



BME VIK

# Mellkasröntgen-felvételek regisztrációja wavelet-transzformáció alkalmazásával

TDK DOLGOZAT

**Készítette:** Kapelner Tamás  
**Konzulens:** Orbán Gergely



## Kivonat

A dolgozat egy a tüdőelváltozások szimmetriájának elemzésére alkalmas regisztrációs algoritmust mutat be, mely a regularizációt wavelet-transzformáció alkalmazásával végzi. A fejlett társadalmakban az egyik legelterjedtebb ráktípus a tüdőrák. A korai felismerés érdekében szervezett, általában röntgen-felvételek készítésével és értékelésével végzett szűrések hatékonysága növelhető lenne olyan orvosi döntéstámogató rendszerek segítségével, melyek megkönnyítik a diagnosztika munkáját. A BME Méréstechnika és Információs Rendszerek Tanszéken évek óta folynak mellkasröntgen felvételek számítógépes feldolgozására irányuló kutatások, melyek részét képezi a dolgozatban tárgyalt képregisztrációs eljárás is.

A tüdő kóros elváltozásai jellemzően aszimmetrikusak, így a képletek szimmetriájának vizsgálatával lehetőség nyílik a diagnózis szempontjából releváns információ kiemelésére. A vizsgálat a két tüdő regisztrációjával, majd a regisztrált képek kivonásával történik. A dolgozat a probléma formális ismertetése, és a releváns szakirodalom feldolgozása után bemutat egy elkészült alkalmazást, illetve annak egy továbbfejlesztését, majd megvizsgálja a megoldás hatékonyságát és alkalmazhatóságát. A tárgyalt algoritmus egy wavelet-transzformáción alapuló optimalizációs megközelítést használva végzi el a regisztrációt. A költségfüggvény minimumát a legkisebb frekvenciához tartozó wavelet-koefficienseket használva keresi, emiatt az általa megtalált transzformáció is alacsony frekvenciás lesz, tehát reguláris marad. Az algoritmus a regisztráció alatt a torzulás mértékét folyamatosan ellenőrzi, és korlátok között tartja.

Az eljárás egyik legnagyobb előnye, hogy az eredményül kapott transzformáció az általában szükséges lépések nélkül is reguláris lesz, illetve, hogy a kapott transzformáció tulajdonságai könnyen előírhatóak. Az algoritmus ezen felül megtartja a kóros képleteket, a képeket csak kis mértékben torzítja, és képes úgy elvégezni a szimmetriavizsgálatot, hogy érzéketlen marad a szívárnyékra. A dolgozat az algoritmus eredményességét a JSRT adatbázisból származó, valós mellkasröntgen-felvételeken teszi próbára, majd összehasonlítja az eredményeket létező, korábban különböző területeken sikerekkal alkalmazott regisztrációs megoldásokéval.



## Abstract

The study introduces a registration algorithm for symmetry-analysis of pulmonary lesions, using wavelet transform for regularization. In the developed world one of the most common types of cancer is lung cancer. The effectiveness of the screenings organized to facilitate early detection, usually by obtaining and analysing chest radiographs, could be raised with the help of computer aided diagnostic systems, by assisting the diagnostician. For years, the BME Department of Measurement and Information Systems performed research in digital processing of X-ray images, including the registration algorithm introduced in this study.

Malignant lesions of the lung are characteristically asymmetric, thus symmetry-analysis provides a possibility to emphasize crucial information regarding the diagnosis. The analysis includes a registration of the lungs, and the subtraction of the registered images. First, the study formally reviews the problem, and presents the relevant literature, then introduces a simple application, and an improved version of it, finally verifies the solution in terms of effectiveness and applicability. The discussed algorithm performs the registration using an optimization approach based on wavelet transform. The search for the minimum of the cost function is executed in the domain of the wavelet coefficients corresponding to the lowest frequencies, resulting in a low-frequency, hence regular transformation. The algorithm constantly monitors the amount of image deformation, keeping it under control.

One of the greatest benefits of the method are that the resulting transformation is by all means regular, without having to take further, usually needed steps, and that the characteristics of the resulting transformation are easy to specify. In addition, the algorithm preserves existing lesions, applies only a small-scale distortion, and performs the symmetry-analysis while being insensitive to the hearth shadow. The study examines the effectiveness of the algorithm using chest x-rays from the JSRT database, and compares it to various other, successfully used registration algorithms.



