritmus szépen kiszegmentálja a májat, nincsenek adatok sem a pontosságáról, sem a futási idejéről. Farraher és társai [8] egy klaszterezésen alapú módszert használnak MR képeken, ami felhasználói interakciót is igényel (a felhasználó értékeli ki a szegmentáció eredményeit, és módosítja a paramétereket, amennyiben szükséges) és időigényes (a futási idő kb. 5 perc). Hermoye és társai [9] a manuális kontúrozást vetik össze a szemi-automatikus 2D-s deformálható modell technikával, ami szeletről szeletre halad egy, a felhasználó által megadott körvonalból kiindulva, amit a módszer a szerv határvonalához igazít. Hozzávetőlegesen 5 percet és több felhasználói beavatkozást vesz igénybe, ami jelentős inter-operátor változást idézhet elő.


A fent említett eredményekből láthatjuk, hogy szükség van egy automatikus módszerre, ami MR képeken gyorsan és pontosan szegmentálja a májat. Felhasználva a korábbi eredményeket célunk egy olyan módszer kifejlesztése, ami ötvözi az intenzitás, alak és lokális statisztikai adatokon alapuló módszerek előnyeit.

2 A módszer leírása

2.1 Modellépítés

Ebben az alfejezetben bemutatunk egy valószínűségi modellt, ami felhasználva az anatómiai szegmensek elhelyezkedését lehetővé teszi, hogy a máj különböző részeit különböző intenzitás-statisztikák segítségével szegmentáljuk. A modell két fő részből áll: a máj voxeleinek valószínűségi térképéből és a máj anatómiai szegmenseiből.

A valószínűségi modellt 60, manuálisan kontúrozott máj kontúrból állítottuk össze, melyet radiológusok készítettek el CT vizsgálatokon. A kontúrozott májakat újra mintavételeztük, hogy azonos méretű, izotróp (2.5 mm) voxeleket kapjunk. Ezt követően 3D-s hasonlósági transzformációval a szegmentált májakat egy előzetesen kiválasztott referencia májhoz regisztráltuk. A regisztrációs transzformáció eltolást, nagyítást és elforgatást tesz lehetővé. Referencia májként azt az esetet választottuk, amelynek a térfogata (1520 ml) a legközelebb állt a 60 esetből számolt átlagos máj térfogathoz (1525 ml). A regisztráció során a referencia és a mozgókép négyzetes hibáját (ITK-ban megvalósított) gradiens csökkenő módszerrel optimalizáltuk. A regisztrációt követően a kapott transzformációt minden képre alkalmaztuk, majd a valószínűségi térképet a szegmentált képek összegével definiáljuk. Végül a valószínűségi térkép értékeit a $[0,1]$ -es tartományra normalizáltuk.



1. ábra: Szegmentált máj modell. A máj valószínűségi térképet 30%-ánál küszöböltük, hogy megkapjuk az átlagos máj modellt (baloldalon), amit a referencia májhoz definiált elválasztó síkokkal osztottunk fel. A máj modell egy axiális (középen) és egy koronális (jobb oldalon) szelete, ami voxelenként két értéket mutat: a máj valószínűségi értéket (fényerő) és a szegmens címkét (színek).

A modell építés kulcsfontja, hogy a valószínűségi modellt anatómiai szegmensekkel bővítettük. A Couinaud szegmentáció [10] 8 különálló szegmentumra osztja a májat. Minden egyes szegmentum rendelkezik saját vénával, artériával, valamint epevezetékkel. Ez lehetővé teszi a máj részekre történő automatikus felosztását és az egyes részekhez tartozó különböző statisztikák felhasználását. Couinaud szegmentumok leegyszerűsített meghatározása 5 sík segítségével definiálja a 8 szegmenst. Ezeket a síkokat a májvéna 3 és a májkapuér 2 fő ágához kell illeszteni. A modellépítésben a felosztó síkok helyzetét a referencia májhoz tartozó CT képen határoztuk meg (az érhálózat látható CT-n). Ezekkel a síkokkal az átlagos máj alakzatot osztottuk szegmentumokra. Azért, hogy megkapjuk az átlagos májmodellt, a valószínűségi térkép küszöb értékét 30%-on állapítottuk meg, így a térfogata közel egyenlő az átlagos máj térfogattal.

