

# Képmínőségmérés tüdő CT felvételeken

Bognár Gergő

Eötvös Loránd Tudományegyetem, Informatikai Kar, Numerikus Analízis Tanszék  
bognargergo@caesar.elte.hu

**Absztrakt.** Az alacsony dózisu tüdő CT felvételek alkalmazása egyre elterjedtebbek a tüdőszűrés során. A csökkentett sugárdózis előnyös klinikai tulajdonságai mellett a képmínőség romlásához vezet. Jelen cikkben egy referenciakép nélküli képmínőségmérő eljárást mutatok be, amely objektívan méri a CT képek minőségét. A módszer intenzitás szerinti szegmentáláson alapul, kifejlesztését és tesztelését valós, alacsony és magas dózisu felvételekkel, valamint egy konstruált tüdő-fantom és zajmodellezés segítségével szintetizált képekkel végeztem.

## 1. Bevezetés

A komputertomográfia alkalmazása során orvosi szempontból a legkomolyabb problémát a páciensre érő sugárterhelés jelenti. Napjainkban egyre elterjedtebb, elsősorban tüdő CT felvételek készítésekor, az alacsony sugárdózis használata. A dózis redukálása a páciensre érő sugárterhelést ugyan csökkenti, de a felvétel képmínőségének romlásához, a kép zaj felerősödéséhez vezet, emiatt az orvosi diagnosztikai felhasználás során nehezebben azonosíthatók az egyes anatómiai képletek. Munkám motivációjául ezen alacsony dózisu CT felvételek minőségének elemzése szolgált: olyan objektív mérőszámot kerestem, amely jól jellemzi az alacsony dózisu CT képek minőségét. A kifejlesztett és bemutatásra kerülő képmínőségmérő eljárás szimulált környezetben és valós CT felvételek esetén is megbízhatóan határozza meg a felvételek minőségét. Az eljárás kidolgozásához a PET Pozitron-Diagnosztika Központ felvételeit használtam, de a módszert teszteltem az ELCAP [9] alacsony dózisu, és a Lung Image Database Consortium [1] magas dózisu tüdőfelvételeit tartalmazó adatbázisain. A szimulációk futtatását MATLAB környezetben végeztem.

A tomográfias képalkotás során a röntgensugaraknak a vizsgált test anyagában történő elnyelődése a Beer-Lambert-törvény segítségével írható le:

$$I = I_0 \exp\left(-\int_L \mu\right), \quad (1)$$

ahol  $I_0$  a forrás röntgensugár intenzitása,  $I$  a detektor által mérhető intenzitás,  $L$  a sugár által megtett út,  $\mu$  a helytől függő, a test anyagára jellemző lineáris elnyelési együttható. A CT felvétel rögzítése során keletkező szinogram a lineáris elnyelési együtthatók adott irányok szerint vett Radon-transzformáltja, amiből rekonstruálható a helytől függő elnyelési együttható a Radon-transzformáció

diszkrét invertálásával, szűrt visszavetítéssel, vagy iteratív rekonstrukciós módszerek segítségével. Mivel a lineáris elnyelési együttható energiafüggő, így a CT felvételeken a víz elnyelési együtthatójával normált ún. HU (*Hounsfield Unit*) értékek kerülnek megjelenítésre:

$$\text{HU} = 1000 \cdot \frac{\mu - \mu_{\text{H}_2\text{O}}}{\mu_{\text{H}_2\text{O}}}. \quad (2)$$

A röntgenfotonok elnyelődése és szóródása mellett a képrögzítés során a felvételen megjelenő zaj két fő összetevője az elektromos eszközök zaja és a fény természetéből adódó kvantumzaj. Előbbi képfüggetlen, additív, fehér Gauss-zajként, utóbbi képfüggő Poisson-zajként modellezhető. A rekonstrukció során a diszkrétizációból származóan további kvantálási zaj rakódhat a képre.