# Tartalomjegyzék

|  |           |
|--|-----------|
| <b>1. Bevezetés</b>                                    | <b>1</b>  |
| 1.1. Orvosi döntéstámogatás . . . . .                  | 1         |
| 1.2. Orvosi képregisztráció . . . . .                  | 2         |
| <b>2. Az algoritmus elméleti alapjai</b>               | <b>3</b>  |
| 2.1. A regisztrációról általában . . . . .             | 3         |
| 2.1.1. A regisztrációs feladat . . . . .               | 3         |
| 2.1.2. Jellemző-alapú megoldások . . . . .             | 4         |
| 2.1.3. Textúra-alapú megoldások . . . . .              | 5         |
| 2.2. Textúra alapú képregisztráció . . . . .           | 6         |
| 2.2.1. Regisztrációs megközelítés . . . . .            | 6         |
| 2.2.2. Az optimalizációs feladat . . . . .             | 6         |
| 2.2.3. Regularitás biztosítása . . . . .               | 7         |
| 2.3. Wavelet-transzformáció . . . . .                  | 9         |
| 2.3.1. A wavelet-transzformációról általában . . . . . | 9         |
| 2.3.2. DWT alkalmazásának motivációja . . . . .        | 10        |
| <b>3. Az algoritmus megvalósítása</b>                  | <b>12</b> |
| 3.1. Az algoritmust körülvevő rendszer . . . . .       | 12        |
| 3.1.1. Tüdőhatárok egyszerűsítése . . . . .            | 12        |
| 3.1.2. Ellenoldali régiók megkeresése . . . . .        | 14        |
| 3.2. Az algoritmus szerkezete . . . . .                | 16        |
| 3.3. Torzulás követése . . . . .                       | 17        |
| 3.4. Az algoritmus továbbfejlesztése . . . . .         | 20        |
| 3.5. Verifikáció és elemzés . . . . .                  | 21        |
| 3.5.1. Az algoritmus általános tulajdonságai . . . . . | 21        |
| 3.5.2. Szintetikus tesztek . . . . .                   | 21        |
| 3.5.3. Optimális képméret megválasztása . . . . .      | 22        |
| 3.5.4. Alkalmazási tesztek . . . . .                   | 24        |
| <b>4. Összehasonlítás más algoritmusokkal</b>          | <b>28</b> |
| 4.1. Démon-algoritmus . . . . .                        | 28        |
| 4.1.1. Elméleti alapok . . . . .                       | 28        |
| 4.1.2. Futási eredmények . . . . .                     | 29        |
| 4.2. SIFT alapú regisztráció vizsgálata . . . . .      | 32        |
| 4.2.1. Elméleti alapok . . . . .                       | 32        |
| 4.2.2. Futási eredmények . . . . .                     | 33        |
| <b>5. Konklúzió és kitekintés</b>                      | <b>36</b> |

# 1. Bevezetés

## 1.1. Orvosi döntéstámogatás

A számítási kapacitás növekedése és a számítástechnikai eszközök orvosi gyakorlatba való integrációja folytán egyre nagyobb szerep jut a modern képfeldolgozási algoritmusok diagnosztikai gyakorlatban való alkalmazásának. Ilyen alkalmazásra példa egy különböző radiológiai eljárások eredményeit autonóm módon feldolgozó kiértékelési algoritmus, mely az orvosi döntéshozatal támogatására hivatott. A fejlett országokban a tüdőrák az egyik legelterjedtebb ráktípus, előfordulás és mortalitás szempontjából is. Ahogy a legtöbb rákos folyamat esetében, kezelésének hatékonyságát legnagyobb mértékben a kórfolyamat előrehaladottsága befolyásolja. A korai felismerés érdekében kulcsfontosságú a rendszeres szűrések szervezése, melyeket általában röntgen-felvételek készítésével és értékelésével végeznek. Az egészségügyre emiatt háruló teher csökkenthető lenne olyan orvosi döntéstámogató rendszerek segítségével, melyek különböző képletek kóros voltának megállapításában nyújtanak segítséget a diagnosztika számára. Főként olyan esetekben mutatkozhatnak meg az ilyen rendszerek előnyei, ha az elváltozások csontok, vagy nagyerek takarásában, esetleg a kép egy kevésbé kontrasztos területén találhatóak. A jelenleg a BME MIT-en futó projekt egy ilyen, számos funkcionalitást integráló számítógépes orvosi döntéstámogató (Computer Aided Diagnostics - CAD) rendszer elkészítését célozza.

