

# DILOMAMUNKA

## Bőrultrahang képek elemzése

Bakacs Eszter Katalin

Témavezető: Dr. Gyöngy Miklós  
egyetemi docens  
PPKE ITK

Belső konzulens: Dr. Dóczy Rita  
egyetemi docens  
BME Nukleáris Technika Intézet  
Nukleáris Technika Tanszék

# DIPLOMA THESIS

## Analysis of skin ultrasound images

Bakacs Eszter Katalin

Supervisor: Dr. Gyöngy Miklós

associate professor

PPKE ITK

Internal supervisor: Dr. Dóczy Rita

associate professor

BME Institute of Nuclear Techniques

Department Nuclear Techniques

## Köszönetnyilvánítás


Köszönöm *Dr. Gyöngy Miklós* témavezetőmnek a diplomamunkám megírása során adott tanácsait, továbbá *Csabai Domonkosnak, Marosán Péternek* és az ultrahang labor összes tagjának, hogy a témában felmerülő kérdéseimre készségesen válaszoltak.

## Tartalomjegyzék

1.BEVEZETÉS.....	5
2.CÉLKITŰZÉSEK.....	5
3.ELMÉLETI BEVEZETŐ.....	6
3.1.EGÉSZSÉGES BŐR FELÉPÍTÉSE.....	6
3.2.HFS [High Frequency Sonography].....	6
3.3.HFS KÉPEK JELLEMZŐI.....	7
4.PREPROCESSZÁLÁS.....	9
4.1.ROI előkészítése.....	9
4.2.SZŰRÉS.....	10
4.2.1. ADAPTÍV MEDIÁN FILTER.....	10
4.2.2. MMM [Modified Mean Median].....	12
4.2.3.WIENER FILTER.....	14
4.2.4.WAVELET-TÉRBE TÖRTÉNŐ SZŰRÉS.....	16
4.2.5.HOMOMORF FILTER.....	20
4.3.SZŰRŐK KIÉRTÉKELÉSE.....	22
4.3.1.KÉPMINŐSÉG JELLEMZÉSE.....	22
4.3.2.KÉPMINŐSÉGI JELLEMZŐK ZAJVARIANCIA FÜGGÉSE.....	24
4.3.3.SZŰRÉSI MÓD KIVÁLASZTÁSA BŐRULTRAHANG KÉPEKHEZ.....	30
5.SZEGMENTÁCIÓ.....	31
5.1.BINARIZÁCIÓS SZEGMENTÁLÁSI MÓDSZEREK.....	31
5.1.1.OTSU KÜSZÖBÖLÉSI TECHNIKA.....	31
5.1.2.NIBLACK.....	32
5.2.MEANSHIFT.....	33
5.3.WATERSHED.....	34
5.3.1.GRADIENS.....	35
5.3.2. WATERSHED MÁTRIX.....	36
5.3.3.RÉGIÓK EGYESÍTÉSE.....	38
6.ÖSSZEFOGLALÁS.....	39
7.KITEKINTÉS.....	39
8.FÜGGELÉK.....	40

## 1. BEVEZETÉS

Az ultrahang ma már nélkülözhetetlen eszköze a bőrdiagnosztikának. Ez a technika olyan információkat szolgáltat az orvosok számára, amelyek segítségével egy sokkal pontosabb kép kapható a bőrfelszíni léziókról, így a rosszindulatú daganatok kiszűrése is megbízhatóbbá vált. Nemcsak a felszíni, hanem a bőrléziók mélységi kiterjedéséről is szolgáltat adatokat. A bőruntervizsgálat jelentőségét tovább fokozzák az elmúlt évtizedek statisztikái. Ausztráliában, az USA-ban, valamint Európában is megfigyelhető a betegszám növekedése. Hazánkban szintén egyre nagyobb figyelmet kíván a melanoma korai felismerése. Az alábbi diagramon is jól kivehető, hogy az újonnan diagnosztizált betegek száma évről-évre közel százal nő.



*1. ábra Invazív melanomával újonnan diagnosztizált férfiak és nők száma Magyarországon 2001 és 2012 között*

Az ultrahanggal történő vizsgálatok nagy előnye, hogy noninvazív, azaz műtéti beavatkozást nem igényel. Jelenleg a csak ultrahang képek alapján történő diagnózis egy szakképzett orvos számára is kihívás, ezzel szemben szöveti mintavétellel közel 100% pontossággal meghatározható a lézió típusa. Az ultrahang alapján történő diagnózis pontosságát elősegítheti az UH képek megfelelő szegmentálása, a szegmentált területek tulajdonságai mentén való típusba sorolás [BCC, melanoma, nevus].

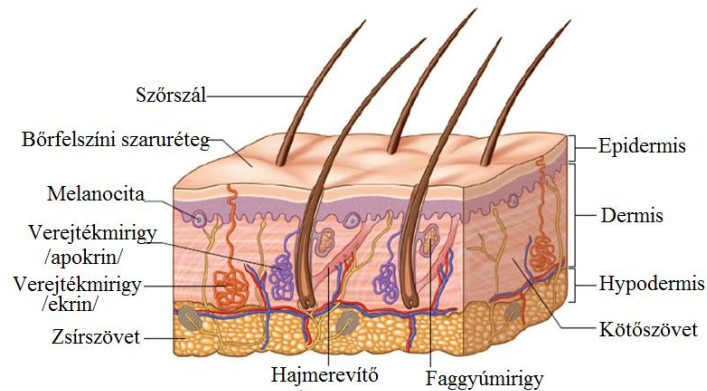
## 2. CÉLKITŰZÉSEK

A diplomamunka távoli célja, hogy a különböző típusú [BCC, melanoma, nevus] bőrléziókról készült ultrahang felvételek pontos szegmentációját követően a léziók tulajdonságait [intenzitás várható értéke és szórása, homogenitás, alaki jellemzők, terület] alapul véve a típusuk meghatározható legyen. Ennek eléréséhez a szegmentációt megelőzően különféle szűrőtípusokat vizsgáltam a zaj erősségének függvényében. A megfelelő filter kiválasztását követően eltérő szegmentálási módokat próbáltam ki. A munkám során *MatLabot* használtam a kódok megírásához.

### 3.ELMÉLETI BEVEZETŐ

Ebben a fejezetben azokat a bőరుltrahanghoz köthető alapvető biológiai, és fizikai ismereteket szeretném röviden összefoglalni, melyek nélkülözhetetlenek a téma megértéséhez.

#### 3.1.EGÉSZSÉGES BŐR FELÉPÍTÉSE




2. ábra Az egészséges bőr felépítése [1]

Az ultrahang képek megfelelő értelmezéséhez elsősorban az egészséges bőr struktúráját kell ismernünk, hiszen a léziók felismerése, pontos meghatározása nélkül nem lehetséges. A bőr alapvetően három rétegből tevődik össze: epidermis, dermis, hypodermis. A három réteg jól elkülöníthetővé válik az ultrahang képeken. A léziók leginkább a felső rétegeket érintik (epidermis, dermis felső rétege), hiszen ebben a régióban található a melanociták, azaz a melanint termelő festéksejtek.

#### 3.2.HFS [High Frequency Sonography]

A bőrultrahangnál alkalmazott magas frekvencia oka az általa elérhető nagyobb axiális és laterális felbontás. A frekvencia növelésével csökken a behatolási mélység, de ebben a vizsgálati esetben ez nem korlátozó tényező. Az általam vizsgált képek 13-15 MHz tartományban készültek, de manapság már a 20 MHz is elterjedt. Az akusztikus tengely mentén megadható a




3. ábra A felbontás frekvenciafüggése

természetes fókuszpont az apertúrateület és a hullámhossz hányadosaként. A szöveti hangsebességet a víz hangsebességével közelítve 38 mm átmérőjű apertúra esetén a laterális felbontás 15 MHz mellett

### 3.3.HFS KÉPEK JELLEMZŐI

#### Egészséges bőr




4. ábra Egészséges bőrről készült B-módú kép

A bőrfelszín egy echodús vonalként jelenik meg, az epidermis keratintartalma miatt. Vastagabb, nagyobb mértékben elszarusodott epidermist (talp, tenyér) kettős vonal jellemzi. Ezt követi a SLEB (subepidermal hypoechoic band), ami az epidermis alatti vékony echoszegény sáv. A dermis echogenitását a kollagének határozzák meg. Jellemzően echodús réteg, de homogenitása kisebb az epidermisnél. A bőralja sötét sávként rajzolódik ki, hiszen a zsírszövetből nem kapunk válaszjelet. A hypodermis arteriális és vénás erezettségét color Doppler technikával vizsgálhatjuk meg.

#### Bőrfelszíni léziók


##### Melanoma

A melanoma nagy előnye a többi daganattal szemben, hogy a kültakarón, szemmel jól látható formában helyezkedik el. A kellő időben diagnosztizált esetekben ma már nagy hatékonysággal gyógyítható. Az előrehaladott stádiumban lévő melanomáknál azonban jelentős az áttétképzés kockázata. Az előbbieket ismét alátámasztják a megelőzés fontosságát. Kialakulásában szerepet játszanak a környezeti hatások (UV), genetika, életkor és a társadalmi helyzet. A leginkább érintett emberek az I. vagy a II. Fitzpatrick-féle fényérzékenységi csoportba tartoznak.



5. ábra 2.55 mm vastagságú ovális alakú melanoma

A melanoma a vizsgálatok 100 százalékában echoszegény területként jelenik meg az ultrahang képeken, míg a nem melanoma eredetű léziók nagy hányadáról echodúsabb képet kapunk. A másik fontos jellemzője a nagyfokú homogenitás. Emellett megfigyelhető a határozott körvonal, a jól kivehető ovális alak. Az 5. ábrán látható melanomára gradiens szűrőt alkalmaztam, így még inkább megfigyelhető a homogenitás.




6. ábra Gradiens szűrő használata melanomáról készült ultrahang képen

Az ilyenfokú homogenitás csak a melanómákra jellemző, más léziók esetében a heterogénitás jelenik meg.

## BCC

A bőr rosszindulatú betegségeinek 95%-a BCC, ami a melanomával szemben nem pigmentált. Főleg a vékony, napsugárzásnak kitett bőrfelületeken jelenik meg: szemhéjak, orr, ajkak, fülek területén.



7. ábra 1,53 mm vastag BCC

A BCC léziókról készült ultrahang felvételek sajátossága a nagyfokú heterogenitás. Melanomával szemben körvonala kevésbé határozott, területéről kapunk echot.

## Festékes anyajegyek (Nevus)

Ezek a melanocita eredetű léziók a test bármely részén megjelenhetnek. Alapvetően jóindulatúak, de gyakorta képezik a daganatos megbetegedések kiindulópontját, ezért fontos az



ellenőrzésükre nagy hangsúlyt fektetni. A születést követően kialakuló anyajegyek elsődleges oka az UV sugárzás.

