

TDK Dolgozat

Emri Balázs

Tojások CT és MR felvételeinek szegmentálása invariáns momentumokkal a fajtanemesítés támogatására

Debreceni Egyetem Informatika Kar, Komputergrafika és Képfeldolgozás Tanszék

Emri Balázs
Programtervező Informatikus hallgató IV.

Témavezető: Kovács György
Egyetemi tanársegéd

Informatika Tudományi Szekció

Tartalomjegyzék

Bevezetés	4
A képfeldolgozás napjainkban	4
MR és CT képek sajátosságai	4
MR	4
CT	5
Előzmény: képfeldolgozással támogatott fajtanemesítés	6
Célkitűzés	6
Módszer	8
A tojások szeparálása	8
Kézzel készített maszkok gyártása a tanuló-adatbázis felépítéséhez	8
Az openIp képfeldolgozó programcsomag és a mögötte húzódo metodika	9
openIp	9
Statistikai és diszkretizáló módszerek	9
Invariáns momentumok 2D	11
Invariáns momentumok 3D	12
Validálás	13
Eredmények	14
MR eredmények	14
CT eredmények	16
MR és CT képek sárgája-fehérje probléma konklúzió	16
Alkalmazás	17
Orvosi alkalmazás	17
További alkalmazások	17
Köszönetnyilvánítás	18
Mellékletek	18
BrainMOD	18
openIp	19
Irodalomjegyzék	20

Bevezetés

A képfeldolgozás napjainkban

A digitális képfeldolgozás az elmúlt évtizedek során az informatika egyik legintenzívebben kutatott területévé vált, mivel az orvosi és ipari alkalmazások egyre nagyobb mértékben igénylik a korszerű matematikai eszközökre épülő eljárások kidolgozását, használatát. A képfeldolgozáson belül fontos terület a képek szegmentációja, amivel a primer képi információ osztályozott képtartalomra bontható, azaz az egyes problémák szempontjából fontos dolgok elkülöníthetők a kevésbé érdekes részletektől. A zajjal terhelt képek esetében a statisztikai eszközök használata két-, illetve háromdimenziós képek szegmentálására nagyon hatékony eszközöket biztosít, mivel együtt látja el a zajszűrés és az osztályozás feladatát. A statisztikai módszerek alkalmazása előtt azonban a problémák redukciójára van szükség, azaz az egyes képekből, képrészekből azokat jól leíró, alacsony dimenziójú, ún. sajátosság vektorokat kell kinyerni. Nagyon gyakran csak az intenzitást használják ilyen célra, azonban számtalan különböző sajátosság származtatható az egyes képelemek környezetében elhelyezkedő intenzitásértékekből, így nehéz feladat kiválasztani azokat, amelyek a legjobban képesek reprezentálni egy képet vagy képrészletet.


A kutató munka során forgatás, eltolás és skálázás invarianciát biztosító sajátosságok használatának hatékonyságát vizsgáltuk meg háromdimenziós, tojások CT és MR felvételeinek automatikus szegmentációjára. A sajátosságok felhasználásával számos különböző statisztikai tanuló algoritmust teszteltünk. A tesztek során kézzel szegmentált képi adatbázist használtunk referencia anyagként. Az eredmények alapján kijelenthetjük, hogy az invariáns momentumok használata jobb szegmentációt eredményez a tojásokat tartalmazó CT és MR képeken, mint az intenzitásök önálló használata, így a javasolt módszer, azaz a sajátosságok és a statisztikai modell együttes alkalmazása megoldást ad a tojások fehérje- és sárgája térfogatok meghatározására, akár nagyobb adathalmazon is. Kutatási eredményeink lehetőséget teremtenek arra, hogy a későbbiek során bekapcsolódhatunk komolyabb volumenű, hazai vagy nemzetközi fajtanemesítési projektekbe ill. az ezekhez kapcsolódó pályázatokba ipari fejlesztésekbe.