A rendszer célja tehát a radiológus döntéseinek támogatása mellkasröntgen-felvételek értékelésekor. A számos alkalmazási lehetőség [vGtHRV01] közül a program a tervek szerint képes lesz többek között olyan intelligens képfeldolgozási műveletek elvégzésére, mint a bordák és a tüdő szövetének a szétválasztása, a szívárnnyék kompenzációja, a tüdő ereinek feltérképezése, kerekárnyékok – azaz kerek, a környezetüknél nagyobb denzitású<sup>1</sup> elváltozások – detektálása stb. Az alkalmazáson belül helyet kap egy szimmetriaanalízist végző részegység is, melynek eredményeit alapvetően két módon használhatjuk fel. Egyrészt a kerekárnyék-detektálás támogatására, mivel a kóros eredetű kerekárnyékok a tüdőben jellemzően nem szimmetrikusak. A két tüdő összehasonlítása segíthet a detektálásban, illetve a fals pozitívok szűrésében is. Ezt az alkalmazási módot kétoldali különbségvizsgálatnak nevezhetjük (Contralateral Subtraction [KHN10]). Másrészt a kóros folyamatok progressziójának nyomon követésére a legegyszerűbb módszer az időbeli különbségvizsgálat (Temporal Subtraction [LMVS03]), mely esetben ugyanarról a betegről különböző időpontokban készült képeket hasonlítunk össze. Jelenleg a dolgozatban tárgyalt alkalmazás a szimmetriaanalízist kizárólag kétoldali különbségvizsgálat megvalósítására használja.

---

<sup>1</sup>A radiológiában egy voxel denzitásán a voxel sugárgyengítési együtthatójának a vízéhez képesti nagyságát értjük. Mellkasröntgen-felvételek esetén a használt sugárzás energiájából következően az elnyelődést a fotoeffektus okozza, ennek bekövetkezési valószínűsége – és így a sugárgyengítési együttható értéke is – a tömegszám harmadik hatványával arányos.



## 1.2. Orvosi képregisztráció

A szimetriavizsgálatok kapcsán felmerül az igény olyan képfeldolgozó eljárás kidolgozására, mely képes különböző képek egymáshoz igazítására, azaz regisztrációjára. Az egymáshoz igazított – regisztrált – képek létrehozása után egy egyszerű kivonással elvégezhető a képek tartalmának összehasonlítását célzó kétoldali különbségvizsgálat. Természetesen egy ilyen megoldásra szükség van időbeli különbségvizsgálat megvalósítása esetén is, progresszió vizsgálatokor. Az orvosi célú regisztráció a klinikai gyakorlatban számos esetben felhasználható, gondoljunk csak a modern orvostudomány által nap mint nap használt képalkotó eljárások (CT, MR, PET, stb.) eredményeinek kiértékelésére, különös tekintettel a multimodalitású eszközök terén (pl. PET-CT). Mindemellett a regisztráción alapuló különbségelemzéses technikák használata a klinikumban még nem elterjedt, de eredményességük alapján a módszerek további térhódítása várható [NOTO02].

A gyakorlati alkalmazások sokrétűségének tudatában nem meglepő, hogy a terület nemcsak gazdag szakirodalommal rendelkezik, de máig az orvosi célú képfeldolgozás intenzíven kutatott részterületei közé tartozik. A dolgozat ennek megfelelően először a regisztrációs feladat elméleti ismertetését tűzi ki céljául. Az általános módszertan után a dolgozat a konkrét megoldás elméleti alapjait ismerteti, majd néhány, az implementációval kapcsolatos kitérő után a módszer eredményességének vizsgálata következik. Az eredmények konkluzív voltát biztosítandó, a dolgozat ismerteti további két, regisztrációra használható algoritmust, valamint futási eredményeiket, melyek összehasonlítási alapként szolgálnak majd a teljesítmény elemzésekor.

## 2. Az algoritmus elméleti alapjai

### 2.1. A regisztrációról általában

Az 1.2. pontban leírtak szerint a képregisztráció két kép egymáshoz igazítását jelenti: a két kép között valamilyen egymáshoz rendelést, transzformációt tételez fel, majd ezt kompenzálja. A regisztráció során kompenzált transzformációknak a következő két felosztását használhatjuk[MV98].

A transzformáció természete szerint:

- merev: translációk és rotációk összessége;
- affin: párhuzamos egyeneseket párhuzamos egyenesekbe transzformál (nyújtás lehetséges);
- projektív: egyeneseket egyenesekbe transzformál;
- elasztikus: egyeneseket görbékbe transzformál, melyek folytonosak maradnak;
- szabad: bármilyen transzformáció megengedett, szakadás is.

A transzformáció által érintett terület szerint pedig lehet lokális, illetve globális attól függően, hogy a kép egy részét, vagy egészét érinti.