Összegezve, a modellépítés olyan 3-dimenziós eredményt adott, amelynél minden voxelhez két érték tartozik: egy voxel milyen valószínűséggel tartozik a májhoz, illetve az adott voxel tartalmazó szegmens címkéje. Az 1. ábrán az átlagos máj modell felosztása, valamint a felosztott máj valószínűségi térképének egy axiális és egy koronális szelete látható.

2.2 Szegmentáció


A következő részben azt mutatjuk be, hogy hogyan regisztráljuk a máj modellt az input képhez, valamint, hogy hogyan szegmentáljuk a képet a regisztrált modell segítségével. Inputként kontrasztos (kapuér fázisban készített) MR LAVA képeket használtuk. A LAVA protokollt hasi képalkotásra fejlesztették ki, így kizárólag arról a területről készít felvételt, ahol a máj is található (nem tartalmazza sem a mellkast, sem a medencét).

A májszövet intenzitása (mostantól $[G_{\min}, G_{\max}]$) jelentős mértékben változik a kontrasztanyagos LAVA képeken (a vizsgált adathalmazon az átlagos májintenzitás 729 és 2954 között változott). A CT modalitással szemben ezt a tartományt minden esetben külön ajánlott meghatározni, amely a teljes kép hisztogramja (h) alapján

történik. A kontrasztanyag hozzáadásnak és a jól behatárolható területen készített felvételnek köszönhetően a hisztogramon az átlagos máj intenzitásának mindig van egy jól elkülöníthető maximuma.


Azért, hogy megtaláljuk a máj maximum intenzitását, a simított hisztogramon (h) elemeztük az összes lokális maximum környezetét. Minden egyes lokális maximum pozícióhoz (m) meghatároztuk a jobb oldalra eső r_m és baloldalra eső l_m legközelebbi pozíciót a következő formában:

- $h(l_m) < 0.1 \cdot h(m)$ vagy l_m egy lokális minimum, és
- $h(r_m) < 0.1 \cdot h(m)$ vagy r_m egy lokális minimum.



2. ábra: Egy input kép simított hisztogramja. A máj intenzitását (szürke intervallum) minden vizsgálaton külön számoltuk ki úgy, hogy minden egyes lokális maximumot (m) egyenként elemeztünk.


Miután meghatároztuk az l_m és r_m pozíciót, kiszámoljuk azt a terület (A_m), ami az $[l_m, r_m]$ intervallum hisztogramjához tartozik (lásd 2. ábra). Ha A_m minden maximum pozícióhoz meghatározott, az átlagos máj intenzitásként a legnagyobb m -et választjuk, amelyre $0.05 < A_m$. A G_{min} és G_{max} értékét az l_m és r_m értékekkel definiáljuk. Az 5%-os korláttal megelőzzük, hogy a módszer egy nagyobb intenzitású lézióhoz vagy egy másik szervhez tartozó intenzitástartományt válasszon.



3. ábra: Szegmentált máj modell. A máj valószínűségi térképet 30%-ánál küszöböltük, hogy megkapjuk az átlagos máj modellt (baloldalon), amit a referencia májhoz definiált elválasztó síkokkal osztottunk fel. A máj modell egy axiális (középen) és egy koronális (jobb oldalon) szelete, ami voxelenként két értéket mutat: a máj valószínűségi értéket (fényerő) és a szegmens címkét (színek).