A képminőségmérés általános célkitűzése a vizuális tartalom minőségének jellemzése az emberi érzékelésnek megfelelően, automatikus mérési módszerek, ún. *képminőséget mérő metrikák* segítségével. Ezen metrikák a vizsgált kép minőségét egy objektív mérőszám segítségével határozzák meg [7]. A kép jellegétől függően a metrikák többféle megközelítéssel alapulhatnak: az emberi látórendszer modellezésén, vagy a kép adott minőségbeli jellemzőinek elemzésén, a képtípusra jellemző torzulások (zaj, elmosódás, intenzitásváltozás, stb.) vizsgálatán. A gyakorlatban elterjedt módszerek legtöbbje a képminőség meghatározásához felhasználja a vizsgált kép egy jó minőségű, torzítatlan változatát, az ún. referenciaképet. Ezek közül a legismertebbek a referencia- és a vizsgált kép közötti hiba mérésén alapuló MSE (*mean-squared error*) és SNR (*signal-to-noise ratio*), a strukturális hasonlóságot vizsgáló SSIM (*structural similarity*) [13] valamint a természetes képek elemzésén alapuló VIF (*visual information fidelity*) [10] metrikák. Ezen módszerek azonban nem alkalmazhatók közvetlenül CT felvételek esetén, mivel az alacsony dózisu felvétel mellett jellemzően nem áll rendelkezésre magas dózisu, jó minőségű változat.<sup>1</sup> Az ismert referenciakép nélküli metrikák közül a természetes képek modellezésén alapuló módszerek nem alkalmazhatóak CT felvételekre, mivel ezek a természetes környezetünk látható fénytartományban rögzített felvételeit vizsgálják. A torzításelemzésen alapuló módszerek ígéretesek, de ezen módszerek gyakori hibája, hogy csak relatív értelemben mérik a képminőséget, azaz ugyanazon kép eltérő minőségű változatai között különbséget tudnak tenni, de két különböző kép esetén nem összemérhető az eredményük. CT felvételek esetén alkalmazzák a CNR (*contrast-to-noise*) és SNR (*signal-to-noise*) metrikákat [2], a háttér és a szöveti régiók általában kézzel kijelölve, nem automatizált módon.

A cikk felépítése a következő: A 2. fejezet a kidolgozott módszert ismerteti. A 3. fejezet ennek működését és vizsgálatát mutatja be egy konstruált tüdőfantom és zajmodellezés segítségével végzett szimulációban. A 4. fejezet a valós CT képeken végzett vizsgálatok eredményét tartalmazza. Az utolsó, 5. fejezetben a bemutatott eredmények összefoglalása és a további kutatási tervek találhatók.

<sup>1</sup> A referenciaképet használó metrikák alkalmazása CT képek esetén ugyanakkor nem példa nélküli: a [8] cikkben az SSIM és az RMSE (*root-mean-squared error*) metrikákat használták alacsony dózisu felvételek iteratív rekonstrukciós eljárásainak vizsgálatához, egy magas dózisu felvételt referenciaként felhasználva.

## 2. Szegmentálás és képmínőségmérés

A bemutatásra kerülő módszer a CT képeket intenzitás szerint szegmentálja a CT felvételek tulajdonságainak figyelembevételével. A képmínőség meghatározása a kapott szegmentált kép és az eredeti kép összehasonlításán alapul.



1. ábra: Különböző minőségű alacsony dózisú CT képek és histogramjaik

A módszer kifejlesztéséhez a PET Pozitron-Diagnosztika Központ 20 alacsony dózisú tüdő CT felvételét használtam fel, melyek hasonló körülmények között és beállításokkal kerültek rögzítésre. A további teszteléseket a későbbiekben bemutatásra kerülő tüdő-fantom és zajmodellezés segítségével végeztem. Az alapötlet a CT képek histogramjának és intenzitáseloszlásának elemzéséből származik, ugyanis azt tapasztaltam, hogy a felvételek histogramjai azonos karakterisztikájúak és hasonló lefutásúak. Az 1. ábrán két különböző minőségű felvétel egy-egy szelete (hamis színes megjelenítéssel) és azok histogramjai láthatók. A többi felvételhez viszonyítva az (a) jelű kép átlagosnak, a (c) jelű