Kérdés, hogy ebbe a felosztásba hogyan illeszthetők a mellkasröntgen-felvétel-eken jelentkező transzformációk. Progresszió vizsgálatok a páciensről havi rendszerességgel készülhetnek képek, akár más intézményekben is. Az egyes alkalmakkor a beteg megváltozott elhelyezkedése projektív transzformációként jelentkezik a képen, a háromdimenziós objektumról való kétdimenziós kép készítése során jelentkező információvesztés miatt. A mellkas aszimmetriái — különösen, ha a beteg mellkasa egyébként sem szimmetrikus, pl. gerincferdülés, törött borda stb. — viszont elasztikus transzformációként jelennek meg. Kétoldali regisztráció esetén nem csak a bordák aszimmetriái, és a szívárnyék jelent nehézséget, hanem az egyéni topológiai változatosság is, ezért a legáltalánosabb – szakadás nélküli – feltételezésből, az elasztikus transzformációból érdemes kiindulni. Mondhatjuk tehát, hogy mellkasröntgen-felvételek regisztrációjakor a képek között elasztikus transzformáció vehető alapul.

#### 2.1.1. A regisztrációs feladat

Az általánosan megfogalmazott regisztrációs feladat a következő: adott egy  $f(\mathbf{x})$  intenzitásfüggvénnyel jellemezhető kép, valamint egy  $\mathcal{A}$  torzítás – ez tulajdonképpen egy transzformáció, melyet a képre alkalmazva egy

$$g(\mathbf{x}) = \mathcal{A}\{f(\mathbf{x})\} \tag{2.1}$$

függvényt kapunk. A regisztrációs feladat tehát az  $f(\mathbf{x})$  kép  $g(\mathbf{x})$  képpé való alakítása, mely tulajdonképpen az  $\mathcal{A}$  transzformáció megtalálását jelenti. Általános

esetben ez nem könnyű feladat, megoldására több megközelítési mód is kínálkozik. Mivel több átfogó tanulmány is tárgyalja a problémák és a módszerek jellegzetességeit, illetve mivel a tématerület méreténél fogva a részletes elemzés terjedelmi korlátokba ütközne, a dolgozat a továbbiakban csak a főbb irányvonalakat ismerteti.

### 2.1.2. Jellemző-alapú megoldások

Az első megközelítés szerint jellemzőket kell kijelölni a képeken, ezzel egy olyan ponthalmazt állítva elő, mely csökkenti a probléma komplexitását, mégis lehetőleg minden – de legalábbis minél több, a megoldás szempontjából releváns – információt tartalmaz az adott képről [Bro92].

A pontok kiválasztása történhet szakember bevonásával, illetve különböző képfeldolgozási módszerekkel is. A regisztráció során tehát már csak az így keletkezett pontpárokat kell figyelembe venni (ld. később). A módszer előnye, hogy a regisztrálandó pontok mennyiségét csökkenti, hátránya viszont, hogy igazán hatékonyan csak jól megkülönböztethető ismertetőjegyekkel ellátott képeken (például térképek, kamerafelvételek stb.) használható. A jellemzőpontok szűkösségéből adódó problémát általában vagy anatómiai struktúrák, vagy a kép valamilyen egyéb okból (például éles határ) jellemző területeinek azonosításával oldják meg, melyet elvégezve a regisztrációs feladat megoldása a kevés alkalmazott pont miatt jellemzően kevés számításra igényel [MV98].

Az azonosított struktúrák nem csak jellemző pontok, hanem geometriai alakzatok is lehetnek [JF93], ebben az esetben a képet különböző szegmentációs algoritmusokkal dolgozzák fel, melyek előre meghatározott modellekre (felületek, görbék) osztják fel a vizsgált képet. Az ilyen módszerek számítási komplexitása szintén viszonylag alacsony. Egy további lehetőség a deformálható modellek alkalmazása, ez azonban a számításigény növekedésével jár. Éppen ezért ezek a modellek inkább lokális transzformációk azonosítására alkalmasak, vagy kisebb méretű képek feldolgozására, ahol a számítási idő kevésbé limitáló tényező.

A jellemzők megtalálása után ezekhez olyan jellemző értékeket (ún. deskriptort) kell rendelni, melyek alapján más képek jellemzőivel összehasonlíthatóvá, illetve összerendelhetővé válnak. Természetesen a deskriptor egészen egyszerű is lehet, görbék, illetve felületek esetén például a struktúra alakja, kiterjedése stb. A regisztrálandó és a mintául szolgáló kép jellemzőinek deskriptorait összehasonlítva állapítható meg, hogy azok mennyire tolódtak el, így megkapható a két kép közötti transzformáció egy közelítése. Egy széleskörűen elterjedt, jellemzőpont alapú megoldás részletes ismertetése – a megértéshez szükséges elméleti alapokkal együtt – a 4.2. pontban található.