MR és CT képek sajátosságai

MR

A mágneses rezonancián alapuló képalkotás (MRI) az 1970-es évek végétől vált a képi diagnosztika egyik fontos eszközévé, működési elve a proton NMR (Nuclear magnetic resonance) alapú jelfeldolgozás. Az MRI látóterében elhelyezett objektum vagy testrészek atommagjaiban az erős mágneses tértől függő frekvenciájú elektromágneses hullám energiája nyelődik el, majd a kötési helyzetének (és ezen keresztül az anyagi szerkezetnek) megfelelő, azonos vagy kissé eltérő


frekvenciájú jelet sugároz, amelynek időbeli változása is a kötési tulajdonságaitól függ. Ennek megfelelően az NMR egy kiváló analitikai módszer, ahol a kapott válaszjel spektrumának elemzésével az anyagminta összetételére lehet következtetni. Az MR felvételeken a lágy részek, esetünkben a tojás sárgája- és fehérjerésze kiválóan elkülönülnek, azonban a fehérje körbehatárolása nehezebb feladatnak bizonyul.[1.]



1. ábra - Tojásról készült MR felvétel

CT

A CT (computer tomográfia) röntgensugárzás alkalmazásán alapuló, digitális-számítógépes adatfeldolgozású, keresztmetszeti vizsgálómódszer. A képalkotáshoz a röntgensugarat kibocsátó röntgenső és a vele szemben lévő érzékelő detektorok rendszere a vizsgálandó test kiválasztott szelete körül 180° -ot körbefordul, miközben az egyes irányokhoz rögzített vetületi képet tárolják. E vetületi képsorozatból szűrt visszavetítéssel vagy iteratív képrekonstrukciós módszerrel állítják elő a metszeti képeket. A CT felvételeken – röntgensugárzás elnyelési tulajdonságai miatt - a nagyobb sűrűségű részek (csont, ízület) markánsan elkülönülnek a lágy részeketől, ami miatt a CT az egyik fontos orvosi és ipari vizsgálóeszközzé vált. Esetünkben tehát a tojások héja lesz könnyen körülhatárolható, így a fehérjét tudjuk lokalizálni a képen könnyebben. A fehérje és sárgája határa azonban a CT felvételeken nehezebben meghatározható a közel azonos anyagsűrűség miatt.[2.]



2. ábra - Tojásról készült CT felvétel

Előzmény: képfeldolgozással támogatott fajtanemesítés

Ebben a fejezetben a pályamunkát illető kaposvári projektről esik szó. A Kaposvári Egyetem Egészségügyi Centrumának és a DEOEC Nukleáris Medicina Intézet (NMI) munkatársai a tojásokról készült CT és MR felvételekből kinyert fehérje/sárgája arány meghatározására speciális, elsősorban az orvosi képfeldolgozáshoz használt szoftvereket alkalmazták. A kutatás során azt vizsgálták, hogy a tojások fehérje- és sárgájatömegének meghatározásával nyert információból milyen mértékben lehet következtetni bizonyos tyúkfajok termékenységre. A projektbe, melybe bekapcsolódtunk, 90 darab tojásról készítették CT és MR felvételeket, majd kézzel is megmérték ezen tojások sárgája- és fehérjetömegét, hogy referencia adatokat szolgáltatassanak a képfeldolgozás által kapott eredmények validálásához, azt remélve, hogy olyan automatizált rendszert sikerül kifejlesztünk, amellyel később nagyobb adathalmazt (1800 db tojásról készült felvétel) lesznek képesek feldolgozni kis hibaszázalékkal. Az első szegmentációs eredmények nem adtak megfelelő eredményt a kézi és a szoftveres tömegmeghatározás összehasonlítása során, így a szegmentációs eljárás további finomítására volt szükség. Ezt a fejlesztést az NMI munkatársai nem tudták elvégezni, így a problémával megkeresték a DE Informatika Karának Komputergrafika és Képfeldolgozás Tanszékét, azaz kialakult egy olyan együttműködés, amely a szegmentációs módszerek orvosi- és ipari alkalmazásának fontos kiindulópontja lehet.


A dolgozatban bemutatott eredményeket a Kaposvári Egyetem munkatársai egy tudományos cikkben teszik majd közzé, így a pályamunka kiváló eszköz arra, hogy a fent említett három intézet hatékony kooperációját bemutassa és a további együttműködés lehetőségét biztosítsa.