szélsőségesen rossz minőségűnek tekinthető. A hisztogramok hasonlósága anatómiai okokra vezethető vissza: a tüdőrégiót alkotó szövettípusok személyenként hasonló mennyiségi eloszlásúak, és intenzitás szerint elkülöníthetők egymástól. Az intenzitások területi eloszlását vizsgálva megállapítható, hogy a zsír-, izom- és csontszövet nagyobb összefüggő homogén régiókat, míg a tüdőszövet kis csomókat vagy vékony vonalakat alkot a képeken. Mindezen megfigyelésekből származik az az ötlet, hogy a CT képeket, pontosabban a CT felvételek egy belső szeletét szegmentáljuk intenzitás szerint, az egyes pixeleket osszuk szövettípus szerinti klaszterekbe. A kijelölt klaszterek és reprezentáns értékeik az 1. táblázatban láthatók. A gyakorlatban ezek a klaszterek nem különülnek el élesen egymástól, ugyanis a diszkretizáció és a felvételre rakódó zaj miatt az egyes szövettípusok intenzitásának szórása megnő. Diagnosztikai szempontból a tüdő vizsgálata fontos, így a szegmentáló algoritmusnak a tüdőszövet részletességének megőrzésére, míg más szöveti régiókban a területi homogenitás kialakítására kell törekednie.

Anyag	Prototípus (HU)
Levegő	-1000
Tüdőszövet	-600
Zsírshószövet	-100
Izomszószövet és belsőszerv	100
Csontszószövet	500

1. táblázat: Az intenzitás szerinti szegmentálás klaszterei

A szegmentáló algoritmus konstrukciójához az orvosi képfeldolgozásban ismert SKFCM (*spatially constrained kernelized fuzzy C-means*) [14] algoritmust vettem alapul, a bemutatásra kerülő módszer ennek módosítása. Az SKFCM a klasszikus FCM (*fuzzy C-means*) szegmentáló algoritmus továbbfejlesztése, amely távolságmétrikaként egy radiális Gauss-bázisfüggvényt (kernel) használ, és homogén területek kialakítására törekszik, így lehetővé téve zajos képek szegmentálását. Az  $x = (x_k)_{k=1}^N$  szegmentálandó pixelhalmaz  $C$  számú klaszterbe sorolásához meghatározza a  $v = (v_i)_{i=1}^C$  klaszterprototípusokat és az  $U \in [0, 1]^{C \times N}$  particionáló mátrixot, melynek elemeire:

$$\forall k : \sum_{i=1}^C u_{ik} = 1, \forall i : 0 < \sum_{k=1}^N u_{ik} < N. \quad (3)$$

A particionáló mátrix  $u_{ik}$  eleme az  $x_k$  pixel  $i$ -edik klaszterhez tartozásának a valószínűségét reprezentálja. A mátrix ismeretében az  $x_k$  elem az  $i$ -edik klaszterbe sorolandó, ha  $u_{ik} = \max \{u_{jk} | j = 1, \dots, C\}$ . Az algoritmus eredményeképp a szegmentálandó kép pixeleit a hozzájuk rendelt klaszterprototípusára cserélve

adódik a szegmentált kép. A mátrix és a klaszterek prototípusai a következő  $J_m = J_m(x, v, U)$  kifejezés minimalizálásából adódnak:

$$J_m = \sum_{i=1}^C \sum_{k=1}^N u_{ik}^m \left( 1 - K(x_k, v_i) + \frac{\alpha}{|N_k|} \sum_{r \in N_k} (1 - u_{ir})^m \right), \quad (4)$$

ahol  $m$  az algoritmust jellemző pozitív kitevő,  $K$  radiális Gauss-bázisfüggvény  $\sigma$  szórással,  $N_k$  ablak az  $x_k$  elem egy  $x_k$ -t nem tartalmazó környezete,  $0 < \alpha < 1$  pedig az  $\frac{\alpha}{|N_k|} \sum_{r \in N_k} (1 - u_{ir})^m$  térbeli együtttható hatásának erősségét szabályozza.

E térbeli együtttható segíti elő a területi homogenitás kialakulását.