Ahhoz, hogy a valószínűségi modellt a szegmentálandó képhez tudjuk regisztrálni, a következőket tesszük. Első lépésként az input képet 2,5 mm izotróp voxel-méretet használva újra mintavételezzük. Ezt követően, a $[G_{\min}, G_{\max}]$ intervallum segítségével küszöböljük, majd a test bal hátsó sarkát (ahol a lép található) kitöröljük (3. ábra). A küszöbölt kép összes nem-nulla voxelére 3D-s Chamfer távolságot számolunk ki, melynek eredményeképpen létrejön egy 3-dimenziós távolságtérkép (3. ábra). Mivel a hasi régióban a máj rendelkezik a legnagyobb térfogattal, a távolságtérképen található legnagyobb értékek a máj belső részét reprezentálják. Fontos, hogy a valószínűségi térképnek is ugyanezek a jellemzői, ami lehetővé teszi a máj modell távolságtérképpel történő regisztrációját (3. ábra). A regisztráció egy 3D-s hasonlóság transzformációt határoz meg azáltal, hogy a valószínűségi modell és a távolságtérkép közötti négyzetes különbséget minimalizálja, miután a távolságtérképet a $[0,1]$ -es tartományra normalizáltunk. A regisztrációs transzformáció kezdeti értékei: nagyítási faktor 1; a forgatási mátrix az egységmátrix és az eltolás a távolságtérképhez és valószínűségi modellhez tartozó tömegközéppontok közötti távolság. A regisztráció után az átlagos máj modellt és a szegmenst információkat a képre helyezzük. Azért, hogy az összes lehetséges máj voxelre megkapjuk a szegmenst információkat (regisztrációs hiba miatt pár voxel kieshet a modelltől), a szegmenstumokon háromdimenziós dilatációt alkalmazunk. (3. ábra)

A májszövet szegmentálásához régiónövelő algoritmust használunk. A módszer bemenete egy vérereket és léziókat nem tartalmazó kezdő régió. A régiót 3D-s erózióval nyerjük az előbbi lépésben létrehozott küszöbölt képből. Kihasználva, hogy a hasüregben a legnagyobb térfogattal a máj rendelkezik, az erózióhoz egy nagy átmérőjű (15 mm) gömböt használunk, majd az így kapott régiókból a legnagyobb 3D-s összefüggő régiót választjuk (4. ábra).



4. ábra: A szegmentáció fő lépései. Kiinduló régió (bal felső), a régió növelés eredménye (jobb felső), a dilatació eredménye (bal alsó), az üregfeltöltés eredménye (jobb alsó).

A következő lépésben a régiónöveléshez szükséges intenzitás statisztikákat számoljuk ki, mind a kezdő régió, mind az összes szegmensben külön-külön. A kezdő régió intenzitás tartományát $[L_{\min}, L_{\max}]$ a következő módon számoljuk ki a régió hisztogramjából: Jelölje L_{mod} , $L_{\text{std}(l)}$ és $L_{\text{std}(r)}$ a hisztogram móduszát, valamint az intenzitás szórási értékeit mind a bal, mind a jobb oldalon. Ekkor, $L_{\min} = L_{\text{mod}} - c \cdot L_{\text{std}(l)}$ és $L_{\max} = L_{\text{mod}} + c \cdot L_{\text{std}(r)}$, ahol $c = 3$ egy empirikus konstans. Ez az intenzitás tartomány szűkebb, mint $[G_{\min}, G_{\max}]$ mert nem tartalmaz sem vérereket, sem hypodens vagy hyperdens léziókat.