Célkitűzés

Célunk egy olyan szoftverrendszer kialakítása volt, amely biztosítja a tojások fehérje- és sárgájatömegének automatikus meghatározását a tojásokról készült CT- és MRI-felvételek szegmentációja alapján. A feladatot négy részfeladatra bontottuk:

1. Szortírozás és számozás: a dobozban vagy tartóban tárolt tojásokról készült CT- és MR képek feldarabolása olyan képekre, amelyek csak egy tojást tartalmaznak olyan módon, hogy az egyedi tojás-képek sorszáma megegyezzen a kísérletben használt tojás-számmal.
2. Referencia adatbázis készítése: a képi szegmentumok manuálisan történő kijelölése 4-4 darab felvételen a tanuló adatbázis elkészítéséhez.
3. Analízis: az egyedi tojás-felvételek szegmentációja, a fehérje- és sárgája tömegarány meghatározása.
4. Ellenőrzés, validálás: a számolt és mért adatok összehasonlítása.

A gyakorlati alkalmazás kényelmesebbé tétele mellett célunk volt a kétdimenziós képeken alkalmazott szegmentációs eljárások kipróbálása háromdimenziós felvételeken is, nagy hangsúlyt fektetve az invariáns momentumok használatára.



3. ábra - A folyamatot ábrázoló diagram, ami szemlélteti a három résztvevő intézet szerepvállalását

Módszer

A kapott felvételek olyan tojásokról készültek, melyeknek sárgája- és fehérjetömegét feltörés után megmérték. Ezek a mérések kézi mérések, tehát a pontosságuk megkérdőjelezhető, valamint volt olyan tojás, melynek feltörésekor a sárgája megsérült, így arról a tojásról nem született használható, kézzel mért információ. A mérési adatokat szöveges fájlokban rögzítették és elküldték nekünk a képekkel együtt, az intézeti szerverre.

A tojások szeparálása

A tojások egyesével történő szétválasztásához egy címkéző algoritmust kellett implementálni. A Hoshen-Kopelman algoritmusra[3.] esett a választás, melyet felkészítettünk háromdimenziós képek klaszterezésére. Az algoritmus inputja az eredeti, címkézendő kép, az output pedig egy egész intenzitás értékeket tartalmazó ún. labelmap. A módszer a képen két adott intenzitásérték közötti voxeleket megtartja, majd a különálló klasztereket felcímkézi.

Az algoritmusra támaszkodva implementáltunk egy, a problémát kielégítő célalkalmazást (EggSort). A tojások esetében a két intenzitás küszöbérték meghatározása nem volt kritikus, mivel a tojástartó anyaga általában kis intenzitással jelenik meg az MR és a CT felvételeken, így az alsó küszöböt megemelve megfelelően különváltak a tojások. A felcímkézést a Kaposvári Egyetem munkatársai által megadott sorrendben végeztük, majd minden tojástartót szeparált képfájlokba mentettünk, a címkéjük azonosítóját használva névnek. Így eljutottunk ahhoz a lépéshez, ahol a kapott tojásaink a számozásnak megfelelően külön lettek választva, tehát az egyes tojásokból később szegmentációval kinyert térfogatértékeket párosítani tudtuk a kapott kézi mérések tömegértékeivel.




4. ábra - 10 tojástartót tartalmazó tartóról készült MR kép és a hozzá tartozó labelmap

Kézzel készített maszkok gyártása a tanuló-adatbázis felépítéséhez

Mivel a szegmentáló programcsomagunk egy tanuló adatbázist használ a probléma, jelen esetben a tojás fehérje-, sárgájárész határainak meghatározásához, ezért el kellett készítenünk ezt az adatbázist mind az MR, mind a CT felvételek esetében. Ehhez a Nukleáris Medicina által fejlesztett BrainMOD (Melléklet 1) multimodális képfeldolgozó programot használtuk. A

tojások képein szeletenként körberajzoltuk a fehérje és sárgája részt a programba beépített ROI (Range of Interest) eszköztár segítségével, majd a körberajzolt részekből az intézet könyvtári függvényeinek használatával készítettünk egy-egy összeillesztett három dimenziós maszkot. Ezek a maszkok 3 intenzitás értéket tartalmaznak: 0-háttér, 1-fehérje, 2-sárgája. A későbbiekben bemutatott szegmentáló algoritmusok ebből a tanulóadatbázisból nyernek információt a feladat elvégzéséhez.