Az alapmodell hiányossága esetünkben az, hogy az egyes klaszterekben azonos mértékű területi homogenitás kialakítására törekszik. Az alkalmazáshoz ezért a térbeli együtttható módosítására volt szükség, emellett megvalósításomban a klaszterprototípusokat rögzítettnek tekintettem (az 1. táblázatbeli értékeknek megfelelően), és az eljárás paramétereit a CT képekhez optimalizáltam. A térbeli együttthatóban szereplő ablakok méretét klaszterenként különböző méretűre választottam, az  $i$ . klaszterhez tartozó  $N_{i,k}$  ablakokban az összegzést  $w_{ik}$  súlyokkal végeztem el (ahol  $\forall i : \sum_{r \in N_{i,k}} w_{ik} = 1$ , és  $x_k \notin N_{i,k}$ ). A különböző méretű ablakok

használata lehetővé teszi, hogy az egyes klaszterekben különböző mértékű homogenitást követeljünk meg, a  $w$  súlyokat egy Gauss-szűrő segítségével megválasztva pedig csökkenthető az eljárás során jelentkező blokkosodás. A módosított paraméterekkel a tüdőszövet részletessége megőrizhető, miközben a zsír-, izom- és csontszövet esetén továbbra is homogén területek kialakítását kívánjuk elérni. A módosított optimalizáló kifejezés a következő:

$$J_m = \sum_{i=1}^C \sum_{k=1}^N u_{ik}^m \left( 1 - K(x_k, v_i) + \alpha \sum_{r \in N_{i,k}} w_{ir} (1 - u_{ir})^m \right). \quad (5)$$

A kifejezés minimalizálása az eredeti SKFCM algoritmushoz hasonlóan iteráció segítségével történik, de mivel most  $v$  rögzített, így az egyes lépésekben csak  $U$  frissítése történik meg a következőképpen:


$$u_{ik}^{(t+1)} = \frac{\left( 1 - K(x_k, v_i) + \alpha \sum_{r \in N_{i,k}} w_{ir} (1 - u_{ir}^{(t)})^m \right)^{-1/(m-1)}}{\sum_{j=1}^C \left( 1 - K(x_k, v_j) + \alpha \sum_{r \in N_{j,k}} w_{jr} (1 - u_{jr}^{(t)})^m \right)^{-1/(m-1)}}. \quad (6)$$

Az iteráció előtt  $U$  a következőképpen inicializálható:

$$u_{ik}^{(0)} = \frac{(1 - K(x_k, v_i))^{-1/(m-1)}}{\sum_{j=1}^C (1 - K(x_k, v_j))^{-1/(m-1)}}. \quad (7)$$

Az iteráció egy előre rögzített  $t_{max}$  lépés után áll meg, vagy ha az  $U$  már nem változik elég nagy mértékben, azaz az  $E^{(t)} = \|U^{(t)} - U^{(t-1)}\|_{\infty}$  hibára  $E^{(t)} < \varepsilon$ . A tesztek azt mutatják, hogy míg jó minőségű képek esetén a módszer valóban konvergens, nagyobb zajszint esetén az iteráció korai leállása esetén kapható legjobb eredmény. A korai leállás a  $t_{max}$  lépésszám alacsony értékűre választásával, vagy az  $E^{(t)} > \beta E^{(t-1)}$  feltétel esetén történő kilépéssel érhető el, valamely  $\beta > 0$  együttható mellett.

Az algoritmus hatékonysága növelhető a szegmentálás elé beiktatott előfeldolgozási fázissal. Ennek során a háttér, vagyis a CT kép testen kívüli része szűrésre kerül Gauss- és mediánszűrő, küszöbölés és régiókitöltés segítségével, valamint a  $-700$  HU intenzitás alá eső értékeken gammakorrekción történik. Az eljárás paraméterei kézi optimalizálással kerültek kiválasztásra, a további szimuláció és tesztelés során  $m = 2$ ,  $\alpha = 0.3$ ,  $\beta = 0.75$ ,  $t_{max} = 100$ , a levegő és a tüdő ablaka  $3 \times 3$  méretű,  $0.5$  szórású, a többi klaszter esetén  $9 \times 9$  méretű,  $1.5$  szórású Gauss-szűrőből származik. A tesztelesek alapján az algoritmus akkor hatékony, ha a  $K$  Gauss-kernel  $\sigma$  szórása a képzajjal arányos. A képzaj durva becslését és ezáltal  $\sigma$  meghatározását wavelet-transzformáció segítségével végeztem. A 2. ábrán az előfeldolgozás (a) és a szegmentálás (b) eredménye látható, az 1. ábrán bemutatott (a) jelű képre vonatkozólag.