### 3.4.HFS KÉPEK ANALÍZISE

Az adott lézióról készült képet jellemezhetjük elhelyezkedése, echogenitása, homogenitása, alakja, szélei, akusztikus árnyékolása és a fokozott hátulsó echogenitása szerint. Ezek mellett mérvadó a prognosztikai faktorok megadása.

A Breslow szerinti tumorvastagság (Breslow index) a tumor abszolút vastagságát jelenti. Az epidermis felső rétegétől a legmélyebben fekvő tumoros sejtrétegig mérik. Ez az érték megmutatja, hogy a daganat mennyire előrehaladott állapotban van, azaz minél kisebb ez a szám (minél vékonyabb), annál nagyobb esély van a gyógyulásra.

Clark szerinti behatolási mélység a bőr anatómiai rétegeinek beszűrtsége alapján I-V. csoportba sorolja a léziókat.

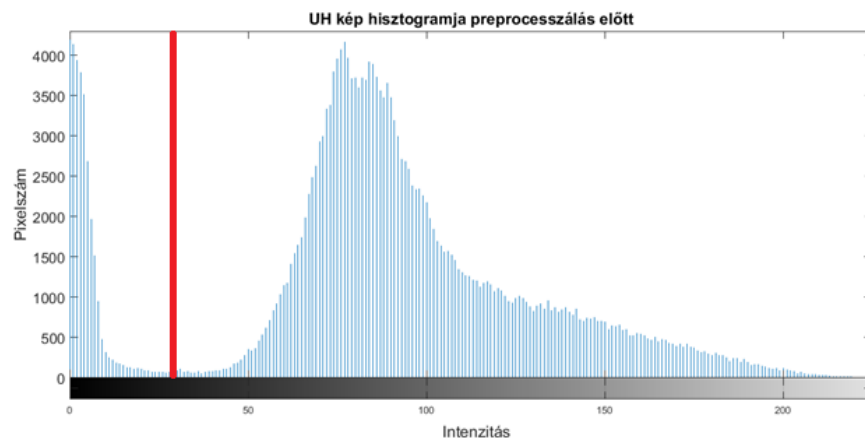
## Bőruntrahang képek analízisének lépései

A bőruntrahang képek analízisének lépéseit a következő két fejezetben (4-5.fejezet) mutatnám be. Az általam használt szűrési technikák, szegmentációs módszerek kerülnek bővebb tárgyalásra.

## 4.PREPROCESSZÁLÁS


### 4.1.ROI előkészítése

Számos képen megtalálható a léziók helyzetét jelölő kereszt, a lézió testfelszínén való pontos pozícióját mutató 'térkép' és egy intenzitásskála. Ezek azonban az elemzés során zavaró elemként vannak jelen, ebből kifolyólag ezeket eltávolítottam egy már korábban megírt [1] kód segítségével. Következő lépésként a hisztogramot vizsgáltam meg.



8. ábra A vizsgált ultrahang kép hisztogramja

A bőrléziókról készült felvételek hisztogramjából is jól látható, hogy a bőrfelszín (epidermis) felett jelentkező kis intenzitású jelek mértéke jelentős. Ez a méréskor használt gél régiójának egyenetlenségéből (pl. légbuborékok okozta zaj) fakadhat. A képek további vizsgálatakor a felső pixelsortól az epidermisig terjedő tartományt maszkoltam. A hisztogram első minimumát vettem threshold értéknek, majd a vizsgálni kívánt tartományban keletkezett hibákat morfológiai műveletek segítségével állítottam helyre. A további analízis során már csak a megfelelően maszkolt képekkel dolgoztam, ezzel is csökkentve a számítási időket.



9. ábra A maszkolt régió (gél) nemnulla pixeljei

## 4.2.SZŰRÉS

### A zajról általánosan

Az ultrahang képek esetében rendkívül ritka a PSF [] ismerete. Erre a vak dekonvolúció nyújthatna megoldást, azonban még itt is egy jó becslést kell adni a PSF méretéről, illetve alakjáról. Emellett nehezíti a problémát a zaj multiplikatív jellege is.

$$g = f + n * f = f + \eta \quad (1)$$

Előzőleg említettem, hogy az ultrahang képekre jellemző zaj multiplikatív, ami azt jelenti, hogy az egyenesletes eloszlású zaj a képpel szorozódik össze.

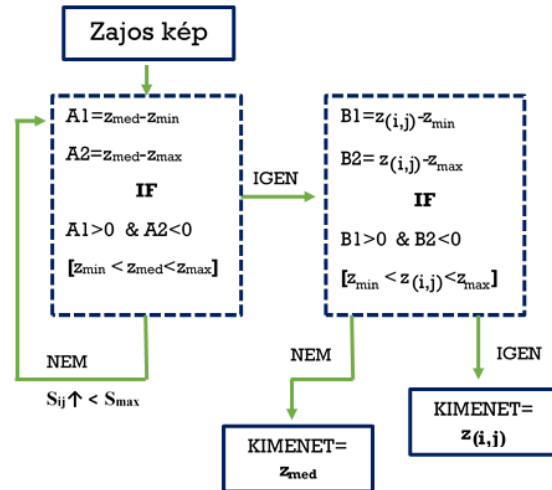
Még a szegmentálást megelőzően a képszűrési műveleteket elvégezve egy, az eredeti intenzitásértékeket jobban megközelítő képen egy pontosabb szegmentálási eredmény nyerhető. A szűréseket öt különböző módon végeztem, majd a szűrés eredményét különböző kvalitatív mennyiségek mentén összevettem az eredeti képpel, ezzel meghatároztam az általam használt szűrők közül a leghatékonyabbat.

#### 4.2.1. ADAPTÍV MEDIÁN FILTER

A medián szűrők népszerűségének alapvető oka, hogy a lineáris szűrőkkel szemben nem okoz nagy elkenődést, és e legtöbb statisztikai (random) zajra alkalmazható. Általában kisebb PDF-fel (valószínűségi sűrűségfüggvény) zajoknál egyszerű medián filter is elegendő, nagyobb PDF esetén már az adaptív medián szűrő alkalmazható. Emellett az adaptív medián szűrő képes arra, hogy a kép részleteinek megőrzése mellett a zajt csökkentse (smoothing).

Az adaptív medián két szűrési szintből tevődik össze. Sajátsága, hogy a szűrés folyamán a kernel méretét fokozatosan növeli egy általunk kiválasztott maximális értékig [  $S_{max}$  ]. Az első A szintről csak akkor léphetünk tovább, ha  $Z_{min} < Z_{med} < Z_{max} \in S_{ij}$  feltétel teljesül, egyéb esetben növeljük az

ablak méretét. A maximális kernelméret elérésével sem teljesül az A feltétel, akkor a kimeneti (i,j) pozíciójú pixelérték a medián lesz ( $z_{med}$ ). A B szinten a centrális pixel intenzitását vetjük össze a kernel minimális és a maximális intenzitásértékével. Itt a  $z_{min} < z_{ij} < z_{max}$  teljesülése a  $z_{ij}$  kimenetet adja, a többi esetben szintén a mediánnal helyettesítjük a zajos kép (i,j)-dik pixelét.




10. ábra Adaptív mediánszűrő blokkvázlata

$$\hat{f}(i,j) = \underset{(s,t) \in S_{ij}}{\text{median}} \{g(s,t)\} \quad (2)$$


$$\hat{f}(i,j) = \underset{(s,t) \in S_{ij}}{\text{max}} \{g(s,t)\} \quad (3)$$

$$\hat{f}(i,j) = \underset{(s,t) \in S_{ij}}{\text{min}} \{g(s,t)\} \quad (4)$$

A  $z_{min}$  és a  $z_{max}$  statisztikai értékekkel az impulzusszerű zajokat becsüljük meg.



11. ábra Adaptív medián szűrővel kapott különbségi kép



12. ábra Adaptív medián szűréssel kapott különbségi kép nemnulla pixeljei

#### 4.2.2. MMM [Modified Mean Median]

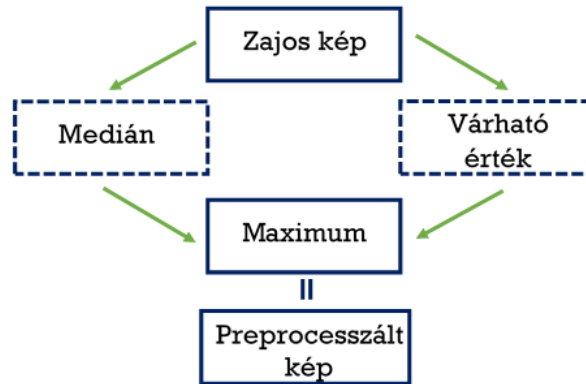
Az MMM szűrőt lineáris és egy nemlineáris szűrő kombinációjával állíthatjuk elő. Ez a filter egy adott méretű kernelen belüli medián és várható érték maximumát veszi az  $(i,j)$  pixelpontban lévő intenzitásértéknek.

$$\mu(i,j) = \frac{1}{mn} \sum_{p=i-r}^{i+r} \sum_{q=j-r}^{j+r} g(p,q) \quad (5)$$


$$Med(i,j) = median\{g(p,q) \in S_{ij}\} \quad (6)$$

$$MMM(i, j) = \max\{Med(i, j), \mu(i, j)\} \quad (7)$$


A szűrés során egy 3x3 méretű négyzetes kernelt használtam, mivel emellett az érték mellett kaptam a legjobb eredményt.



13. ábra Az MMM szűrő folyamatábrája



14. ábra Eredeti zajos kép(balra), MMM szűrővel kapott kimeneti kép (jobbra) [0 255] intenzitáskálán ábrázolva



15. ábra MMM szűrővel kapott különbségi kép

#### 4.2.3. WIENER FILTER

Fourier-térben, illetve képtérben is végezhető szűrési módszer. Az utóbbi az MS (mean squared) módszert veszi alapul és csak zajszűrést végez, simítást nem. A Wiener-szűrő egy lokális, lineáris szűrő, mely az MSE értékét minimalizálja [LLMMSE] a zajjal terhelt és a becsült szűrt kép között, ezzel is megőrizve a vizsgált objektum információtartalmát. Additív (Gauss) zaj esetében lokális adaptív Wiener-szűrő a következő alakban írható fel:

$$\hat{f}(i, j) = \mu(i, j) + \frac{\sigma_f^2}{\sigma_f^2 + \sigma_\eta^2} [g(i, j) - \mu(i, j)] \quad (8)$$

Az eredeti képet úgy becsüljük meg, hogy a szűretlen kép intenzitásértékeiből konvolúcióval kapott várható értékhez hozzáadjuk a szűrt és a szűretlen varianciákkal súlyozott differenciát. Itt feltételezzük a zaj varianciájának pontos ismeretét. A várható érték a zajjal terhelt képnél az alábbi módon definiálható:


$$\mu(i, j) = \frac{1}{(2r + 1)^2} \sum_{p=i-r}^{i+r} \sum_{q=j-r}^{j+r} g(p, q) \quad (9)$$

A becsült kép varianciájának számításakor figyelembe kell venni a zaj additív jellegét, így a zaj szórásnégyszete levonható.


$$\sigma_f^2 = \frac{1}{(2r+1)^2} \sum_{p=i-r}^{i+r} \sum_{q=j-r}^{j+r} (g(p,q) - \mu(i,j))^2 - \sigma_\eta^2 \quad (10)$$

A multiplikatív jelleget úgy vettem figyelembe, hogy a zaj varianciája helyett a globális varianciát alkalmaztam. Emellett a lokális variancia képletében a zaj varianciája nem került levonásra.

$$\hat{f}(i,j) = \mu(i,j) + \frac{\sigma_f^2}{\sigma_f^2 + \sigma_{glob}^2} [g(i,j) - \mu(i,j)] \quad (11)$$



16. ábra Eredeti zajos kép(balra) és a Wiener szűrés eredménye (jobbra)



17. ábra Wiener-filterrel kapott normalizált különbségi kép

#### 4.2.4. WAVELET-TÉRBEN TÖRTÉNŐ SZŰRÉS

A Fourier-transzformációhoz képest a DWT lokálisan vizsgál egy vektort, tehát a lokálisan megjelenő frekvenciakomponensek detektálhatók, a jel lokális tulajdonságaira következtethetünk.