5. ábra - Balról jobbra: kézzel szegmentált maszk, eredeti CT kép, a két kép fúziója

Az openIp képfeldolgozó programcsomag és a mögötte húzódo metodika

openIp

A Debreceni Egyetem Informatika Kar, Komputergrafika és Képfeldolgozás Tanszékén fejlesztett openIP (Melléklet 2) programcsomagot használtuk a képek feldolgozására. Az openIP egy C++ nyelvű könyvtárarkból és célalkalmazásokból álló programcsomag, amely kutatási, oktatási és ipari célok kielégítésére alkalmas képfeldolgozó eszközöket biztosít. Fejlesztésének célja a kereskedelmi és akadémiai képfeldolgozó rendszerek közti szakadék áthidalása volt.

Statisztikai és diszkretizáló módszerek

Diszkrét, hisztogram alapú szegmentációs eszközöket választottunk, Bayes-döntési szabállyal, mivel a mintavektorok száma nagy, Support Vector Machine esetén a modell illesztés az ismételt tanítási lépések miatt nagyon lassú lenne, Neurális hálók alkalmazása számos további paramétert hoz be, amelyek tovább növelik a modell illesztés idejét. Döntési fák és random forest-ek alkalmazása nagy mintaszám esetén megint csak lassú, hiszen n minta esetén a k -dik fa elágazás

meghatározásához nagyságrendileg $\frac{n}{\log_2(k)}$ entrópiát kell kiszámítani. A statisztikai módszerek közül az egyszerű, naiv Bayes-megközelítést és az Averaged One Dependence Estimator-t alkalmaztuk.

Mindkét módszerhez diszkrétizálni kell az adat vektorokat:

- Equal width discretization: minden egyes feature koordinátára a $\min$ és $\max$ értékek meghatározásra kerülnek, és D diszkrét kategória esetén a k . kategória a

$$\frac{i \cdot (\max - \min)}{D} \text{ és } \frac{(i-1) \cdot (\max - \min)}{D} \text{ közé eső értékeket tartalmazza.}$$

- Equal frequency discretization: minden egyes feature koordináta értékei nagyság szerinti növekvő sorrendbe rendezzük, majd ezt a sorozatot felosztjuk D diszkrét részre, így diszkrétizáljuk a koordinátákat.

A naiv diszkrét Bayes osztályozáshoz a tanító halmaz minden koordinátájának kiszámítjuk a hisztogramját, majd normalizáljuk azt (osztjuk az összes tanító elem számával). Ezt követően a döntési szabály a következő módon alakul:

$$\arg \max_i \left(\prod_j P(x_j | y_i) \right),$$

azaz azt az osztálycímkét választjuk, amelyre az attribútum értékekhez tartozó feltételes valószínűségek szorzata a legnagyobb. A döntési szabály "naivitása" arra utal, hogy a koordináták között függetlenséget feltételez.

Az Averaged One-Dependence[4.] classifier még mindig kezelhető idő és tárkapacitással dolgozó osztályozó, működése a Bayes-tétel kifejtésén két feature koordináta szerinti kifejtésén alapul. Döntési szabály:

$$\arg \max_i \left(\sum_{i: 1 \leq i \leq n} \hat{P}(y_i, x_i) \prod_j \hat{P}(x_j | y_i, x_i) \right),$$

azaz azt az y osztálycímkét választjuk, amelyre a feltételes valószínűségek szorzata a legnagyobb.

A modell illesztés esetünkben tehát az ismeretett két osztályozó és két diszkrétizáló módszer kombinációinak kipróbálását takarja, grid-search eljárást alkalmazva a diszkrétizálás kategóriáinak számán (4-16), az előálló statisztikai modell validációja k-fold cross validation eljárással történik.