Az eredeti (nem dilatált) szegmens információit felhasználva kiszámoljuk mind a 8 szegmens intenzitás tartományát úgy, ahogy azt a kezdő régió esetében tettük. Jelölje $[S_{\min}^i, S_{\max}^i]$ a szegmens intenzitás tartományát, ahol $i \in [1,8]$. Mivel a felosztott modellt a képhez regisztráltuk, meghatározhatjuk az egyes szegmenszekhez tartozó

voxeleket. Így az S_{\min}^i és az S_{\max}^i értéke a megfelelő voxelek halmaza alapján kiszámítható. Összefoglalva, a régió növelés során a következő intenzitás statisztikákat használjuk:

- Máj statisztika $[L_{\min}, L_{\max}]$: a teljes tartomány részhalmaza, ami az (egészséges) májszövetet mutatja vérerek és léziók nélkül.
- Szegmens statisztikák $[S_{\min}^i, S_{\max}^i]$: az i . szegmenshez tartozó lokális intenzitást mutatja, beleértve az egészséges májszövetet, a vérereket és léziókat (lehet szűkebb, mint $[L_{\min}, L_{\max}]$ vagy szélesebb, mint $[G_{\min}, G_{\max}]$ a műtermékektől és patológiáktól függően).

Az intenzitás statisztikák számítása után a kezdő régióból elindítjuk a régiónövelést. Minden iterációban egy voxel (j) vizsgálunk. A j voxel hozzáadjuk az eredményhez, amennyiben az 5 mm sugarú 3-dimenziós környezetében az összes voxel intenzitása a $[V_{\min(j)}, V_{\max(j)}]$ tartományon belül van, amit a következőképpen határozunk meg:

$$V_{\min}(j) = S_{\min}^{i(j)} + (L_{\min} - S_{\min}^{i(j)}) \cdot (1 - p(j)) \quad \text{és} \quad (1)$$

$$V_{\max}(j) = S_{\max}^{i(j)} + (L_{\max} - S_{\max}^{i(j)}) \cdot (1 - p(j)) \quad (2)$$

,ahol a j voxel tartalmazó (vagy ahhoz legközelebb eső) szegmensnek indexe $i(j)$, és $p(j)$ a valószínűségi térkép értéke a j voxelnél. Ha a j voxel az eredményhez adjuk, akkor a hat szomszédos voxelét is meg kell vizsgálni. Ez a módszer lehetővé teszi, hogy a lokális (szegmensekből számított) és a globális (kezdő régióból számított) intenzitás tartomány között mozogjunk. Minél magasabb a $p(j)$, annál jobban hasonlít a lokálisan alkalmazott intenzitás tartomány az adott szegmentumhoz tartozó statisztikához. Ez a megközelítés teszi lehetővé a régió szegmentálását ott, ahol a máj valószínűsége magas, de az intenzitása jelentősen eltér a normál, egészséges májszövetétől (pl. léziók). Ugyanakkor elkerülhetjük a túlszegmentálást is, hiszen az eredmény csak akkor tartalmazza az alacsony valószínűségű voxeleket, ha azok intenzitása nagyon közel áll a normál, egészséges májszövet intenzitásához. (4. ábra)

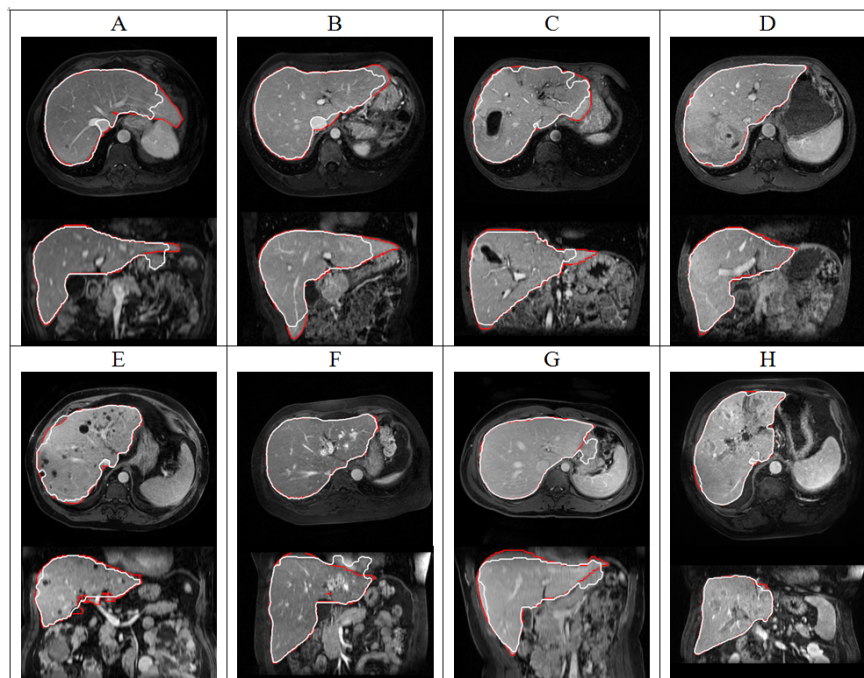
Mivel a régiónöveléshez minden egyes lépésben nagy (5 mm sugarú) környezetet használunk, az eredmény aluszegmentált lesz. Ezt a problémát korrigáljuk egy utólagos, dilatációval (4. ábra). Végül az axiális szeleteken végrehajtott kétdimenziós üregfeltöltést követően a végeredmény a vérereket és a léziókat is tartalmazni fogja. (4. ábra).