A wavelet-transzformáció során a wavelet és a skálafüggvények együtthatói szerezhethők meg, melyeket különféle küszöbölési technikák mentén szűrhetünk, majd az inverz wavelet-transzformációnál már a szűrt együtthatókat alkalmazzuk

$$f(x) = \sum_k c_{j_0}(k) \varphi_{j_0,k}(x) + \sum_{j=j_0} \sum_k d_j(k) \Psi_{j,k}(x) \quad (12)$$

A  $c_{j_0}$  a skálafüggvény együtthatója,  $d_j(k)$  a wavelet-függvények koefficiense. A wavelet függvények szerinti sorfejtés diszkrét esetre is felírható. Itt  $W_\varphi(j_0, k)$  és  $W_\Psi(j, k)$  lesznek a vizsgált együtthatók.

$$f(n) = \frac{1}{\sqrt{M}} \sum_k W_\varphi(j_0, k) \varphi_{j_0,k}(n) + \frac{1}{\sqrt{M}} \sum_{j=j_0} \sum_k W_\Psi(j, k) \Psi_{j,k}(n) \quad (13)$$

Diszkrét wavelet-transzformáció során alul mintavételezéssel ( $2\downarrow$ ) állíthatók elő a különböző  $j$  szintekhez tartozó együtthatók. Inverz transzformációhoz a  $2\uparrow$  végzése szükséges. Minden lépésben az LL (lowpass) komponenst bontjuk tovább, és így számítjuk ki az irányérzékeny wavelet függvények együtthatóit.

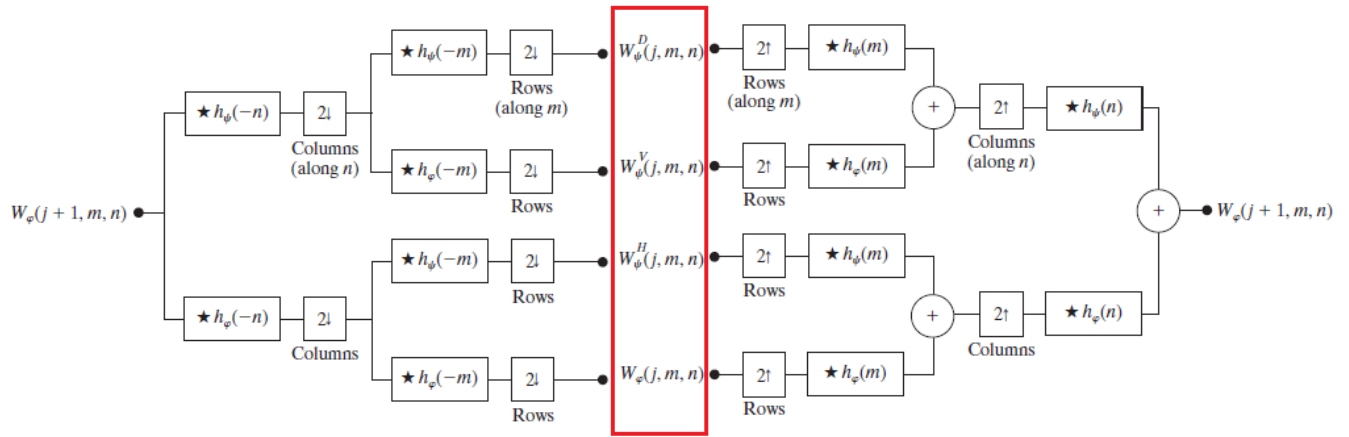
$$\Psi_{LH} = \Psi^H = \Psi(x) \varphi(y) \quad (14)$$

$$\Psi_{HL} = \Psi^V = \varphi(x) \Psi(y) \quad (15)$$

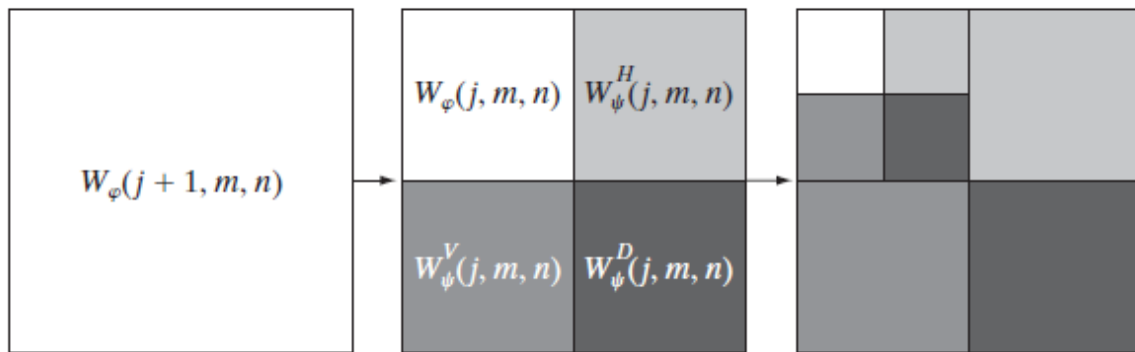
$$\Psi_{HH} = \Psi^D = \Psi(x) \Psi(y) \quad (16)$$

$$\varphi_{LL} = \varphi(x) \varphi(y) \quad (17)$$





18. ábra DWT és iDWT összefoglaló folyamatábrája



A fenti képen piros kerettel kiemelt együtthatók wavelet-térben történő szűrésével lehet elérni a bemeneti kép zajcsökkenését. Ehhez a Bayes-szabályt alkalmaztam. A küszöbérték a becsült zajvariancia és az adott sáv variációjának függvényeként fejezhető ki. A  $\hat{\sigma}_x^2$  a zajos kép variációjára, illetve  $N_k$  az adott sáv wavelet együtthatóinak a száma.

$$\lambda_{Bayes} = \frac{\hat{\sigma}^2}{\hat{\sigma}_s} \quad (18)$$

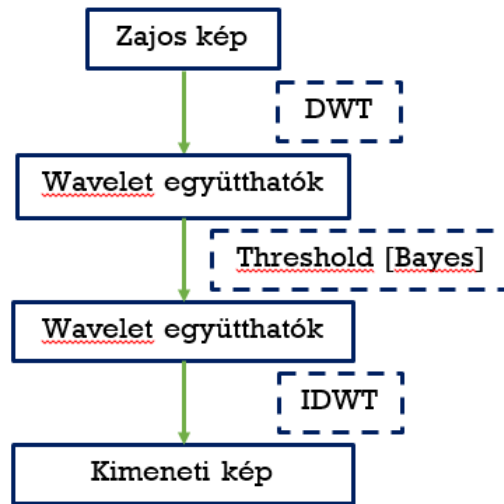
$$\hat{\sigma}_{zaj} = \hat{\sigma} = \frac{\text{medián}(W_{ij} \in HH_1)}{0,6752} \quad (19)$$

$$\hat{\sigma}_s = \sqrt{\max(\hat{\sigma}_x^2 - \hat{\sigma}_{zaj}^2, 0)} \quad (20)$$

$$\hat{\sigma}_x^2 = \frac{1}{N_k^2} \sum_{i,j=0}^{N_k-1} W_{ij}^2 \quad (21)$$

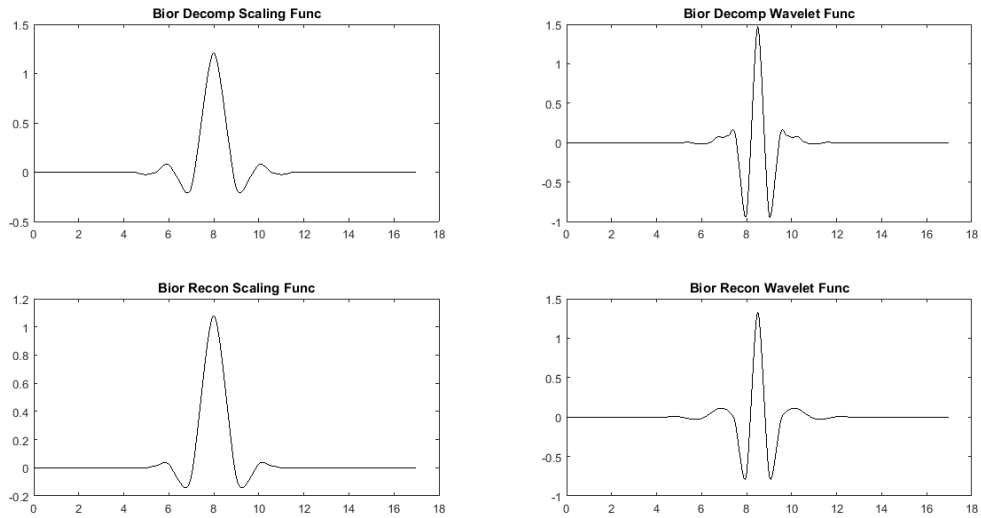
Azt, hogy a küszöbértékeket milyen módon alkalmazzuk, a küszöbölési függvény határozza meg. A lágy küszöbölés pontosabb szűrést ad. Ez azt jelenti, hogy a küszöb alatti értékeket nem elhagyjuk, hanem egy meghatározott értékkel csökkentjük.

$$Y = \text{sign}(X) * (|X| - T) \quad (22)$$




19. ábra DWT-alapú szűrés folyamatábrája


A diszkrét wavelet transzformáció során biortogonális waveletekkel dolgoztam, mivel a biortogonális waveletek rendelkeznek a Haar-waveletek szimmetria tulajdonságával. A koefficiensek kinyerését három felbontási lépésen keresztül végeztem.