Invariáns momentumok 2D

Mivel ez a rendszer nyílt forráskódú, ezért lehetőségem volt implementálni új sajátságokat, melyek alkalmazása valószínűleg megoldást nyújthat a tojás problémára. Ezek forgatás, skálázás és mozgás invariáns momentumok, melyek már implementálva voltak kétdimenziós esetre. Feladatom a fejlesztés ezen szakaszában a 2D sajátságok adaptálása volt 3D-re.

Az invariáns momentumok háromdimenzióban értelmezhető definíciójához előbb meg kell ismernünk a kétdimenziós, alapértelmezett definíciókat[5].

- “Raw image moment”, azaz a nyers képmomentumot a következőképp kapjuk meg:

$$M_{ij} = \sum_x \sum_y x^i y^j I(x, y),$$

ahol $I(x, y)$ az x és y koordinátákhoz tartozó intenzitás érték.

- “Central moment”, azaz a központi momentum definíciója, ha $f(x, y)$ egy digitális kép:

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q f(x, y),$$

$$\text{ahol } \bar{x} = \frac{M_{10}}{M_{00}} \text{ és } \bar{y} = \frac{M_{01}}{M_{00}}$$

- Skálázás invariáns momentum:

$$\eta_{ij} = \frac{\mu_{ij}}{\mu_{00}^{(1+\frac{i+j}{2})}}$$

Ezen definíciók alapján határozhatóak meg az n -ed rendű kétdimenziós skálázás, forgatás és mozgás invariáns képmomentumok. A szegmentáció céljára az első és másodrendű momentumot találtuk használhatónak:

$$I_1 = \eta_{20} + \eta_{02},$$

$$I_2 = (\eta_{20} - \eta_{02})^2 + (2\eta_{11})^2$$

Invariáns momentumok 3D

A háromdimenziós adaptációban a következőkép alakultak a definíciók, a harmadik koordináta bevezetése miatt:

- “Raw image moment” 3D:

$$M_{ijk} = \sum_x \sum_y \sum_z x^i y^j z^k I(x, y, z),$$

ahol $I(x, y, z)$ az x , y és z koordinátákhoz tartozó intenzitás érték.

- “Central moment” 3D, feltéve, hogy $f(x, y, z)$ egy háromdimenziós digitális kép:

$$\mu_{pqr} = \sum_x \sum_y \sum_z (x - \bar{x})^p (y - \bar{y})^q (z - \bar{z})^r f(x, y, z),$$

$$\text{ahol } \bar{x} = \frac{M_{100}}{M_{000}} \text{ és } \bar{y} = \frac{M_{010}}{M_{000}}, \text{ valamint } \bar{z} = \frac{M_{001}}{M_{000}}$$

- Skálázás invariáns momentum:

$$\eta_{ijk} = \frac{\mu_{ijk}}{\mu_{000}^{(1+\frac{i+j+k}{3})}}$$

Ezen változások tükrében az első és másodrendű momentum már kiszámolható[6.]:

$$I_1 = (\eta_{200} + \eta_{020} + \eta_{002})/\eta_{000}^2,$$


$$I_2 = (\eta_{200}^2 + \eta_{020}^2 + \eta_{002}^2 + 2\eta_{110}^2 + 2\eta_{101}^2 + 2\eta_{011}^2)/\eta_{000}^4$$

Ezeztől a sajátságoktól reméljük, hogy a tojások sárgája- és fehérje részének elkülönítésében nagy hasznunkra fognak válni.

Validálás

A validálási folyamat során a 90 szegmentált maszk érvényességét vizsgáltuk. Amint elkészültek a szegmentált maszkok, le kellett ellenőriznünk, hogy mennyire hasonlítanak a kézzel készített tanulóadatbázisban szereplő képekhez, ezt egy összetevő alkalmazással vizsgáltuk, amely százalékban megadja az egyezést a program által, és a kézzel szegmentált kép között. Mivel nem minden képhez készült kézzel körberajzolt maszk, ezért ez csak egy hozzávetőleges érték, ami igazából a nagyon nagy eltérést hivatott kiszűrni.