3 Eredmények

A kiértékeléshez nyolc májkapueres kontrasztanyag MR LAVA vizsgálatot használtunk. A szeletfelbontás minden esetben 512x512, az átlagos szeletszám 134 (min 91, max 176), az átlagos pixelméret 0,82x0,82 mm² (min 0,7x0,7 mm², max 0,86x0,86 mm²), és az átlagos szeletvastagság 1,7 mm (min 1,3 mm, max 2,2 mm) volt. A vizsgálatok radiológus által kiválasztott jellemző klinikai eseteket reprezentáltak és (lásd 5. ábra) a következő tipikus eseteket tartalmazzák: (A)

egészséges máj felvétel műtermék nélkül; (B) egészséges máj műtermékkel annak bal lebenyénél és az alsó részén; (C) máj nagy hypodens lézióval; (D) a jobb lebeny alulso részében nagy hyperdens léziót tartalmazó máj, (E) sok hypodens cisztát tartalmazó máj, (F) a bal lebenyben néhány hyperdens léziót tartalmazó máj, (G) hyperdens léziós máj és műtermékkel (a szerv határa elmosódott a vese és a gyomor mellett), (H) nagy területen szétterjedt heterogén kóros máj.

Az automatikus szegmentáció eredményét összevetettük a manuális szegmentáció eredményével. Az 5. ábra a szegmens specifikus intenzitás statisztikával készült automatikus szegmentálás eredményét mutatja. A képek alapján az egészséges májszövet túlnyomó része jól szegmentált, még akkor is, ha a kép műterméket (A, F) vagy hypodens léziót (C, D, E) tartalmaz. Látható, hogy az eredmények alig túlszegmentáltak, kivéve az (F) esetben a szívnél vagy az (A, G) esetben a gyomornál, továbbá a legtöbb hypodens lézió nem aluszegmentált. Egyes esetekben azonban a szerv határán (G) a máj aluszegmentált, különösen a bal lebenynél (A, B, C), ahol a valószínűségi modell alacsonyabb értékeket mutat.



5. ábra: Lokális intenzitás statisztikákat felhasználó szegmentáció eredménye a 8 teszt esetben axiális és koronális szeleteken bemutatva. A piros kontúr a manuális szegmentációt, a fehér kontúr az automatikus szegmentáció eredményét jelzi.