20. ábra Biortogonális waveletek dekompozíciós és rekonstrukciós függvényei




21. ábra Zajos eredeti kép (balra) és a DWT szűrés eredménye (jobbra)



22. ábra A DWT szűréssel kapott különbségi kép

#### 4.2.5 HOMOMORF FILTER

Multiplikatív zajok szűrésére alkalmas a homomorf filter. A zajt additív formában a képtérben történő logaritmus transzformáció segítségével érhetjük el. FFT-vel áttérve a frekvenciatérbe felüláteresztő filtert ( $H(u,v)$ ) használunk, ami Fourier-térben konvolúció helyett egy egyszerű szorzást jelent a frekvenciakomponensekkel. Ezt követően IFFT-vel visszatérünk képtérbe. Az inverz Fourier-transzformáció valós részének exponenciális transzformáltját véve végül megkaphatjuk a szűrt kimeneti képet.



23. ábra Homomorf szűrési folyamat

$$\ln(g(i, j)) = \ln(\hat{f}(i, j) * \eta(i, j)) = \ln(\hat{f}(i, j)) + \ln(\eta(i, j)) \quad (23)$$

$$H_{u,v} = \gamma_l + (\gamma_h - \gamma_l) \exp\{-c(D_{u,v}^2/D_0^2)\} \quad (24)$$

$$D_{u,v}^2 = (u - M/2)^2 + (v - N/2)^2 \quad (25)$$

A  $H_{u,v}$  (*filter transfer function*) fenti képletében  $D_0$  a levágási frekvencia,  $[M, N]$  a kép frekvenciatérben lévő mérete,  $\gamma_l$  az alacsony frekvenciák erősítési állandója, és  $\gamma_h$  a magas frekvenciák erősítési állandója. Ez a homomorf szűrő egyszerűbb alakja. További finomítás érhető el, ha a  $H_{u,v}$ -t statisztikai súlyokkal látjuk el.

$$H_{u,v}^* = K_1 + K_2 H_{u,v} \quad (26)$$


$$K_2 = \overline{K_{i,j}} \quad (27)$$

$$K_{i,j} = \frac{1 - \overline{g_{i,j}}^2 \sigma_{i,j}^2}{\sigma_{i,j}^2 (1 + \sigma_{glob}^2)} \quad (28)$$


A  $K_1$  értéke 1,  $K_2$  az összes pixelre kiszámított  $K_{i,j}$  statisztikai mátrix várható értéke, amelynek a képlete tartalmazza a lokális, illetve a globális varianciát. A szűrés frekvenciatérben konvolúció helyett egy egyszerű szorzással is elvégezhető.

$$\widehat{F}_{u,v} = H_{u,v} * G_{u,v} \quad (29)$$

A frekvenciatérben történő szűrést követően inverz FFT-t és exponenciális transzformációt alkalmazva kimeneti képként már egy zajcsökkentett intenzitásmátrix érhető el. Az ilyen formában felírt homorf szűrést MNAHF-nek (*Multiscale Noise-Adaptive Homomorphic Filter*) nevezzük.



24. ábra Eredeti szűretlen kép(balra) és a MNAHF szűrővel kapott különbségi kép (jobbra)



25. ábra MNAHF különbségi képe

Összefoglalva az eddigiek alapján elmondható, hogy a statisztikai alapú szűrők nagyobb mértékben redukálják az eredeti kép intenzitásértékeit. Ez jól látható az egyes szűrők differenciaképei mellett feltüntetett intenzitáskálákból. A homomrf filter, illetve a wavelet-térben történő szűrés csak 1 alatti különbségeket eredményez.

### 4.3.SZŰRŐK KIÉRTÉKELÉSE

Ahhoz, hogy szűrők hatásfokát önmagukban, illetve egymással összevetve értelmezni lehessen,

#### 4.3.1.KÉPMINŐSÉG JELLEMZÉSE

A szűrőket statisztikai alapú képminőségi jellemzők mentén vethetjük össze. Ezen mennyiségek segítséget adnak a leghatékonyabb filter kiválasztásához.

#### **MSE**

Az MSE, vagy átlagos négyzetes hiba arra szolgál, hogy statisztikai megközelítésben kvantitatív értéket adjon a képminőség változásáról. Hátránya, hogy önmagában nem használható, csak más metrikákkal együttesen értelmezhető igazán.

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N [X_{i,j} - Y_{i,j}]^2 \quad (30)$$

#### **SNR**

Az SNR megmutatja, hogy adott kép esetén mekkora a jel-zaj viszony. Minél nagyobb az értéke, annál kisebb a háttérzaj intenzitása a valódi jelszinthez képest.

$$SNR = 10 \lg \left( \frac{\sum_{i=1}^M \sum_{j=1}^N X_{i,j}^2}{\sum_{i=1}^M \sum_{j=1}^N [X_{i,j} - Y_{i,j}]^2} \right) \quad (31)$$

#### **PSNR**

A PSNR a maximális intenzitás négyzetével és az MSE-vel függ össze. Értékének nagysága jellemzi az képhűséget. Minél magasabb, annál inkább közelít a vizsgált kép az eredeti kép (referencia kép) információtartalmához.

$$PSNR = 10 \lg \left( \frac{S^2}{MSE} \right) \quad (32)$$

## CC

A lineáris korrelációs koefficiens megadja a két kép pixelei közötti kapcsolat irányát, illetve az erősségét. A kovariancia és a szórások hányadosaként fejezhető ki. Maximális értéke 1, amit csak abban az esetben érhet el, ha a két kép teljes mértékben megegyezik. Előjele a változás irányáról nyújt információt.

$$CC = \frac{\sum_{i=1}^M \sum_{j=1}^N (X_{i,j} - \bar{X})(Y_{i,j} - \bar{Y})}{\sqrt{\sum_{i=1}^M \sum_{j=1}^N (X_{i,j} - \bar{X})^2 \sum_{i=1}^M \sum_{j=1}^N (Y_{i,j} - \bar{Y})^2}} \quad (33)$$

## SSIM [Szerkezeti Hasonlósági Index]

Az ultrahang kép pixelei nem kezelhetőek úgy, mint független jelek. Ez különösen a szomszédos pixeleknél jelentős. Fontos információt hordoznak egy objektum szerkezetéről ezek a pixelkapcsolatok. Az SSIM mindezt figyelembe véve direkt módon számítja ki az emberi látórendszer (HVS) számára érzékelhető strukturális változásokat.

A hasonlósági index három szempont alapján veti össze az eredeti zajos kép ( $g(i, j) = x_i$ ) és a szűrt kép ( $\hat{f}(i, j) = y_i$ ) pixeleit. A fényesség ( $l$ ) összehasonlítása a pixelintenzitások várható értéke mentén történik. Ez konzisztens a Weber-törvénnyel, ami azt mondja ki, hogy a HVS számára még érzékelhető intenzitásváltozás arányos a háttér intenzitásával, azaz a HVS a relatív intenzitásváltozásra érzékeny. A második komponens a kontrasztot ( $c$ ) méri össze a két kép varianciájának függvényében. Az index utolsó eleme a struktúra ( $s$ ) összehasonlítására szolgál. Itt a várható érték és a variancia is megjelenik a képletben ( $\sigma_{xy}$ ). Ez a tag negatív értéket is felvehet. A három komponens egymástól közel függetlenként kezelhető, azaz az egyik változása a másik két elemre nincs hatással. Az SSIM-nek szimmetrikusnak kell lennie, vagyis adott két képnél az összehasonlítás sorrendje nem befolyásolja az eredményt. A másik feltétel az SSIM-mel szemben, hogy határértékének egynek kell lennie, és a maximum 1 értéket kizárólag csak akkor veheti fel, ha a két kép teljes mértékben azonos.

$$SSIM(x_i, y_i) = [l(x_i, y_i)]^\alpha [c(x_i, y_i)]^\beta [s(x_i, y_i)]^\gamma \quad (34)$$

Az  $\alpha, \beta$  és  $\gamma$  nullánál nagyobb paraméterek segítségével súlyozhatjuk az egyes komponenseket. Ezeket egynek vettem.

$$SSIM(x_i, y_i) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (35)$$

$$\sigma_{xy} = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu_x)(y_i - \mu_y) \quad (36)$$

A  $C_1 (= (K_1 L)^2)$  és a  $C_2 (= (K_2 L)^2)$  konstansok az egyes tagok instabilitásának kiküszöbölésére szolgálnak. Az  $L$  dinamikus tartománytól függenek (jelen esetben 255), és a nevezőben megjelenő nulla értékek elkerülése céljából a nevezőhöz és a számlálóhoz is hozzáadódnak. Mivel a  $K_1$  és a  $K_2$  értékét egynél kisebbnek ( $\ll 1$ ) választjuk meg, ezért a komponensek értékeire elhanyagolható mértékben van hatással.

Az SSIM csak egy lokális ablakon belül vizsgálja a két képet. Egy globális mérőszámot akkor kaphatunk, ha a lokális indexek várható értékét vesszük.

$$MSSIM = \frac{1}{M} \sum_{i=1}^M SSIM(x_i, y_i) \quad (37)$$

,ahol  $M$  az összpixelszámot jelöli, ha minden pixel helyén kiszámítjuk a várható értéket és a szórást.

Az eredeti zajos kép (= referencia kép) és a szűrt kép összevetése csupán a bemeneti képpel való hasonlóságot mutatja meg, a szűrők jellemzésére az ilyen módon történő összehasonlítás nem elegendő.


	Homomorf	Adaptív medián	MMM	DWT	Wiener
<b>MSE</b>	6,0994E+08	6,0994E+08	6,0993E+08	6,0994E+08	6,0995E+08
<b>SNR</b>	0,0342	0,0341	0,0342	0,0341	0,0341
<b>PSNR</b>	7,6250	7,6250	7,6251	7,625025337	7,6250
<b>CC</b>	1	0,9998	0,9993	0,9999	0,9992
<b>MSSIM</b>	0,0937	0,0937	0,0937	0,0937	0,0937

1. táblázat Zajos és szűrt kép összevetése

#### 4.3.2. KÉPMINŐSÉGI JELLEMZŐK ZAJVARIANCIA FÜGGÉSE

A szűrők kiértékeléséhez egy idealizált képet használtam. A vizsgálataim során használt kép segítségével Otsu küszöbölési technikával kaptam egy háromféle intenzitással, homogén szegmensekkel rendelkező képet. A bőrfelszín feletti régiót 10, az epidermist és a léziót körbefogó szövetet 255, a többi pedig 125 értékű intenzitással jelöltem a  $[0,255]$  szürkescálás tartományon.