A pontosabb validálást a kézzel mért tömegértékek és a maszkokból kinyert térfogatértékek összevetése szolgáltatta. A térfogatértéket egyszerű volt kinyerni a maszkokból, mivel csak össze kellett számolni a fehérjét és sárgáját jelölő voxeleket, majd meg kellett szorozni a voxeltér-fogattal, amely ezen képek esetében 1x1x1 mm volt. A térfogatértékeket és a tömegértékeket ugyanebben a C++-os programban két vektorba rendeztük, majd korreláció vizsgálatot végeztünk rajtuk. Ezt azért tehetjük meg, mert a tojások számozása miatt a térfogat- és a tömegértékek párosíthatóvá váltak. A korreláció vizsgálat szemléltetésére a projekt elején, a küszöböléssel szegmentált eredményekből és a kézzel mért értékekből sűrűséggörbét készítettünk.



6. ábra - Látható, hogy a korreláció érték igen alacsony, valamint a sűrűséggörbe sem mutat egyenletességet, tehát a küszöbölési módszer nem állja meg a helyét a “tojásprobléma” megoldásakor

Kidolgoztunk egy harmadik validációs módszert, amely lecsökkenti a kézi mérésekben előforduló esetleges hibák mellékhatásait. Először az első 20 tojásból készült maszkból kinyert térfogatérték és az ezekhez tartozó tömegértékek segítségével meghatároztunk egy átlagsűrűséget. Ennek a segítségével minden egyes maszk térfogatértékének és ezen átlagsűrűségnek a segítségével kiszámoltuk a maszkokhoz tartozó tömegértékeket. Minden egyes tojáshoz rendeltünk egy 0 és 1 közötti számot a következő képlet alapján:


$$\min(m_k, m_{sz}) / \max(m_k, m_{sz}),$$

ahol m_k a tojás kézzel mért tömege, m_{sz} pedig az átlagsűrűség által meghatározott tömege.

Ezen számértékek átlaga megadja, hogy mennyire pontos a szegmentáció.

Eredmények

A szegmentáció elkezdése előtt úgy tűnhet, hogy az MR képek sokkal jobban alkalmasak a fehérje- és sárgája rész különválasztására, mivel a CT felvételeken nehéz eltalálni azt a kis intenzitás-intervallumot, melyben a sárgája észlelhető.



7. ábra - A képen szembevető a különbség, a sárgája- és fehérjerész elkülönítése az MR kép esetében egyszerűbb feladatnak tűnik

MR eredmények


Az MR felvételek szegmentálása és a validáció elvégzése után, a következő feature-kombináció bizonyult a leghatékonyabbnak:

1. IdenticalTransform (identikus transzformáció) feature
2. InvariantHuMoment1 feature (elsőrendű invariáns momentum), 10 voxel sugarú gömb környezetben vizsgálva

Eredmények:

1. Tojássárgája tömeg(kézi) és térfogat(gépi) értékek korrelációja: 0.75

2. Tojásfehérje tömeg és térfogat értékek korrelációja: 0.40
3. Fehérje hibaérték: 6.33%
4. Sárgája hibaérték: 4%



8. ábra - Invariáns momentumokkal szegmentált maszk és az eredeti MR felvétel összevetése

Megjegyzés:

A fenti szegmentációt ugyanazokra a képekre, az invariáns momentum használata nélkül a következő értékeket kaptuk:

1. Tojássárgája tömeg(kézi) és térfogat(gépi) értékek korrelációja: 0.13
2. Tojásfehérje tömeg és térfogat értékek korrelációja: 0.30
3. Fehérje hibaérték: 7.5%
4. Sárgája hibaérték: 70%

Ebből tisztán látszik, hogy az invariáns momentum elhagyása nagy mértékben rontotta az eredményeket, valamint szembetűnő lehet, hogy a korreláció-értékek a fehérje esetében alacsonyak, habár szemmel láthatóan (7. ábra) kielégítő a fehérje körülrajzolása és elválasztása a tojássárgájától. Ezt valószínűleg a validációs technika kézi mérések pontosságától való függősége okozza. Ezért vesszük figyelembe súlyozottabban inkább a hibaértéket, mivel az kiküszöböli a kézi mérések esetleges (elég gyakori) hibáit.