Egy további ide sorolható megközelítés a – merev transzformációk kompenzálására használható – nyomatékok és főtengelyek módszere. A módszer a kép egyes összefüggő részeinek pontjait ellipszoidokkal burkolja, melyek egyértelműen jellemezhetőek a tengelyek körüli tehetetlenségi nyomatékokkal. A regisztráció során az

egymásnak megfeleltetett ellipszoidok tömegközéppontjának és főtengelyének egymásra illesztése, valamint egy skálázási lépés után az egymásnak megfelelő pontok átfedésbe kerülnek.

### 2.1.3. Textúra-alapú megoldások

A másik megközelítési mód szerint magukat az intenzitásértékeket, tehát a képek textúráját kell egymáshoz illeszteni[ZF03]. Az ilyen, textúra alapú eljárások kevésbé elterjedtek, főleg orvostechikában használatosak. Számításigényük általában jóval nagyobb a jellemzőkkel dolgozó algoritmusokénál. Legegyszerűbb esetben a képen az előzőekhez hasonlóan jellemző értékek megtalálása a cél, ezúttal azonban a textúrából kiindulva, orientációkat és tömegközéppontokat rendelve bizonyos pixelhalmazokhoz, és ezeken végzve regisztrációt<sup>2</sup>. Hasonlóan járhatunk tehát el, mintha jellemző felületeket vagy struktúrákat keresnénk, azonban ezeket nem egy deskriptor alapján hasonlítjuk össze, hanem egy, a kép intenzitásértékeiből számítható hasonlósági mérték szerint. A hasonlóság mértékének megállapítása után a két kép közti transzformáció egy iteráció során áll elő: valamilyen kiinduló leképezés definiálása után a leképezés paramétereinek változtatásával törekszünk arra, hogy a két kép minél inkább egymáshoz igazodjon.

Az előbbi módszer láthatóan egy klasszikus optimalizációs feladat megoldását írja le. Adott egy – kiinduló – leképezés, melynek jósága egy hasonlósági mérték, azaz egy költségfüggvény segítségével írható le. Ezután a leképezés folyamatos változtatásával határozható meg a költségfüggvény minimuma. A leképezés maga tehát a költségfüggvény egy paramétere lesz, a paraméter-optimalizációs feladat megoldása után pedig – a költségfüggvény minimumában – a képek közötti transzformációnak leginkább megfelelő leképezés lesz az eredmény. A dolgozat alapjául szolgáló algoritmus a textúra alapú megközelítési módot használja.

---

<sup>2</sup>Mind ezek, mind a jellemzőpont-alapú módszerek nyilvánvalóan csak valamilyen közelítést adják a keresett transzformációnak, hiszen nem minden képpont esetén történik meg az összerendelés. (A dolgozat a 4.2. pontban erre a problémára még visszatér.

## 2.2. Textúra alapú képregisztráció

### 2.2.1. Regisztrációs megközelítés

Az első fontos feladat, hogy a rendelkezésre álló képeken kijelöljük azokat a területeket, melyeket regisztrálnunk kell. Ezzel kapcsolatban felmerül a kérdés, hogy milyen módszerrel keressük az  $\mathcal{A}$  torzítást.

A globális megközelítés szerint a két kép közötti transzformáció közel azonos a képek különböző részein, ugyanolyan jellegű torzulás hat a kép egészére. A lokális megközelítés szerint a képek fel kell osztanunk kisebb egységekre (a továbbiakban Region Of Interestek, azaz ROI-k), melyeken belül a torzulás uniform jellegű, két különböző ROI esetén azonban más és más lehet. Mivel a globális megközelítések láthatóan merev illetve affin, a lokálisak jellemzően elasztikus torzulások esetén hatékonyak, nem meglepő, hogy a legtöbb elterjedt megoldás coarse-to-fine megközelítést alkalmaz, azaz egy kezdeti, globális transzformáció azonosítása után lokális regisztrációt végez. A két feladatot általában külön apparátus segítségével oldják meg [NHK09], de létezik minden lépésben ugyanarra a módszertanra épülő coarse-to-fine megoldás is [LCC05].