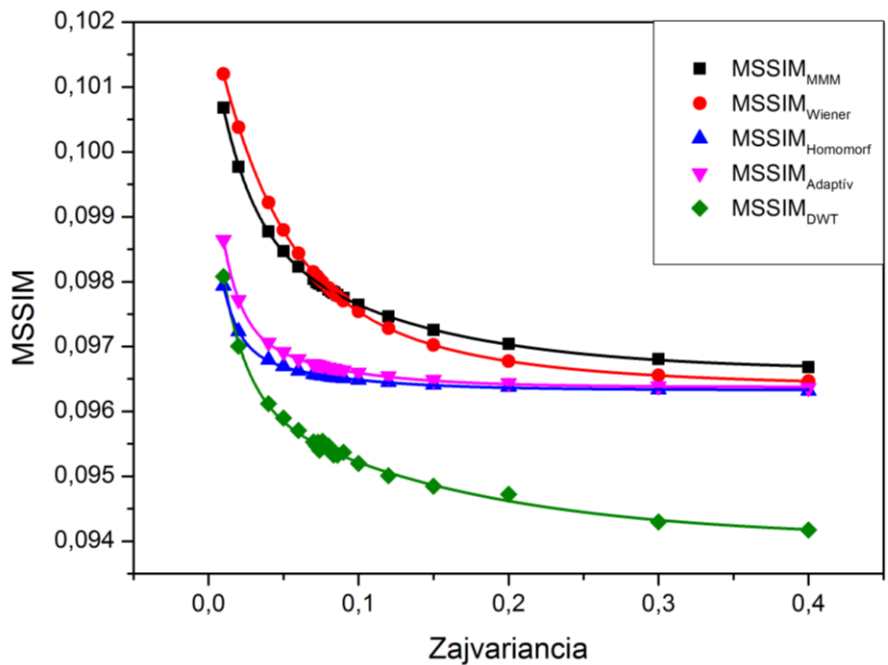


26. ábra Idealizált bőrlézió UH felvétel (fent), zajjal terhelt idealizált kép(lent)

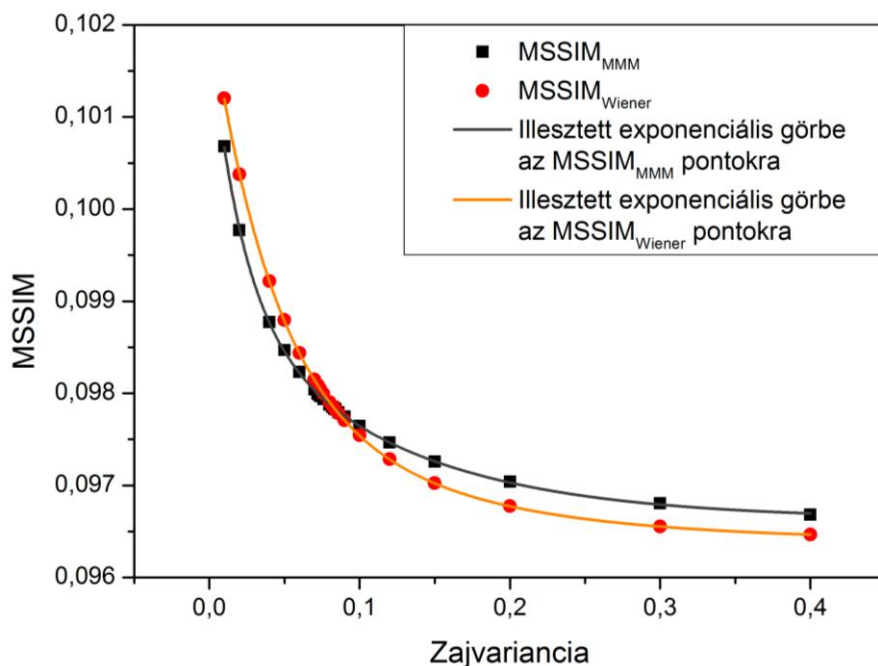
A zajjal terhelt képen alkalmaztam a korábban bemutatott szűrőket, majd a hatásukat úgy vizsgáltam, hogy összevettem az eredeti, zajmentes idealizált képpel a statisztikai paraméterek mentén (MSE, SNR...). Ilyen módon megfigyelhető, hogy a különböző típusú szűrők milyen hatékonysággal képesek visszaállítani az eredeti képet. Nemcsak egy, hanem egy viszonylag nagy tartományban több zajvariancia érték mellett számoltam ki a paramétereket, majd ezeket a zajvariancia függvényében ábrázoltam. A kapott pontokra exponenciális, illetve logaritmikus görbéket illesztettem. Az eredményekből jól látható, hogy nagy zajvariancia mellett minden szempontból az MMM szűrő adódott a legjobbnak, míg kisebb zajvarianciáknál a Wiener szűrő MSSIM, illetve CC tekintetében jobbnak bizonyult. Az MMM és a Wiener filterrel kapott MSSIM-zajvariancia, és a CC-zajvariancia függvények metszéspontjából megállapítható, hogy melyik szűrőt melyik tartományban érdemesebb használni. A szűrők közötti eltérést a variációs együtthatóval jellemeztem, ami százalékos formában a szórás és az átlag hányadosaként írható fel. Ezek alapján az SNR 2-3%, CC 4-6% és az MSSIM 1-2% értékű variációs együtthatóval rendelkezik a zajvariancia függvényében. Az MSE és a PSNR  $\widehat{C}_v$  értéke 0,02 % körül mozog, ezért ezeket elhanyagolhatónak tekintettem. A későbbiekben vizsgáltam, hogy a szűrők eltérő hatása mennyiben befolyásolja a szegmentációs eredményt, illetve a szűrő használatának szükségességét a szegmentációra tett hatása alapján ellenőriztem.

A három, nem elhanyagolható különbséggel rendelkező paraméterek közül elsőként az MSSIM értékének változását figyeltem meg. Ahogyan azt már korábban említettem, a Wiener és az MMM szűrő használatával kapható a legjobb struktúra index. A homomorf és az adaptív szűrők alacsony zajvariancia szint mellett rosszabb eredményeket szolgáltatnak, a két görbe kis

hibával fedi egymást, tehát az MSSIM tekintetében a két szűrő azonos hatású. Nagyobb zajvarianciáknál már jóval kisebb az eltérés a szűrők között, az illesztett exponenciális görbék konvergálnak. A kezdőpontban (0.01) még jelentős differencia nagyobb varianciák esetében jelentősen csökken. Ez alól kivételt képez a DWT szűrő, melyre a 0,1 feletti tartományban a közel nulla meredekségű szakasz az MMM értékének csak a 97%-ra áll be. Összességében az MMM szűrő tekinthető a legoptimálisabb választásnak az MSSIM alapján.



27. ábra MSSIM zajvariancia függése



28. ábra MSSIM zajvariancia függése MMM és Wiener filter esetén

Ahogy azt már korábban is említettem, alacsonyabb zajvarianciánál a Wiener szűrő bizonyult jobbnak. A  $[0, \sigma_{\text{Wiener,max}}^2]$  tartomány megállapításához az adatokra egy exponenciális görbét illesztettem.

$$y = y_0 + A_1 e^{-x/t_1} + A_2 e^{-x/t_2} \quad (38)$$

Itt az  $y = \text{MSSIM}$  és az  $x = \sigma_{\text{zaj}}^2$ . Az MMM és Wiener szűrők görbéi metszik egymást. A metszéspont kiszámításához az illesztésből kapott paramétereket használtam fel, amiket *Originban* végeztem el. A metszéspont megadja a  $\sigma_{\text{Wiener,max}}^2$  értékét, ami azt a maximális zajvarianciát jelöli, amire még teljesül a  $\text{MSSIM}_{\text{MMM}} \geq \text{MSSIM}_{\text{Wiener}}$  feltétel.

$$y_{01} + A_{11} e^{-x/t_{11}} + A_{12} e^{-x/t_{12}} = y_{02} + A_{21} e^{-x/t_{21}} + A_{22} e^{-x/t_{22}} \quad (39)$$

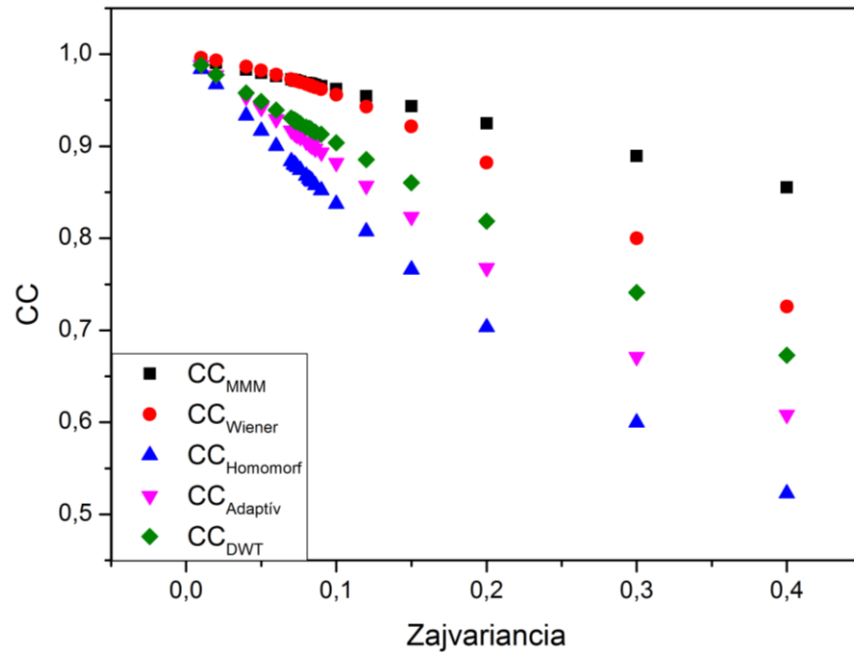
A fenti egyenletből a  $\sigma_{\text{Wiener,max}}^2 = 0,083$  értéket kaptam.