CT eredmények

Az CT felvételek szegmentálása és a validáció elvégzése után, a következő feature-kombináció bizonyult a leghatékonyabbnak:

1. IdenticalTransform feature
2. Variance (variancia) feature 6 voxel sugarú gömbbre nézve
3. StandardDeviation (szórás) feature $r=6$ végső konklúzió, összeredmény, értékelés
4. InvariantHuMoment1 feature $r=6$
5. InvariantHuMoment2 (másodrendű invariáns momentum) feature $r=6$

Eredmények:

1. Tojássárgája tömeg(kézi) és térfogat(gépi) értékek korrelációja: 0,63
2. Tojásfehérje tömeg és térfogat értékek korrelációja: 0.86
3. Fehérje hibaérték: 2.5%
4. Sárgája hibaérték: 6.83%


MR és CT képek sárgája-fehérje probléma konklúzió

A kezdeti feltevés, miszerint a CT és MR képek szegmentálásakor a képalkotó eljárások sajátosságai miatt a sárgája és fehérje elkülönítése nehezebb lesz CT felvételek esetében, hamisnak bizonyult. A használt eltolás, skálázás és forgatás invariáns képmomentumok segítségével hasonló eredményeket értünk el mindkét képalkotó módszerrel készült felvételeken. Habár az eredmények pontosságán még van mit csiszolni, az invariáns momentumok árnyaltabb használata valószínűleg pozitív irányba fogja mozdítani a mutatókat.

Alkalmazás

Orvosi alkalmazás

A címkéző algoritmust fMRI (funkcionális MRI) felvételek feldolgozására is használtuk az intézetben belül, továbbá egy 2011. júliusában közzétett cikk[7.] megírásához szükséges adatok előállításához is alkalmaztuk.



10. ábra - Balról jobbra: Szógenerálás közben készült fMRI felvétel, és a vizsgálat szempontjából lényeges klaszter, valamint az összefűzionált kép

A kidolgozott szegmentációs eljárásokat – megfelelő átalakítás után - alkalmazni kívánjuk patológiás MRI felvételeken tumor szegmentációra, kisállat PET és MRI felvételeken szervi és agyi régiók szegmentációjára, fMRI felvételek automatizált feldolgozására, kinetikai PET mérések és képrekonstrukciós folyamatok optimalizálására.

További alkalmazások

A Kaposvári Egyetem munkatársai több olyan projekten is dolgoznak, amelyekben szükség van speciális képfeldolgozási feladatok megoldására. Pl. hús-zsír arány meghatározása sertés felvételeken. E projektek jelenleg, pályázati finanszírozás hiányában állnak, vagy lassan haladnak. Reményeink szerint ezen munka során kialakított kapcsolat lehetőséget teremt majd közös pályázati részvételre.

Köszönetnyilvánítás

A dolgozat mellett, hogy egy összetett képfeldolgozó programcsomagot és egy agráripari alkalmazási területet mutat be, reprezentál egy kialakult kapcsolatrendszert is. Ez a rendszer a Debreceni Egyetem Informatika Karának Komputergrafika és Képfeldolgozás Tanszéke, a Kaposvári Egyetem és a Debreceni Egyetem Orvos- és Egészségtudományi Centrumának Nukleáris Medicina Intézetének alkalmazottjai között jött létre.

Kovács György, egyetemi tanársegéd (DE-IK) és ezen TDK pályamunka témavezetője ajánlotta fel az általa fejlesztett, a dolgozatban bemutatott openIP képfeldolgozó programcsomag használatát.

A Kaposvári Egyetem munkatársai, Dr. Donkó Tamás intézeti mérnök és Dr. Milisits Gábor tudományos főmunkatárs biztosították a képanyagot és az ahhoz tartozó kézi mérések eredményeit tartalmazó dokumentumokat.


A szegmentáció és az eredmények összesítése, validálása pedig a DEOEC Nukleáris Medicina Intézetében valósult meg, Dr. Opposits Gábor, Dr. Kis Sándor Attila és Dr. Emri Miklós segítségével.