### 2.2.2. Az optimalizációs feladat

A 2.1. egyenletben szereplő  $\mathcal{A}$  torzítás matematikai modellje legáltalánosabb esetben az elasztikus transzformáció esete, mely tetszőleges szakadásmentes elmozdulást megenged – egy  $\Phi(x): \mathbb{R}^2 \Rightarrow \mathbb{R}^2$  folytonos leképezés, melyet a gyakorlatban egy elmozdulásmezővel jellemezhető:

$$g(\mathbf{x}) = \mathcal{A}\{f(\mathbf{x})\} = f(\Phi(\mathbf{x})) = f(\mathbf{x} + \mathbf{u}(\mathbf{x})) \quad (2.2)$$

Megjegyzendő azonban, hogy a későbbiekben transzformálandó modell más szerkezetű is lehet, használható például radiális bázisfüggvények lineáris kombinációjából felépülő függvénymodell, vagy B-spline-ok is [LMVS03]. A regisztráció alapjául szolgáló költségfüggvény megválasztására számos lehetőség áll rendelkezésre [Bro92]. Használhatjuk a két függvény keresztkorrelációs koefficiensét, vagy tulajdonképpen bármilyen, integrális jellemzőt, mely a két kép hasonlóságára utal – léteznek például a jelek kereszt spektrumának használatán alapuló, frekvenciafüggő módszerek is. Az elasztikus módszerek jellemzően a regisztrált és a referenciakép különbségének abszolút, vagy négyzetes integrálját használják.

A költségfüggvény kiválasztása után az  $\mathbf{u}(\mathbf{x})$  változtatásának módját meghatározó módszer kiválasztása következik. Bármilyen optimalizációs módszer használható, a legegyszerűbb, legmeredekebb lejtő, illetve konjugált-gradiens módszertől kezdve a jóval számításigényesebb, lokális minimumokon felülkerekedni képes módszerekig, mint amilyen a szimulált lehülés, vagy a genetikus algoritmusok – igaz, utóbbiak képek regisztrációjára való használata számításigényük miatt nem jellemző.

Fontos azonban, hogy a regisztrált kép ne transzformálódjon át a referenciaképbe, tehát, hogy a transzformáció reguláris maradjon, ne hozzon létre új alakzatokat.

Ez különböző regularitási feltételek költségfüggvényben való alkalmazásával érhető el. A hasonlóság mértékének megállapítására négyzetes különbséget választva a költségfüggvény alakja:

$$J(\mathbf{u}) = \gamma\epsilon(\mathbf{u}) + \frac{1}{2} \int \{f(\mathbf{x} + \mathbf{u}(\mathbf{x})) - g(\mathbf{x})\}^2 d\mathbf{x}, \quad (2.3)$$

ahol  $\epsilon(\mathbf{u})$  az előbb említett regularitást, azaz a költségfüggvény simaságát biztosítandó tag. A klasszikus gradiens-módszernek megfelelően az elmozdulásfüggvény módosítása az algoritmus  $i$ -edik lépésében:

$$\mathbf{u}_{i+1} = \mathbf{u}_i + \eta \nabla J(\mathbf{u})_i, \quad (2.4)$$

ahol  $\eta$  a bátorsági tényező.

Megemlítendő, hogy szigorúan véve az eljárás során a költségfüggvény csak az  $\mathcal{A}$  transzformációra nézve került (lokális) minimumba, mivel  $\mathcal{A}^{-1}$ -re nézve a költségfüggvény – így annak szélsőértéke is – megváltozna. Ez a gyakorlatban azt jeleti, hogy nem feltétlenül kapható ugyanolyan jó illeszkedés egy olyan eljárással, mely az  $f(\mathbf{x})$  kép regisztrációjából kapott elmozdulásmező alapján akarná „visszaszámolni” a  $g(\mathbf{x})$  kép esetén alkalmazandót. Amennyiben a két kép közötti transzformáció további pontosítására lenne szükség, érdemesebb először az egyik, majd a másik kép regisztrációja, majd a két regisztráció eredményének átlagolása, vagy a két transzformáció különbségével való korrekció is – ezek azonban egyelőre nem részei az implementált alkalmazásnak.

### 2.2.3. Regularitás biztosítása

A 2.3. egyenletben szereplő  $\epsilon(\mathbf{u})$  tag megválasztásában segítségünkre lehetnek a természetből vett példák. A regisztrálandó képet valamilyen modellel helyettesítve a regisztrációs folyamat felfogható úgy, mintha ez a modell deformálódna addig, míg a kérdéses kép egybe nem esik a referenciaképpel.