**2. ábra:** Az előfeldolgozás és a szegmentálás eredménye

A fentiek alapján a CT képek minőségének mérésére a következő módszert javaslom: a szegmentált képet mint referenciaképet és az előfeldolgozott képet hasonlítjuk össze a gyakorlatban elterjedt SSIM [13] metrika segítségével. A kapott mérőszám a  $[-1, 1]$  intervallumba esik, az alacsonyabb érték rosszabb képminőségnek felel meg. A következő fejezetekben bemutatott tesztek azt mutatják, hogy ez a mennyiség jól követi a vizsgált alacsony dózisu tüdő CT felvételek minőségét.

### 3. Tüdő-fantom segítségével végzett tanulmány

A CT képfeldolgozó algoritmusok tesztelésének szokásos módszere a fantomok segítségével történő szimuláció. A legismertebb fantom a Shepp-Logan fantom [11], amely az agy sematikus modellezése ellipszisek segítségével. Az ellipszisekkel konstruált fantomok azért előnyösek a CT szimuláció során, mert Radon-traszformáltjuk ismert és könnyen számítható [12], így a fantom szintetizált szinogramja analitikusan előállítható. Az előző fejezetben bemutatott módszer teszteléséhez egy ellipszisekből álló tüdő-fantomot konstruáltam a Shepp-Logan fantom mintájára. A fantom a 3. ábrán látható, az ellipszisek intenzitásai az 1. táblázatban szereplő prototípusok. A zsír-, izom- és csontszövetet reprezentáló 6 nagy ellipszis mellett a tüdőben 100-100 kisméretű, véletlenszerű elhelyezkedésű és méretű ellipszis modellezi a tüdőszövetet.



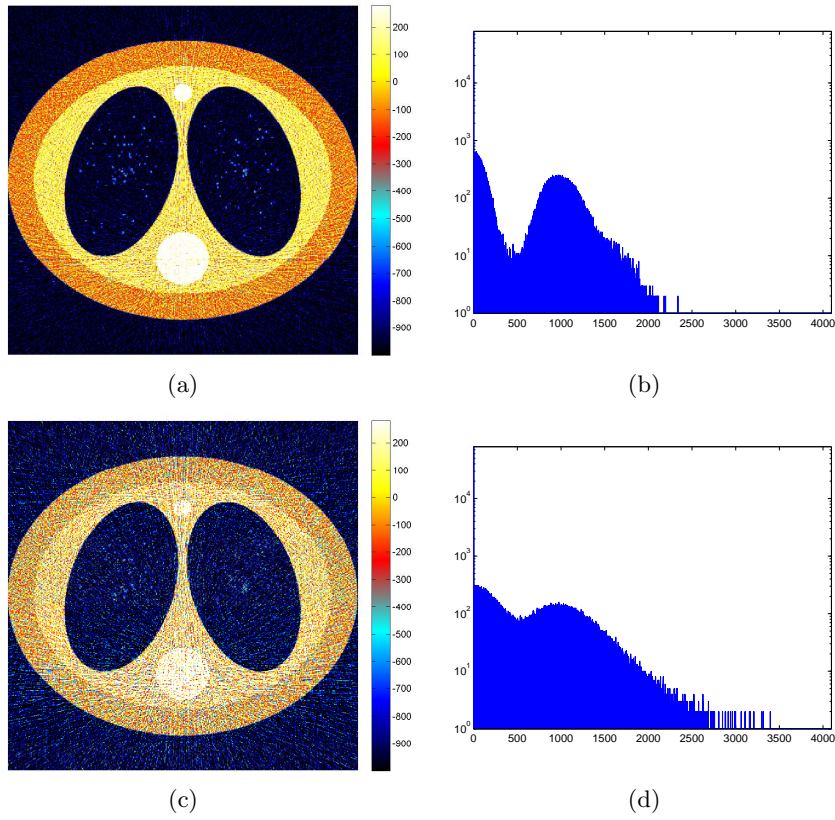
3. ábra: A tüdő-fantom

A fantom segítségével a következőképpen végeztem a CT képalkotás szimulációját: A fantom Radon-traszformáltját mintavételeztem, az így kapott szinogramhoz különböző mértékű, mesterségesen generált zajt adtam, majd rekonstruáltam a képet szűrt visszavetítés, Ram-Lak szűrő segítségével. Ezen szintetizált CT képeket használtam fel a további vizsgálatokhoz.