MMM	Érték	$\sigma$	Wiener	Érték	$\sigma$
$y_{01}$	0,09663	1,34E-05	$y_{02}$	0,0964	1,43E-05
$A_{11}$	0,00289	5,06E-05	$A_{21}$	0,00168	1,63E-04
$t_{11}$	0,02091	6,54E-04	$t_{21}$	0,12531	0,00986
$A_{12}$	0,00246	5,51E-05	$A_{22}$	0,00411	1,69E-04
$t_{12}$	0,1099	0,00365	$t_{22}$	0,04235	0,00105

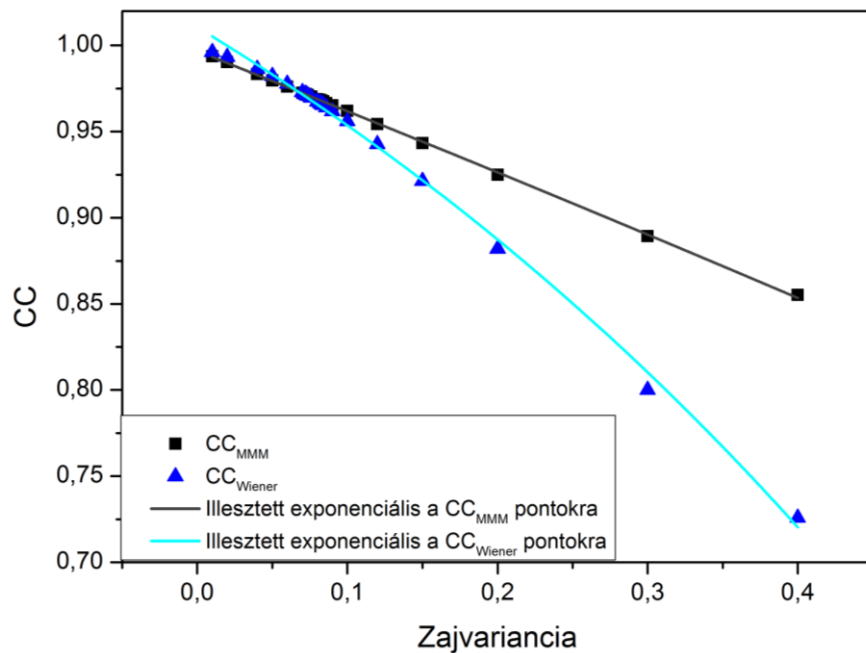
2. táblázat Az illesztett exponenciális lecsengésű görbe paraméterei

A CC görbék a MSSIM görbékkel szemben a nulla körüli kezdőpontban közelítőleg egybe esnek,

majd a zajvariancia értékének növelésével divergálnak. Itt is elmondható, hogy kezdetben  $CC_{\text{Wiener}}$  kis mértékben meghaladja  $CC_{\text{MMM}}$  értékeit, nagy zajvarianciáknál azonban már az MMM szűrő használata javasolt. Az utolsó ábrázolt pontban már közel 40 %-os eltérés tapasztalható a maximális (MMM) és a minimális (homomorf) értékei között. A divergencia mértékét úgy becsültem, hogy a  $CC_{\text{MMM}}$  és a  $CC_{\text{Homomorf}}$  görbékre lineáris közelítésben egyenest illesztettem, majd a két egyenes által bezárt szög felét vettem. Erre a  $15,25^\circ$  értéket kaptam.



A kezdeti szakasz vizsgálatához itt természetes alapú logaritmikus függvényt illesztettem, mivel erre a függvényalakra kaptam a legkisebb illesztési hibát.

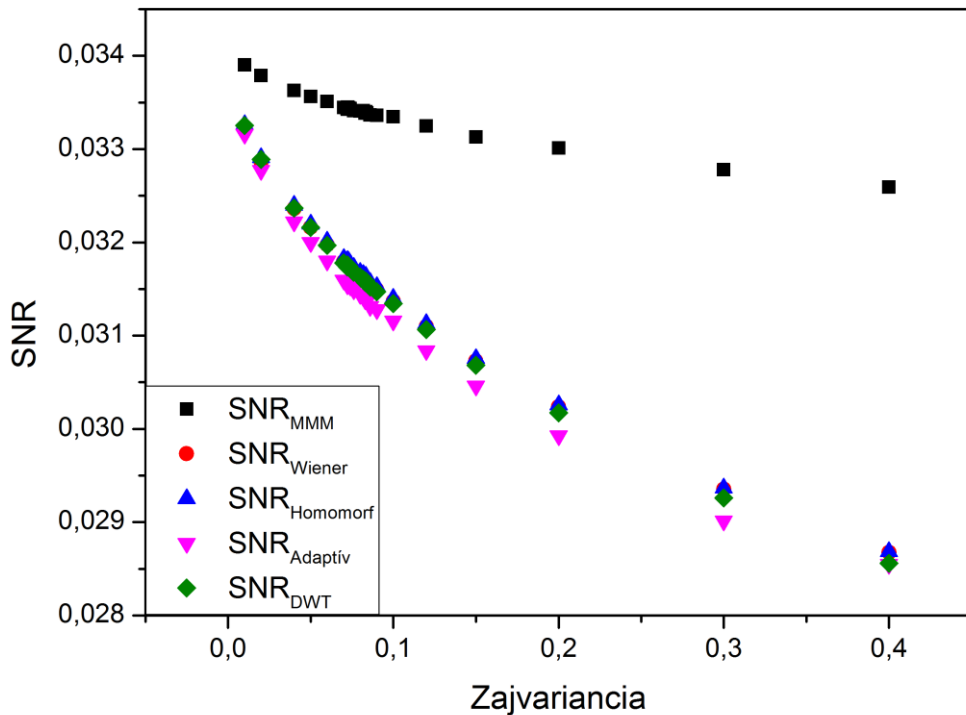


$$y = \ln(a + bx) \quad (40)$$

MMM	Érték	$\sigma$	Wiener	Érték	$\sigma$
$a$	2,7076	6,56E-04	$a$	2,7649	0,0036
$b$	-0,9034	0,0048	$b$	-1,7406	0,0249

3. táblázat Illesztett logaritmikus görbe paramétereit

Ezek alapján a metszéspont helyét kiszámítva azt kaptam, hogy  $\sigma_{\text{Wiener,max}}^2 = 0,0684$  variancia érték felett az MMM szűrővel vett CC értéke magasabb lesz, vagyis az illesztett görbe meredeksége kisebb, ebből fakadóan a zajvariancia növekedésével az 1 ideális (maximális) értéktől való differencia kevesebb lesz, mint Wiener szűrő esetén. Ez a különbség jelentősebb zajoknál ( $\sigma_{\text{zaj}}^2=0.4$ ) akár a 15 %-ot is elérheti.



SNR-zajvariancia görbéből (a CC-hez hasonlóan) is kitűnik, hogy az MMM szűrő görbéje szinte lineárisnak tekinthető, azaz az exponenciális függvény egyenessel közelíthető. Kis meredeksége biztosítja, hogy a jel-zaj viszony nagy zajok esetén is megfelelő mértékű legyen. A Wiener filterhez tartozó pontok a ráülő többi adat következtében lett nehezen észrevehető. Az előzőekkel ellentétben itt a Wienerhez tartozó pontok a többi, kevésbé hatékony szűrő adataihoz hasonló paraméterű exponenciálisan lecsengő görbére ülnek rá. Ez azt jelenti, hogy SNR tekintetében egyértelműen az MMM szűrő a legjobb az 5 szűrő közül. A kezdő  $\sigma_{\text{zaj}}^2=0.01$ , és az utolsó mérési pontot  $\sigma_{\text{zaj}}^2=0.4$  összevetve az SNR értékénél a legjelentősebb a különbség.

Látható, hogy az MMM szűrő mellett csak a Wiener szűrő képes hasonló hatékonysággal a bírni a paraméterek alapján. A két filtert összevetve három különböző pontban az alábbi táblázatban foglaltam össze a Wiener és az MMM paraméterek, illetve a minimális és a maximális értékek százalékban kifejezett arányát.

$\sigma^2_{\text{zaj}}$	SNR			CC				
	SNR <sub>MMM</sub>	SNR <sub>Wiener</sub>	SNR <sub>Wiener</sub> / SNR <sub>MMM</sub> [%]	CC <sub>MMM</sub>	CC <sub>Wiener</sub>	CC <sub>min</sub> (=CC <sub>DWT</sub> )	CC <sub>Wiener</sub> / CC <sub>MMM</sub> [%]	CC <sub>min</sub> / CC <sub>MMM</sub> [%]
0,01	0,0339	0,0332	97,9820	0,9937	0,9961	0,9839	100,2423	98,7772
0,08	0,0334	0,0316	94,7285	0,9688	0,9676	0,8679	99,8711	89,5852
0,4	0,0326	0,0287	<b>87,9805</b>	0,8552	0,7259	0,5228	<b>84,8748</b>	<b>61,1285</b>

4. táblázat SNR és CC értékek összevetése a zajvariancia mentén különböző szűrőkre

$\sigma^2_{\text{zaj}}$	MSSIM				
	MSSIM <sub>MMM</sub>	MSSIM <sub>Wiener</sub>	MSSIM <sub>min</sub> (=MSSIM <sub>DWT</sub> )	MSSIM <sub>Wiener</sub> / MSSIM <sub>MMM</sub> [%]	MSSIM <sub>min</sub> / MSSIM <sub>MMM</sub> [%]
0,01	0,1007	0,1012	0,0981	100,5177	96,9144
0,08	0,0979	0,0979	0,0955	100,0285	1,0255
0,4	0,0967	0,0965	0,0942	<b>99,7736</b>	<b>97,4050</b>

5. táblázat MSSIM értékek összevetése a zajvariancia mentén különböző szűrőkre

#### 4.3.3.SZŰRÉSI MÓD KIVÁLASZTÁSA BŐRULTRAHANG KÉPEKHEZ


Azt, hogy az általam vizsgált ultrahang képek esetében melyik szűrőt alkalmaztam, a képből mintavételezett kis, közel homogén ROI-k zajvariancia elemzéséből kaptam meg. A multiplikatív zajjal (speckle noise) terhelt kép és a zajmentes kép összefüggésében megjelenő  $n$  szorzófaktor egy egyenletes eloszlású, nulla várható értékű random zaj.

$$g = f + n.*f \quad (41)$$

$$PDF[n] = \begin{cases} \frac{1}{b-a}, & \text{ha } a \leq z \leq b \\ 0 & \text{élt} \end{cases} \quad (42)$$

A zaj becsléséhez feltételeztem, hogy a mintavételezett területek mediánja az eredeti zajmentes mintamatrixot jó közelítéssel megadja. A csupa medián pixelértékű mátrixra, ahogyan azt már korábban a képminőségi jellemzők varianciafüggés vizsgálatánál is tettem, a *MatLab imnoise* [] függvényét használtam, azon belül is a multiplikatív [speckle noise] zajjal terhelt kimeneti képet adó képletet alkalmaztam. A bemeneti zajvariancia növelése mellett a kimeneti kép varianciáját számítottam ki. A kapott adatokra egyenest illesztettem, majd az eredeti minta varianciájához tartozó zajvarianciát behelyettesítéssel, illetve az egyenlet átrendezésével kaptam meg. Azaz kiszámítottam, hogy az *imnoise* milyen bemeneti paramétere mellett kapnánk az

eredeti képvarianciát. A mintavételezést három különböző, szöveti struktúraváltozást nem tartalmazó helyről, ugyanolyan 20x20 pixel méretben végeztem el. Mindhárom esetben



29. ábra Mintavételezett, multiplikatív zajjal terhet képmátrixok

kiszámítottam a mintához tartozó *imnoise* bemeneti zajvarianciát. Ezek értéke 0,005 és 0,02 közé esik, négyzetes középértékük 0,0067. A becslés alapján a 0,01 zajvariancia érték körüli ultrahang képeknél a képminőségi jellemzők figyelembevételével a Wiener filter a leghatékonyabb szűrő. Fontos kiemelni, hogy ebben a tartományban a többi szűrőtől való eltérés csupán 1-2%, ami azt jelenti, hogy a többi szűrő választása esetén csak kis mértékben kapunk rosszabb eredményt, vagyis a szegmentációnál a szegmentációs technika hibájához képest elhanyagolható hibát okoz.