Kézenfekvőnek tűnik az analógia, hogy a regisztráció tulajdonképpen valamilyen anyag(modell) deformációja, melynek hajtóereje valamilyen külső erő – így az elmozdulásmező egy „valós” elmozdulásnak felel meg. Az alkalmazott modell típusát illetően előbb az elasztikus anyagmodellek, majd a viszkózus folyadékok kerültek előtérbe [BK89]. A matematikai modell és a valós feladat között mindkét esetben a deformációt okozó erő teremt kapcsolatot. Az  $f = -\nabla v$  képletnek megfelelően a potenciál, azaz a választott költségfüggvény deriváltja fogja adni az elmozdulásmező változásának a hajtóerejét, nulla értékű derivált esetén a költségfüggvény minimumban lesz, így erő sem hathat a modellre.

#### – Elasztikus modell

Lineáris elasztikus modellt feltételezve a kiindulási egyenleteink egyrészt a Hooke-törvény:  $\epsilon = \mathbf{H}\sigma$ , valamint a szilárd test – elemi hasábjának – esetében felírható

egyensúlyi egyenlet:  $\nabla\sigma + \mathbf{f} = 0$ , ahol  $\epsilon$  és  $\sigma$  az elmozdulás-, illetve feszültség-tenzorok,  $\mathbf{f}$  a testre ható külső erők eredője. Az egyenletekből a feszültségeket és az alakváltozásokat kiküszöbölve a következő összefüggésre jutunk<sup>3</sup>:

$$(\lambda + G)\nabla(\nabla\mathbf{u}) + G\Delta\mathbf{u} + \mathbf{f} = \mathbf{0}. \quad (2.5)$$

Ez az ún. Lamé-egyenlet, az egyenletben szereplő konstansok közül  $G$  a nyírási modulusz,  $\lambda$  a Lamé-állandó. Az elasztikus modell viselkedését leíró egyenlet tehát adott, az egyenletben az erő – ami a nyomástól csak egy skalár szorzóban különbözik, így a szimulációban akár úgy is tekinthetjük, mintha egységnyi felületre hatna – helyére a költségfüggvény deriváltja helyettesítendő. Az így kapott parciális differenciálegyenlet – iteratív – megoldása adja a keresett elmozdulásmezőt.

A differenciálegyenlet numerikus megoldása azonban rendkívül számításigényes, így a gyakorlati alkalmazások zöme a megoldás egy közelítését használja, melynek alapja, hogy a 2.5. egyenletnek megfelelő szerkezetű differenciálegyenletek megoldhatóak egy megfelelő szűrő és az  $\mathbf{u}$  elmozdulás konvolúciójával is [BN96]. A szűrő megválasztásakor további előny, hogy tulajdonságai jól közelíthetők egy Gauss-kernellel. A 2.5. egyenlet egy közelítőleg megfelelő megoldását kapjuk tehát abban az esetben, ha az elmozdulásmező – fizikai példánkban ez felel meg az elmozdulásnak – számítását a korábbi optimalizációs megfontolásoknak megfelelően végezzük, kiegészítve az algoritmust egy szűrési lépéssel.

### – Folyadékmodell

A fentiekhez hasonló úton juthatunk el a viszkózus folyadékokat leíró modellhez is, jelen esetben azonban az összenyomható folyadékokra felírt Navier-Stokes egyenletből kiindulva:

$$-\nabla\mathbf{p} + \left(\frac{1}{3}\mu + \mu^v\right)\nabla(\nabla\mathbf{v}) + \mu\Delta\mathbf{v} + \mathbf{f} = \rho\left(\frac{\partial\mathbf{v}}{\partial t} + \mathbf{v}\nabla\mathbf{v}\right), \quad (2.6)$$

ahol  $\mathbf{v}$  a folyadék sebessége,  $\mu$  a nyíróviszkozitás,  $\mu^v$  a torlóviszkozitás,  $\rho$  pedig a folyadék sűrűsége. Kis Reynolds-számok<sup>4</sup> és stacionaritás feltételezése esetén az egyenlet jobb oldalát, illetve a nyomásgradienst elhagyhatjuk, így az egyenlet formailag azonos lesz a 2.5. egyenlettel, a sebességre felírva [BN96]. Az elasztikus modellek esetén használható konvolúciós megoldás tehát ebben az esetben is alkalmazható, az elmozdulási sebesség, azaz az elmozdulásmező megváltozásának egy megfelelő kernellel való szűrésével.

<sup>3</sup>Szilárd testek mechanikájában ezt a számítási módot „elmozdulásmódszer”-ként tartják számon.