Ezúton szeretnék köszönetet mondani a fent említett személyeknek a segítségükért.

Mellékletek

BrainMOD

A BrainMOD[8.] program segítségével, szeletenként haladva kézzel lettek körülrajzolva a szegmentálandó területek.



11. ábra - A BrainMOD használatával készültek a kézzel szegmentált maszkok

openIP

Az openIP[9.] programcsomagot a Debreceni Egyetem Informatika Kar, Komputergrafika és Képfeldolgozás Tanszékének munkatársai fejlesztették.

Hat különböző könyvtárból, valamint számos alkalmazásból áll.

A könyvtárak a következők:

1. openipDS: a képfeldolgozáshoz használt struktúrákat valósítja meg, a lehető leghatékonyabb implementációkat használva
2. openipIO: a különböző két- és háromdimenziós képfájlformátumokhoz biztosít interfészeket
3. openipSC: a GNU Scientific Library-tól való függést oldja fel, a könnyebb telepítés és hordozhatóság elérésének érdekében
4. openipLL: alacsony szintű képfeldolgozó módszereket implementál az openipDS és openipSC könyvtárak segítségével
5. openipML: machine learning-et biztosító könyvtár, mely többek közt lehetővé teszi a tanulóadatbázisokból való információnyerést és a rejtett Markov-mezők használatát
6. openipVS: az egyetlen 3rd party függőséget mutató könyvtár a rendszerben, amely a Qt4[10.] keretrendszerrel függ. Ez a könyvtár biztosítja a képek vizualizációját.

Az openIP a könyvtárain kívül számos alkalmazást is biztosít, melyeknek paraméterezése rugalmasan teszi lehetővé, hogy a módszereinket könnyedén kombinálhassuk. Az alkalmazások, melyeket a munkánk során használtunk:

- -featureExtractor: az egyik inputjaként megadott sajátsgleíró fájl alapján nyer ki sajátsgvektorokat az outputként megadott fájlba, a kézzel előállított tanulóadatbázisból szerzett információ alapján, felhasználva az openipML által biztosított gépi tanulás módszereit.
- -gridSearch: a featureExtractor alkalmazás által előállított output fájlt felhasználva készít egy "best-model.dat" fájlt
- -segment: a gridSearch outputjaként létrejött best-model.dat fájlban tárolt információk segítségével szegmentálja az input fájlt, a maszkot pedig egy outputként megadott fájlba menti. Fontos megemlíteni, hogy az alkalmazás képes a .mnc kiterjesztésű Minc (Medical Imaging NetCDF extension) típusú háromdimenziós képek használatára az openipIO könyvtár által implementált mnc-interfész segítségével.

Mivel az openIP programcsomag által biztosított alkalmazások jól láthatóan egymásra épülnek, paraméterezésük és a használni kívánt sajátságokat és azok paramétereit tartalmazó fdf fájlok létrehozása egy jól megírt script segítségével rengeteg kombinációját alkalmazhatjuk, a használni kívánt módszereknek és sajátságoknak.

Irodalomjegyzék

- [1.]MRI:forradalmi változás az orvosi képi diagnosztikában; Martos János és Zaránd Pál (1999.)
- [2.]3D képalkotó eljárások alkalmazása kutyák emlődaganatainak vizsgálatában; Dr. Garamvölgyi Rita (2007.)
- [3.]<http://www.ocf.berkeley.edu/~fricke/projects/hoshenkoveman/hoshenkoveman.html>
- [4.]Not so naive Bayes: Aggregating one-dependence estimators; Geoffrey I. Webb, Janice R. Boughton, Zhihai Wang
- [5.]http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/SHUTLER3/CVonline_moments.html
- [6.]<http://zoi.utia.cas.cz/3DRotationInvariants>
- [7.]<http://www.springerlink.com/content/m4567h3078v5358h/>
- [8.]<http://minipetct.com>
- [9.]The openIP open source image processing library; György Kovács, János István Iván, Árpád Panyik, Attila Fazekas
- [10.]<http://qt.nokia.com/products/>