Az automatikus szegmentálás kiértékeléséhez a következő metrikákat használtuk:

- Valós pozitív arány (TPR): a valóban pozitívan megítélt voxelek száma osztva a referencia térfogattal, a $TPR=100\%$ azt jelenti, hogy nincs alulszegmentáció.
- Ál pozitív arány (FPR): a hamisan pozitívan megítélt voxelek száma osztva a referencia térfogattal, az $FPR=0\%$ azt jelenti, hogy nincs túlszegmentáció.
- Dice hasonlósági együttható (DSC): a szegmentált és referencia térfogat átfedése osztva a szegmentált és referencia térfogat átlagával, a $DSC=100\%$ azt jelenti, hogy nincs alul-és túlszegmentáció.
- Térfogat átfedési hiba (VOE): a szegmentált és referencia térfogat metszete osztva a szegmentált és referencia térfogat összege kivonva 1-ből, a $VOE=0\%$ azt jelenti, hogy nincs alul-és túlszegmentáció sem.
- Relatív térfogat különbség (RVD): a szegmentált és a referencia térfogat különbsége osztva a referencia térfogattal, a negatív RVD érték alul a pozitív RVD érték túl szegmentációt jelent.
- Átlagos szimmetrikus felület távolság (ASSD): a szegmentált/referencia határ menti minden voxelhez meghatározzuk a referencia/szegmentált határ voxelei közül a legközelebb eső voxel, majd kiszámoljuk az így kapott távolságok átlagát. Az $ASSD=0$ mm azt jelenti, hogy az eredmény tökéletes.
- Maximális szimmetrikus felület távolság (MSSD): a szegmentált/referencia határ menti minden voxelhez meghatározzuk a referencia/szegmentált határ voxelei közül a legközelebb eső voxel, majd kiszámoljuk az így kapott távolságok maximumát. Az $MSSD=0$ mm azt jelenti, hogy az eredmény tökéletes.

1. táblázat: Hibaszámítás a lokális (szegmens specifikus) intenzitás statisztikát alkalmazó szegmentációs módszerrel.


Vizsgálat	TPR	FPR	DSC	VOE	RVD	ASSD	MSSD
A	93.9	1.9	95.9	7.9	-4.2	1.6	47.6
B	86.5	0.6	92.5	14.0	-12.9	2.6	46.4
C	90.1	1.0	94.3	10.9	-8.9	2.1	26.1
D	95.3	3.7	95.7	8.2	-1.0	1.5	27.8
E	85.0	3.4	90.2	17.8	-11.6	3.1	24.6
F	94.1	4.7	94.7	10.1	-1.1	2.8	43.0
G	89.2	4.6	92.0	14.7	-6.2	3.2	32.7
H	95.3	1.1	97.1	5.7	-3.6	0.9	23.9
AVG	91.2	2.6	94.1	11.2	-6.2	2.2	34.0
SD	4.1	1.7	2.3	4.1	4.6	0.8	10.1

2. táblázat: Hibaszámítás globális intenzitás statisztikákat használó szegmentálási módszerrel. Az utolsó két sor, Δ : lokális statisztikát használó módszer és az átlagos különbség, p : az egymintás t -próba tesztjének értéke.

Vizsgálat	TPR	FPR	DSC	VOE	RVD	ASSD	MSSD
A	84.6	3.7	89.9	18.4	-11.7	3.0	33.1
B	66.6	0.1	79.9	33.4	-33.3	5.9	45.9
C	67.1	0.2	80.2	33.1	-32.7	6.5	48.8
D	88.8	2.2	93.0	13.1	-9.0	2.5	39.7
E	77.2	1.2	86.6	23.7	-21.6	4.1	27.6
F	82.3	0.6	90.0	18.1	-17.1	3.8	40.3
G	72.7	2.7	82.9	29.2	-24.6	6.1	30.7
H	87.7	0.5	93.2	12.7	-11.9	2.1	29.2
AVG	78.4	1.4	87.0	22.7	-20.2	4.2	36.9
SD	8.9	1.3	5.4	8.4	9.5	1.7	7.9
Δ	-12.8	-1.2	-7.1	11.6	-14.1	2.0	2.9
p	0.0007	0.0795	0.0024	0.0015	0.0004	0.0032	0.4793