A szimuláció során az elektromos zajt és a kvantumzajt az [5] zajmodell alapján generáltam, amely a detektoron mért intenzitásra alkalmazható. Az elektromos zajt 0 várható értékű, rögzített varianciájú normális eloszlású valószínűségi változónak, a kvantumzajt a Poisson-eloszlás határeloszlásának figyelembevételével 0 várható értékű, képfüggő varianciájú normális eloszlású valószínűségi változónak tekintve a modellt a következőképpen írható fel:

$$I_{zaj} = I + \eta(I), \quad (8)$$

$$\eta(I) \sim \mathcal{N}(0, aI + b), \quad (9)$$



4. ábra: Szintetizált tüdő-fantom képek különböző erősségű zaj mellett

ahol  $I$  a várt, Beer-Lambert-törvényből adódó,  $I_{zaj}$  pedig a detektoron ténylegesen mérhető intenzitást modellezi, az  $\eta$  zajfüggvény a két zajkomponens hatását tartalmazza, az  $a$  és  $b$  pozitív paraméterek rendre az elektromos zaj és a kvantumzaj erősségét fejezik ki. Hasonló összefüggés írható fel a mért és a forrásintenzitás arányára is, módosított  $a$  és  $b$  paraméterekkel:

$$\frac{I_{zaj}}{I_0} = \frac{I}{I_0} + \eta \left( \frac{I}{I_0} \right), \quad (10)$$

$$\eta \left( \frac{I}{I_0} \right) \sim \mathcal{N} \left( 0, a \frac{I}{I_0} + b \right), \quad (11)$$

ahol  $I_0$  a forrásintenzitás. A modellt a vizsgált alacsony dózisú CT felvételek rögzítésekor használt paraméterek figyelembe vételével alkalmaztam: a szimuláció során a röntgenfotonokat 130 KeV energiájúnak tekintettem, ennek megfelelően a  $\mu_{H_2O} \approx 0.16 \text{ cm}^{-1}$  közelítő értékkel számoltam [6],  $512 \times 512$  felbontású rekonstruált képeket készítettem  $0.06484 \text{ cm}$  pixeltávolsággal. Az  $L$  irányban



számított  $P(L)$  Radon-traszformáltból a következőképpen állítható elő az intenzitások aránya:

$$\frac{I}{I_0} = \exp(-0.16 \cdot 0.06484 \cdot P(L)). \quad (12)$$

Az  $I/I_0$  intenzitásarányt a fenti modell alapján generált zajjal terhelve adódik az  $I_{zaj}/I_0$  intenzitásarány, ebből pedig kiszámítható a  $P_{zaj}(L)$  zajjal terhelt Radon-traszformált:


$$P_{zaj}(L) = -\frac{1}{0.16 \cdot 0.06484} \cdot \ln\left(\frac{I_{zaj}}{I_0}\right). \quad (13)$$

A 4. ábrán a tüdő-fantom  $a = 10^{-4}$ , illetve  $a = 5 \cdot 10^{-4}$  és  $b = 10^{-7}$  zajparaméterek melletti rekonstrukciója, (a) illetve (c), és azok hisztogramjai, (b) illetve (d), láthatók. Az eredményeket az 1. ábrával összehasonlítva látható, hogy a szintetizált képek vizuálisan korrelálnak a valós CT felvételekkel, és hisztogramjaik is hasonló karakterisztikájúak. Ez is igazolja, hogy a konstruált tüdő-fantom tényleg a tüdő CT képek sematikus közelítésének tekinthető.