## 5.SZEGMENTÁCIÓ

A megfelelő szűrő alkalmazását követő lépés a szegmentálás, melynek során a bőrlézió körvonalát megadó pixeleket szeretnénk meghatározni. Az így kijelölt tartományon belül kvalitatív mennyiségek már egyszerűen számolhatók.


### 5.1.BINARIZÁCIÓS SZEGMENTÁLÁSI MÓDSZEREK

Küszöbölés alapú szegmentálási technikákat két nagy csoportra oszthatjuk: globális és lokális. A globális a teljes kép hisztogramjával dolgozik, míg a lokális csupán a kép adott szegmenséhez tartozó hisztogramját vizsgálja. Az ultrahang képeknél többféle binarizációs technika is alkalmazható: Otsu, Niblack, Sauvola és Wolf.

#### 5.1.1.OTSU KÜSZÖBÖLÉSI TECHNIKA

A módszer alapgondolata, hogy a normalizált hisztogramból kiindulva egy olyan  $T$  küszöbszámot kell keresni, amire maximális lesz az objektum és a háttér közötti variancia ( $\sigma_c^2$ ).

Az Otsu módszer nemcsak egy, hanem több küszöbérték alkalmazására is lehetőséget ad. Ekkor nem egy bináris képet kapunk kimenetként, hanem küszöbértékek számánál eggyel több intenzitású kép lesz.



30. ábra Otsu-féle küszöbölési technika 3 küszöbértékre

#### 5.1.2. NIBLACK

A Niblack binarizációs eljárás egy lokális küszöbölési módszer, azaz egy küszöbérték-mátrixot hozunk létre, amiben az elemek az eredeti kép összes pixeléhez egy helyfüggő küszöbértéket köt. A küszöbérték a lokális várható érték és a szórás súlyozott összegeként kapható meg.

$$T(i, j) = \mu(i, j) + k\sigma(i, j) \quad (43)$$

A  $k$  súly is helyfüggő paramétermátrix, ami a globális és lokális statisztikai értékekkel fejezhető ki.

$$k(i, j) = \frac{\mu_{glob}\sigma_{glob} - \mu(i, j)\sigma(i, j)}{\max(\mu_{glob}\sigma_{glob}, \mu(i, j)\sigma(i, j))} \quad (44)$$


A lokális értékek számításakor 15x15-ös kernelméretet használtam. Figyelembe vettem, hogy a túl nagy kernelméret már nem őrzi meg kellő pontossággal a lokális értékeket.

Az adaptív küszöbölés következményeként „szellem” objektumok jelennek meg. Ezek terület alapú küszöböléssel tüntethetőek el.





31. ábra Niblack binarizáció




32. ábra Terület alapú küszöbölés alkalmazása Niblack binarizációt követően

A végeredményül kapott kép még nem elegendő a jó szegmentáláshoz. A lézió határainak pontosabb meghatározásához a nemnulla szomszédos szegmensek a legközelebbi pontjait kötöttem össze a nagy szegmenssűrűségű területeken. Sajnos ez a módszer nem szolgáltat pontos határokat, csak a lézió pozíciójának leírásában nyújt segítséget.

## 5.2.MEAN SHIFT

A mean shift szegmentáció egy klaszterezésen alapuló eljárás. A pixelek intenzitásértékei és/vagy pozíciója alapján keressük az egy klaszterbe tartozó képpontokat a mean shift vektor segítségével. A képpontokat egy ismeretlen sűrűségfüggvényű (PDF) valószínűségi változó mintáinak tekintjük, amelynek csak a gradiensét szükséges megbecsülni.


A mean shift vektor a lokális sűrűségfüggvény gradiensének maximuma felé tolja el a képpontokat, így létrehozva a klasztereket.



33. ábra Mean shift szegmentáció

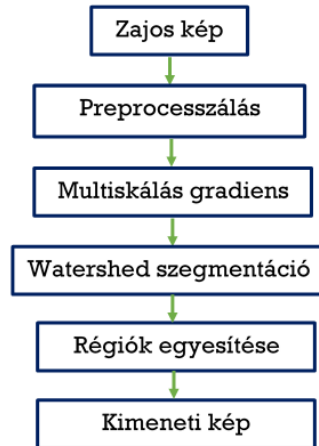
### 5.3. WATERSHED

A watershed szegmentáció alapötlete, hogy a szürkeskálás képre, mint topológiai térképre tekintünk. Ez a szegmentálási technika párhuzamot von a geográfiából ismert fogalmakkal: vízgyűjtő medence a lokális minimumot jelöli, míg a vízválasztó a két vízgyűjtő közötti határvonal, azaz a lokális maximum.



34. ábra Watershed szegmentáció geográfiai alapjai

Ha a WST-t a gradiensképzést követően alkalmazzuk, akkor ideális esetben a vízválasztó vonalak az objektumok széleivel lesznek azonosak. Ez annak köszönhető, hogy a gradiens nagysága az objektumok élei mentén magasak, míg a többi helyen, azonos „szintmagasságú” (közel homogén intenzitású) területeken alacsony értékeket vesz fel.



35. ábra A watershed szegmentáció folyamatábrája

### 5.3.1. GRADIENS

Fontos a megfelelő gradiensképző módszer kiválasztása. Az MG (Multiscale Gradient) használatával megelőzhető a túlszegmentálás, ami WST esetén gyakori probléma. Emellett a zajcsökkentésben (kvantálási hibák, háttérzaj [1]) is szerepet játszik.

A monoskálás morfológiai gradiens a régiók határait a dilatáció és az erózió különbségével adja meg. A dilatáció az adott objektum területét növeli, az erózió pedig csökkenti, tehát a differencia pont a határpixelet adja meg. A strukturáló elem nagysága befolyásolja a kimeneti kép minőségét. Kis kernel esetén nagy felbontás várható, azonban az „intenzitáslejtők” szélei csak alacsony intenzitással jelennek meg a gradiens képen. Nagyméretű strukturáló elem a felbontás romlását eredményezi. Összefoglalva, a monoskálás morfológiai gradiens hátránya, hogy a jó térbeli felbontás és a kellően magas intenzitásértékek a szélek helyén egyszerre nem érhetőek el.

$$G(f) = f \oplus B - f \ominus B \quad (45)$$


Ennek kiküszöbölése lehetséges, ha egy helyett több (multiskálás) különböző méretű strukturáló elemmel is gradienst képzünk.

$$MG(f) = \frac{1}{k} \sum_{i=1}^k [(f \oplus B_i) - (f \ominus B_i)] \ominus B_{i-1} \quad (46)$$


A strukturáló elemekre teljesül a következő feltétel:

$$B_0 \subseteq B_1 \subseteq B_2 \dots \subseteq B_k \quad (47)$$

Az alábbi ábrán is jól látható, hogy a multiskálás módszer nagyságrendekkel felülmúlja a monoskálás gradiens számítási technikát.



36. ábra Monoskálás morfológiai gradiens (kék és piros) és az MG összehasonlítása adott pixelsor pixeltávolság-intenzitás ábrázolásával

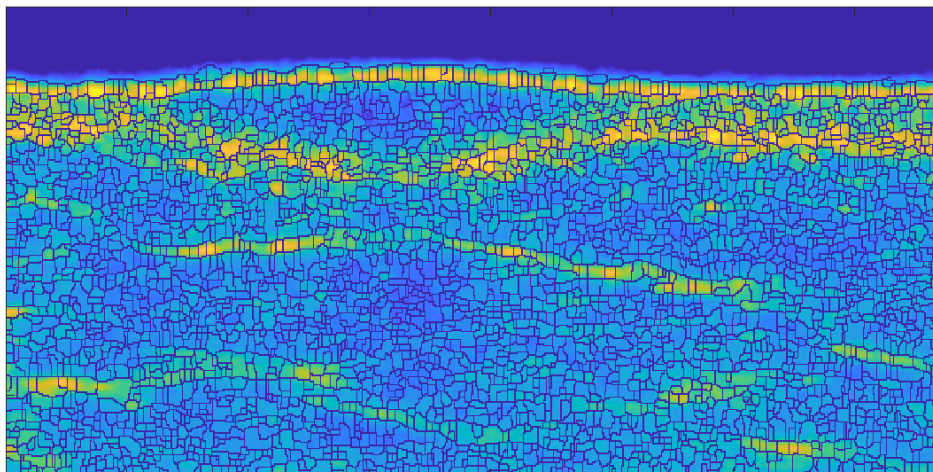


37. ábra Multiscale gradient

A legnagyobb strukturáló elem méretét 7x7 pixelnek választottam, illetve  $B_0$  egyelemű.

### 5.3.2. WATERSHED MÁTRIX

A watershed szegmentációt megelőzően a már korábban leírt Wiener szűréssel csökkentjük a zajt, majd a multiskálás gradiens képet szegmentáljuk. A multiskálás gradiens használatával csökkenthetjük a túlszegmentálás problémáját. A szegmentálásból azonban még így is túl sok kis régiót kapunk. Ezek egyesítése statisztikai alapon történik (statistical merging).




38. ábra Watershed szegmentáció multiskálás gradiens alkalmazását követően

A további műveletek elvégzése előtt egy fontos lépés a nulla pixelintenzitású határok eltüntetése. Ehhez a határokat a watershed mátrix megfelelő régiószámának értékével tettem egyenlővé, ezzel téve az adott szegmens részévé. Ez azért is jelentős, mert a határok az összpixelszám csaknem 23 százalékát képezik. A határokat a többi művelet elvégzését követően rajzoltam vissza, legutolsó lépésben.




39. ábra Watershed mátrix a határok eliminálása után; balról jobbra növekedő régiószám

### 5.3.3. RÉGIÓK EGYESÍTÉSE



40. ábra RAG [Region Adjacency Graph]


A régiók egyesítéséhez első lépésként kiszámítottam a szomszédsági gráfot. Az összes régióhoz tartozó várható érték, illetve pixelszámot (területet) egy vektorba rendeztem a régió indexe alapján. A szomszédok közül kiválasztottam a legkisebb várható érték különbséggel rendelkezőt. Erre a két régióra vizsgáltam meg a várható értékre vonatkozó feltételt. A feltétel teljesülése esetén a két régió unióját képeztem, azaz az eredetileg vizsgált régió indexét kaptam meg a szomszédos régió. Minden iterációt követően frissítettem a watershed mátrix elemeit, illetve a várható értékeket tartalmazó vektort, és a régió területeket. A várható érték mellett a szórás alapú, illetve a szórás/várható érték hányadosára felírt feltétellel is elvégeztem a régióegyesítést. Összességében a várható értékkel történő egyesítés bizonyult a legjobbnak.  $\Delta\mu=40$  mellett az alábbi eredményre jutottam 8500 maximális iteráció után:



41. ábra Várható érték alapú watershed szegmentálás

A várható érték után a kis zárt területeket egyesítettem az azokat körülvevő nagyobb régiókkal. A területnek, másképpen a régióban található pixelek számának nagyobbak kell lennie, mint  $T_{\min}$ . Az előzőekhez hasonlóan itt is iteratív módon jártam el.