A kiértékelést két különböző módszerrel végeztük el: Az első lokális intenzitás statisztikát (a javasoltak szerint), a második globális intenzitás statisztikát (kizárólag a kezdő régióból számolva) használ. Az 1. és a 2. táblázat mindkét módszer metrikus kiértékelését mutatja. Abban az esetben, ha lokális statisztikákat használunk, a TPR és az FPR értéke nem mutat nagy túl- vagy alul szegmentált régiókat. Az FPR átlagos értéke 2,6% míg a TPR-é 91,2%. A DSC minden esetben 90% felett van, míg a VOE átlagos értéke 11,2%. A negatív RVD azt mutatja, hogy az eredmények alulszegmentáltak, különösen a B és E esetekben. Az ASSD átlagos értéke 2,2 mm, míg az MSSD-é 34 mm, ami nagy felületi távolságot mutat egyes helyeken, mint ahogy az A, B, F eseteknél látható.

A globális statisztikákat használva az értékek némiképp változnak. A VOE és az RVD magasabb, a DSC és TPR alacsonyabb, mialatt az FPR átlagosan közel azonos. A felületi értékek szerint úgy az ASSD, mint az MSSD átlaga magasabb. Az átlagértékek közti különbség (ami a hét értékből ötnél statisztikailag jelentős) azt mutatja, hogy lokális intenzitás statisztikákkal jobb szegmentációt kaphatunk.



6. ábra: Lokális (fehér kontúr) és globális (kék kontúr) statisztákat alkalmazó módszerek szegmentációs eredménye A (bal) és B (jobb) képeken.

4 Konklúzió

Tesztjeink igazolták, hogy a modell alapú máj szegmentáció pontosabb, ha szegmens specifikus statisztikákat használunk. Ha 8 szegmenst használunk az eredmény több olyan heterogén régiót is magában foglal, mint léziók vagy műtermékek. Megjegyezzük, hogy az optimális szegmensszám nem feltétlenül nyolc, amelynek igazolása további kutatást igényel. Továbbá azt is megjegyezzük, hogy a szegmentáció tovább javítható, ha a statisztikai értékeket úgy határozzuk meg, hogy azok folytonos átmenetet képezzenek a szomszédos szegmensek között.

Ebben a cikkben egy olyan szegmentációs módszert mutattunk be, ami 60 kézzel kontúrozott májvizsgálaton alapuló valószínűségi modellt alkalmaz. Fontos megjegyezni, hogy az alulszegmentálás a modell alaki információjának felhasználásával csökkenthető. Bár a bemutatott modell modalitás független, a modellillesztés a LAVA képek egyes tulajdonságait használja ki, amit ki kell különböztetni ahhoz, hogy a szegmentációs módszer más protokollal készült MRI képre is alkalmazható legyen.

A szegmentáció pontosságát különböző standard mérési módszerekkel értékeltük ki, ami lehetőséget adott arra, hogy összehasonlítsuk saját eredményeinket az aktuális CT alapú módszerek eredményeivel. Heimann és társai [11] CT képekhez készült automatizált máj szegmentációs módszereket hasonlítanak össze. A tanulmány alapján az átlagos VOE érték 11,3%, az abszolút átlagos RVD 4,5%, az átlagos ASSD 2,5 mm és az átlagos MSSD 35,5 mm volt a tíz bemutatott módszernél. A bemutatott módszerek értékeivel (11.2%, 6.2%, 2.2 mm, 34.0 mm) összehasonlítva saját eredményeinket, elmondható, hogy az MR modalitáshoz egy versenyképes módszert dolgoztunk ki.

A két módszer futási ideje minden vizsgálat során megegyezett. Az átlagidő Intel Core2Duo 2.1 GHz, és 2 GB RAM teljesítményű gép használatakor 30 sec \pm 8,7 volt, ami a klinikai alkalmazások széles körében elfogadható. Mindent egybevetve egy olyan módszert fejlesztettünk ki, ami automatikusan szegmentálja a májat kontrasztanyagos MR LAVA képeken. Ahhoz, hogy a módszer széleskörű klinikai

felhasználhatóságát bizonyíthassuk, további tesztekre lenne szükség egy nagyobb képi adatbázison.