Az előző fejezetben ismertetett metrika tüdő-fantom segítségével végzett tesztelése azt mutatja, hogy a szegmentálás megőrzi a kép kívánt tulajdonságait, a kapott mérőszám pedig jól jellemzi a képmínőséget a zajparaméterek változtatása mellett. A 2. táblázat egy zajszimulációval végzett mérés eredményét mutatja: az  $a$  paraméter 11, a  $b$  paraméter 3 különböző értéke mellett, értékpáronként 20 mérést végezve, az eredményt átlagolva, az 5. ábra diagramja a metrika változását mutatja az  $a$  paraméter függvényében,  $b = 10^{-7}$  esetén. Látható, hogy rögzített  $b$  paraméter, azaz adott elektromos zajszint mellett a metrika értéke csökken az  $a$  paraméter, azaz a kvantumzaj mértékének növelésével.

a \ b	$1 \cdot 10^{-7}$	$5 \cdot 10^{-7}$	$10 \cdot 10^{-7}$
$0 \cdot 10^{-5}$	0.98148	0.95697	0.93425
$5 \cdot 10^{-5}$	0.88519	0.87195	0.85912
$10 \cdot 10^{-5}$	0.82087	0.81362	0.80628
$15 \cdot 10^{-5}$	0.779	0.77572	0.77224
$20 \cdot 10^{-5}$	0.75378	0.75271	0.7515
$25 \cdot 10^{-5}$	0.73755	0.73772	0.73736
$30 \cdot 10^{-5}$	0.72665	0.72734	0.72792
$35 \cdot 10^{-5}$	0.72206	0.72112	0.72237
$40 \cdot 10^{-5}$	0.71746	0.71836	0.72068
$45 \cdot 10^{-5}$	0.71639	0.71768	0.71896
$50 \cdot 10^{-5}$	0.71633	0.7179	0.71867


**2. táblázat:** A metrika értékei a zajos tüdő-fantom szimulációban. A sorok az  $a$ , az oszlopok a  $b$  paraméter értékeit mutatják.




**5. ábra:** A metrika értékeinek diagramja, az  $a$  paraméter függvényében,  $b = 10^{-7}$  mellett, a 2. táblázat alapján.

#### 4. Tesztelés valódi CT felvételeken

A módszer alacsony dózisu tüdő CT felvételeken végzett tesztelése azt mutatja, hogy a szegmentálás jól megőrzi a CT képek szerkezetét, a metrika értéke korrelál a vizuálisan érzékelhető minőséggel. A PET Pozitron-Diagnosztika Központ felvételeihez a metrika 0.61676 és 0.85809 közötti értékeket rendel. A 6. és 7. ábrákon nyolc felvétel és a hozzájuk tartozó metrika értékek hasonlíthatók össze, a legrosszabbnak ítélt (a) jelű, a legjobbnak ítélt (h) jelű, és közepes minőségű felvételek. A vizuálisan is legrosszabb minőségű (a) felvétel esetén a legrosszabb a szegmentálás hatékonysága, a szegmentált kép is zajjal terhelt, de ezzel összhangban a metrika is a legalacsonyabb értéket rendelte hozzá.




(a) 0.61676



(b) 0.68027

**6. ábra:** A PET Pozitron-Diagnosztika Központ alacsony dózisu tüdő CT felvételeinek összehasonlítása: különböző minőségű képek, és a metrika értékei.



**7. ábra:** A PET Pozitron-Diagnosztika Központ alacsony dózisu tüdő CT felvételeinek összehasonlítása: különböző minőségű képek, és a metrika értékei.

Az ELCAP adatbázisban [9] található 50 alacsony dózisu tüdő felvétel elemzése hasonló eredményt mutat: a metrika értéke itt 0.65505 és 0.85857 között mozog. A két adatbázist összehasonlítva a közeli mérőszámmal rendelkező felvételek között szoros vizuális kapcsolatot lehet találni. A módszert az LIDC adatbázis [1] 20 magas dózisu tüdő felvételén is teszteltem: a szegmentálás ezen képek esetén nagy hatékonysággal működik, a metrika 0.82946 és 0.93688 közötti értékeket vesznek fel. A vizsgált alacsony és magas dózisu felvételek elemzése alapján megállapítható, hogy a magas dózisu felvételek mérőszámai magasabb értéktartományban mozognak, de nem különülnek el élesen az alacsony dózisu felvételek mérőszámaiktól. Az éles elkülönülés azonban nem is várható el: diagnosztikai felhasználhatóság szempontjából egy jó minőségű, alacsony dózisu felvétel megközelíthet egy rossz minőségű, magas dózisu felvételt.