A végső lézióhatár berajzolásához kiválasztottam az epidermishez legközelebbi zárt határokkal rendelkező régiót.



42. ábra Szegmentált lézió

A fenti ábrán jól látható, hogy szegmentáció az epidermis egy kis részét is beleveszi a lézió területébe (balra). Ennek oka, hogy azon a kis szakaszon nem elég nagy az epidermis echogenitása. Ennek kiküszöbölésére megszabható, hogy az epidermis egységét a szegmentáció során nem bonthatjuk fel.

## 6.ÖSSZEFOGLALÁS

A diplomamunkám során megvizsgáltam, mely szűrők a legalkalmasabbak az ultrahangra jellemző multiplikatív zaj redukálására különböző zajszintek esetén. Összességében elmondható, hogy az ultrahang képekre jellemző zajszint mellett bármelyik multiplikatív zajok szűrésére alkalmas filter használata megfelelő. A szegmentációs technikák közül a watershed szegmentálási módszerrel sikerült a legpontosabb eredményt elérnem. A következő lépésként a megfelelő korrekciók elvégzését követően, ez az eljárás alkalmas a léziók tulajdonságainak vizsgálatára, ezzel lehetővé téve az eltérő típusok [BCC, melanoma, nevus] jellemzőinek meghatározását.

## 7.KITEKINTÉS

A vizsgálataim során csak az ultrahang felvételek intenzitásmátrixa állt rendelkezésemre. Az analízist pontosítaná az RF adatok feldolgozása, ezzel nemcsak egy morfológiai elemzés végezhető, hanem az egyes rétegek szövettanilag is elkülöníthetők lennének. Ez annak köszönhető, hogy a detektált jelek frekvenciakomponensei eltérőek lesznek a különböző szövetek esetén. Különösen akkor jelentős, amikor két szövettípus intenzitása közel azonos, így csak frekvenciaanalízis útján van lehetőség a szegmentációjukra.

## 8.FÜGGELÉK

A diplomamunka során az alábbi MatLabban írt kódokat használtam. A nem általam írt függvényeknél a forrást külön feltüntettem.



## IRODALOMJEGYZÉK

- [1] Garbe, Claus, and Ulrike Leiter. "Melanoma epidemiology and trends." *Clinics in dermatology* 27.1 (2009): 3-9.
- [2] Jemec, Gregor. *Dermatologic ultrasound with clinical and histologic correlations*. Springer Science & Business Media, 2013.
- [3] Serup, Jorgen, Gary L. Grove, and Gregor BE Jemec. *Handbook of non-invasive methods and the skin*. CRC press, 2006.//Chapter 56.-60.High-Frequency Ultrasound Examination of Skin: Introduction and Guide
- [4] Díaz, Claudia Patricia González. "Characterization of Dermatological lesions by Ultrasound."
- [5] Chami, Linda, et al. "Imaging of melanoma: usefulness of ultrasonography before and after contrast injection for diagnosis and early evaluation of treatment." *Clinical, cosmetic and investigational dermatology* 4 (2011): 1. //Breslow
- [6] Piotrkowska, H. A. N. N. A., et al. "Statistical analysis of ultrasound echo for skin lesions classification." *Hydroacoustics* 15 (2012): 171-178.
- [7] Oláh, Judit Magdolna. *Kockázati tényezők értékelése és új kezelési eljárás alkalmazása bőrdaganatokban*. Diss. SZTE, 2015.
- [8] Bessoud, Bertrand, et al. "High-frequency sonography and color Doppler in the management of pigmented skin lesions." *Ultrasound in Medicine and Biology* 29.6 (2003): 875-879. // tanulmány
- [9] Benameur, Said, Max Mignotte, and Frédéric Lavoie. "An homomorphic filtering and expectation maximization approach for the point spread function estimation in ultrasound imaging." *Image Processing: Algorithms and Systems X; and Parallel Processing for Imaging Applications II*. Vol. 8295. International Society for Optics and Photonics, 2012.
- [10] Dalitz, Christoph, Regina Pohle-Frohlich, and Thorsten Michalk. "Point spread functions and deconvolution of ultrasonic images." *IEEE transactions on ultrasonics, ferroelectrics, and frequency control* 62.3 (2015): 531-544.
- [11] Ranout, Puneet, Anubhooti Papola, and Devesh Mishra. "Conglomeration for color image segmentation of Otsu method, median filter and Adaptive median filter."
- [12] Qiu, Fang, et al. "Speckle noise reduction in SAR imagery using a local adaptive median filter." *GIScience & Remote Sensing* 41.3 (2004): 244-266.
- [13] Krithiga, R. Rani, and C. Lakshmi. "Reduction of Speckle Noise in Ultrasound Images Using MMM Filter." (2017).
- [14] Singh, Prabhishek, and Raj Shree. "A new homomorphic and method noise thresholding based despeckling of SAR image using anisotropic diffusion." *Journal of King Saud University-Computer and Information Sciences* (2017).
- [15] Basak, Kausik, Manjunatha Mahadevappa, and Pranab Kumar Dutta. "Multiscale noise-adaptive homomorphic filtering based speckle denoising in laser speckle imaging." *Computer Vision, Pattern*

*Recognition, Image Processing and Graphics (NCVPRIPG), 2013 Fourth National Conference on.* IEEE, 2013.

[16] Cedarleaf, Jonathan, Steve Philbert, and Arvind Ramanathan. "NOISE CANCELLATION USING LEAST MEAN SQUARES ADAPTIVE FILTER."

[17] Jin, Fu, et al. "Adaptive Wiener filtering of noisy images and image sequences." *Image Processing, 2003. ICIIP 2003. Proceedings. 2003 International Conference on.* Vol. 3. IEEE, 2003.

[18] Vidakovic, Brani. "Nonlinear wavelet shrinkage with Bayes rules and Bayes factors." *Journal of the American Statistical Association* 93.441 (1998): 173-179.

[19] Sulochana, S., and R. Vidhya. "Image denoising using adaptive thresholding in framelet transform domain." *IJACSA) International Journal of Advanced Computer Science and Applications* 3.9 (2012).

[20] Rai, Rajesh Kumar, Jyoti Asnani, and T. R. Sontakke. "Review of shrinkage techniques for image denoising." *International Journal of Computer Applications* 42.19 (2012): 13-16.

[21] Huerta, Gabriel. "Bayesian wavelet shrinkage." *Wiley Interdisciplinary Reviews: Computational Statistics* 2.6 (2010): 668-672.

[22] Sudha, Suresh, G. R. Suresh, and R. Sukanesh. "Speckle noise reduction in ultrasound images by wavelet thresholding based on weighted variance." *International journal of computer theory and engineering* 1.1 (2009): 7.

[23] Silwal, Sharad Deep. "Bayesian inference and wavelet methods in image processing." (2009).

[24] Hiremath, P. S., Prema T. Akkasaligar, and Sharan Badiger. "Speckle noise reduction in medical ultrasound images." *Advancements and Breakthroughs in Ultrasound Imaging.* InTech, 2013.

[25] Soman, K. P. *Insight into wavelets: From theory to practice.* PHI Learning Pvt. Ltd., 2010.

[26] Wang, Zhou, et al. "Image quality assessment: from error visibility to structural similarity." *IEEE transactions on image processing* 13.4 (2004): 600-612.

[27] Deka, Bhabesh, and Debashis Ghosh. "Watershed segmentation for medical ultrasound images." *Systems, Man and Cybernetics, 2006. SMC'06. IEEE International Conference on.* Vol. 4. IEEE, 2006.

[28] Hahn, Horst K.. "IWT – Interactive Watershed Transform: A hierarchical method for efficient interactive and automated segmentation of multidimensional grayscale images." (2003).

[29] Huang, Qinghua, Yaozhong Luo, and Qiangzhi Zhang. "Breast ultrasound image segmentation: a survey." *International journal of computer assisted radiology and surgery* 12.3 (2017): 493-507.

[30] Parvati, K., Prakasa Rao, and M. Mariya Das. "Image segmentation using gray-scale morphology and marker-controlled watershed transformation." *Discrete Dynamics in Nature and Society* 2008 (2008).

[31] Slabaugh, Greg, et al. "Ultrasound-specific segmentation via decorrelation and statistical region-based active contours." *Computer Vision and Pattern Recognition, 2006 IEEE Computer Society Conference on.* Vol. 1. IEEE, 2006.

[32] Thakur, Ashish, and Radhey Shyam Anand. "A local statistics based region growing segmentation method for ultrasound medical images." *statistics* 11 (2004): 12.

- [33] Yang, Qing, and Djamel Boukerroui. "Ultrasound image segmentation using local statistics with an adaptive scale selection." *Biomedical Imaging (ISBI), 2012 9th IEEE International Symposium on*. IEEE, 2012.
- [34] Luo, Yaozhong, et al. "A Novel Segmentation Approach Combining Region-and Edge-Based Information for Ultrasound Images." *BioMed research international* 2017 (2017).
- [35] Zhang, Dong, et al. "A region-based segmentation method for ultrasound images in HIFU therapy." *Medical physics* 43.6Part1 (2016): 2975-2989.
- [36] Pathak, Monika, Harsh Sadawarti, and Sukhdev Singh. "A Comparative Study of Binarisation of Ultrasound Images."
- [37] Farid, S., and F. Ahmed. "Application of Niblack's method on images." *Emerging Technologies, 2009. ICET 2009. International Conference on*. IEEE, 2009.
- [38] Samorodova, O. A., and A. V. Samorodov. "Fast implementation of the Niblack binarization algorithm for microscope image segmentation." *Pattern Recognition and Image Analysis* 26.3 (2016): 548-551.
- [39] Ting, Yun, Gao Mingxing, and Wang Yanming. "Ultrasound image segmentation based on the mean-shift and graph cuts theory." *Indonesian Journal of Electrical Engineering and Computer Science* 11.10 (2013): 5600-5608.
- [40] Comaniciu, Dorin, and Peter Meer. "Mean shift analysis and applications." *Computer Vision, 1999. The Proceedings of the Seventh IEEE International Conference on*. Vol. 2. IEEE, 1999.
- [41] Comaniciu, Dorin, and Peter Meer. "Mean shift: A robust approach toward feature space analysis." *IEEE Transactions on pattern analysis and machine intelligence* 24.5 (2002): 603-619.
- [42] Jähne, Bernd. "Digital image processing. 2002." 29.
- [43] Charbit, Maurice, ed. *Digital signal and image processing using MATLAB*. Vol. 666. John Wiley & Sons, 2010.
- [44] Hansen, Charles D., and Chris R. Johnson. *Visualization handbook*. Academic Press, 2011.
- [45] Gonzales, Rafael C., and Richard E. Woods. "Digital image processing, 2008."
- [46] Dougherty, Geoff. *Digital image processing for medical applications*. Cambridge University Press, 2009.
- [47] Bankman, Isaac N., and Serban Morcovescu. "Handbook of Medical Imaging. Processing and Analysis." *Medical Physics* 29.1 (2002): 107-107.