Referenciák

1. Furukawa, D., Shimizu, A., Kobatake, H.: Segmentation method based on maximum a posterior probability estimation and level set method. In: MICCAI 2007 Workshop Proceedings: 3D Segmentation In The Clinic. (2007) 117–124
2. Rusko, L., Bekes, G., Fidrich, M.: Automatic segmentation of the liver from multi- and single-phase contrast-enhanced CT images. *Medical Image Analysis*, Volume 13, Issue 6, 2009, 871–882
3. Heimann, T., Meinzer, H.P.: Statistical shape models for 3D medical image segmentation: A review. *Medical Image Analysis*, Volume 13, Issue 4, 2009, 543–563
4. Seghers, D.; Loeckx, D.; Maes, F.; Vandermeulen, D.; Suetens, P.: Minimal Shape and Intensity Cost Path Segmentation. *IEEE Transactions on Medical Imaging*, Volume 26, Issue 8, 2007, 1115–1129
5. van Rikxoort, E., Arzhaeva, Y., van Ginneken, B.: Automatic segmentation of the liver in computed tomography scans with voxel classification and atlas matching. In: MICCAI 2007 Workshop Proceedings: 3D Segmentation In The Clinic. (2007) 101–108
6. Kainmuller, D., Lange, T., Lamecker, H.: Shape constrained automatic segmentation of the liver based on a heuristic intensity model. In: MICCAI 2007 Workshop Proceedings: 3D Segmentation In The Clinic. (2007) 117–124
7. Li, H., Elmoataz, A., Fadili, J., Ruan, S.: An improved image segmentation approach based on level set and mathematical morphology. In: *Proc. SPIE Vol. 5286*. (2003) 851–854
8. Farraher, S.W., Jara, H., Chang, K.K., Hou, A., Soto, J.A.: Liver and spleen volumetry with quantitative mr imaging and dual-space clustering segmentation. *Radiology* 237(1) (2005) 322–328)
9. Hermoye, L., Laamari-Azjal, I., Cao, Z., Annet, L., Lerut, J., Dawant, B.M., Beers, B.E.V.: Liver segmentation in living liver transplant donors: Comparison of semiautomatic and manual methods. *Radiology* 234 (2005) 171–178
10. Bismuth, H.: Surgical anatomy and anatomical surgery of the liver. *World Journal of Surgery* 6(1) (1982) 3–9
11. Heimann, T.; van Ginneken, B.; Styner, M.A.; Arzhaeva, Y.; Aurich, V.; Bauer, C.; Beck, A.; Becker, C.; Beichel, R.; Bekes, G.; Bello, F.; Binnig, G.; Bischof, H.; Bornik, A.; Cashman, P.; Ying Chi; Cordova, A.; Dawant, B.M.; Fidrich, M.; Furst, J.D.; Furukawa, D.; Grenacher, L.; Hornegger, J.; Kainmuller, D.; Kitney, R.I.; Kobatake, H.; Lamecker, H.; Lange, T.; Jeongjin Lee; Lennon, B.; Rui Li; Senhu Li; Meinzer, H.-P.; Nemeth, G.; Raicu, D.S.; Rau, A.-M.; van Rikxoort, E.M.; Rousson, M.; Rusko, L.; Saddi, K.A.; Schmidt, G.; Seghers, D.; Shimizu, A.; Slagmolen, P.; Sorantin, E.; Soza, G.; Susomboon, R.; Waite, J.M.; Wimmer, A.; Wolf, I.: Comparison and Evaluation of Methods for Liver Segmentation From CT Datasets. *IEEE Transactions on Medical Imaging*, Volume 28, Issue 8, 2009, 1251–1265