## 5. Összefoglalás, további tervek

A cikkben alacsony dózisu tüdő CT felvételeket vizsgáltam: egy intenzitás szerinti szegmentáláson alapuló módszert javasoltam a CT felvételek minőségének objektív mérésére. A módszer tesztelését egy erre a célra konstruált tüdő-fantom segítségével végzett szimulációban és valós CT felvételeken végeztem el. Mindkét vizsgálat azt mutatja, hogy a kapott metrika jól jellemzi a CT képek minőségét. A bemutatott módszer a paraméterek hangolásával más, hasonló típusú képekre is alkalmazható, például a test egyéb részeinek CT felvételére, az orvosi képzés más modalitásai segítségével rögzített felvételekre, mikroszkopikus képekre. További terveim között szerepel a módszer alkalmazása más körülmények között, illetve egy ezen alapuló képjavító eljárás fejlesztése.

## 6. Köszönetnyilvánítás

A kutatás a PET Pozitron-Diagnosztika Központ és az ELTE IK Numerikus Analízis Tanszék közötti együttműködés keretében történt, a Központban rögzített CT felvételek felhasználásával. Köszönöm Dr. Lengyel Zsoltnak, a Központ orvos igazgatójának a közreműködését, és doktori témavezetőmnek, Dr. Fridli Sándornak a hasznos észrevételeit és tanácsait.

## Irodalom

1. Armato SG III, McLennan G, Bidaut L, McNitt-Gray MF, Meyer CR, Reeves AP, Zhao B, Aberle DR, Henschke CI, Hoffman EA, Kazerooni EA, MacMahon H, van Beek EJ, Yankelevitz D, et al.: *The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A completed reference database of lung nodules on CT scans*. Medical Physics **38** (2011), 915–931.
2. J.T. Bushberg, J.A. Seibert, E.M. Leidholdt Jr., J.M. Boone: *The Essential Physics of Medical Imaging, Second Edition*. Lippincott Williams & Wilkins, Philadelphia, PA (2002), ISBN 0-683-30118-7.

3. S.R. Deans: *The Radon transform and some of its application*. John Wiley & Sons, New York (1983), ISBN 0-471-89804X.
4. G. Dougherty: *Digital Image Processing for Medical Applications*. University Press, Cambridge (2009), ISBN 978-0-521-86085-7.
5. A. Foi, M. Trimeche, V. Katkovnik, K. Egiazarian: *Practical Poissonian-Gaussian noise modeling and fitting for single-image raw-data*. IEEE Transactions on Image Processing **17**(10) (2008), 1737–1754.
6. J.H. Hubbel, S.M. Seltzer: *Tables of X-Ray Mass Attenuation Coefficients and Mass Energy-Absorption Coefficients* (version 1.4). National Institute of Standards and Technology, Gaithersburg, MD (2004), <http://physics.nist.gov/xaamdi> [2014. november 30.]
7. W. Lin., C.-C.J. Kuo: *Perceptual visual quality metrics: A survey*. J. Vis. Commun. Image R. **22**(4) (2011), 297–312.
8. L. Pfister, Y. Bresler: *Tomographic reconstruction with adaptive sparsifying transforms*. IEEE International Conference on Acoustic, Speech and Signal Processing (ICASSP) (2014), 6914–6918.
9. Public Lung Image Database, <http://www.via.cornell.edu/databases/lungdb.html> [2014. november 30.]
10. H.R. Sheikh, A.C. Bovik: *Image information and visual quality*. IEEE Transactions on Image Processing **15**(2) (2006), 430–444.
11. L.A. Shepp, B.F. Logan: *The Fourier reconstruction of a head section*. IEEE Transactions on Nuclear Science **21**(3) (1974), 21–43.
12. Schipp Ferenc: *Radon transzformáció*. Egyetemi Jegyzet, Eötvös Loránd Tudományegyetem, Budapest (2004).
13. Z. Wang, A.C. Bovik, H. R. Sheikh, E. P. Simoncelli: *Image quality assessment: From error visibility to structural similarity*. IEEE Transactions on Image Processing **13**(4) (2004), 600–612.
14. D.-Q. Zhang, S.-C. Chen: *A novel kernelized fuzzy C-means algorithm with application in medical image segmentation*. Artificial Intelligence in Medicine **32**(1) (2004), 37–50.