<sup>4</sup>A Reynolds-szám a folyadékáramra jellemző állandó, legszemléletesebb jelentése, hogy nagy (kb. 2000 feletti) Reynolds-szám esetén a folyadék áramlása örvényes, ellenkező esetben laminális.

## 2.3. Wavelet-transzformáció

### 2.3.1. A wavelet-transzformációról általában

A folytonos wavelet-transzformáció (continuous wavelet transform – CWT) alapelve hasonló a rövid idejű Fourier-transzformációéhoz (short time Fourier transform – STFT). Az STFT, ahogyan az nevéből is látható, a jelet egy olyan térbe képezi le, melynek bázisfüggvényei az időben különböző mértékben eltoltt ablakok. Míg azonban az STFT az ablakok konstans eltolását használja az időtartománybeli mintavételezésre, a CWT során használt waveletek – ezek a bázisfüggvények – az éppen aktuális frekvenciamoduláció függvényében változtatják időbeli lokalizáltságukat. A különböző idő- és frekvenciabeli modulációt egy alapfüggvény (Anyá-Wavelet),  $\Psi(t)$  skálázásával érhetjük el:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (2.7)$$

A transzformáció definíciója pedig a következő:

$$W_x^\Psi(a, b) = \mathcal{W}\{x(t)\} = \int_{-\infty}^{\infty} \Psi_{a,b}^*(t) x(t) dt \quad (2.8)$$

A gyakorlatban általában diszkrét eltolásokat, és diadikus skálázást használunk, azaz  $a_k=2^k$ ,  $b_k=mT_k=m2^kT$ , ahol  $T$  az eltolási periódus – ez a DWT. A transzformáció eredményeül minden  $k$ -ra a jel az adott  $a_k$ -nak megfelelő frekvenciatartománybeli komponenseit kapjuk, az időtartományban  $b_k$  szerint felosztva<sup>5</sup>. Ezen túlmenően a transzformáció a skálázási művelet tulajdonságainál fogva alacsony skálázási faktor értékekre kis idő- és nagy frekvenciafelbontást, míg a nagyobb értékekre nagy idő- és kis frekvenciafelbontást biztosít, miközben a jelenergia a skálázás előtt és után állandó marad.

A módszer gyakorlati megvalósításának legjellemzőbb módja a diszkrét transzformáció szűrőbank-interpretációjával történik. A DWT inverze a következő:

$$x(t) = \sum_{k,m} W_x^\Psi(m, k) \tilde{\Psi}_{m,k}(t) \quad (2.9)$$

Az egyenletből látszik, hogy a transzformáció valóban a függvény egy leképezését adja, hiszen a wavelet-koefficiensek megfelelnek a függvény „koordinátáinak” a  $\tilde{\Psi}_{a,b}(t)$  ún. szintézis-waveletek által kifeszített térben. Az analízis- és szintézis-waveletek természetesen összetartozó párokat alkotnak, a matematikai háttér részletes elemzése azonban meghaladja ezen dolgozat kereteit – valójában a dolgozat már a korábbiakban sem említett meg számos, a transzformációval kapcsolatos matematikai sajátosságot (waveletek tulajdonságai, rekonstrukció kritériuma stb. [KSW08]) A 2.9. egyenletet tovább alakítva szemléletes összefüggéshez jutunk:

---

<sup>5</sup> $k$  tehát azt mondja meg, hányszor skáláztuk a képet. Minél nagyobb ez az érték, az approximációs tag annál kisebb frekvenciájú komponenseket tartalmaz.



$$x(t) = \sum_k \sum_m W_x^\Psi(m, k) \tilde{\Psi}_{m,k}(t) = \sum_k y_k(t), \quad (2.10)$$


és legyen

$$x_0(t) = \sum_k y_k(t), \text{ és } x_{k-1}(t) = x_k(t) + y_k(t). \quad (2.11)$$

Ekkor tehát

$$x(t) = x_0(t) = x_1(t) + y_1(t) = x_2(t) + y_2(t) + y_1(t) = \dots \quad (2.12)$$

Az  $x_k(t)$  jel tehát a transzformáció minden  $k$ -adik lépése után két jellé alakul, amely transzformáció – a matematikai háttér kifejtését mellőzve – egy-egy szűrőn való áthaladással, és egy skálázással írható le. A transzformáció menete tehát a 2.1. ábrán látható struktúrának megfelelően képzelhető el. Az  $x_k(t)$  jelek az approximációs, az  $y_k(t)$  jelek a részleteket tartalmazó tagok. Az előzőeknek megfelelően a teljes szűrőbank kimenetén kapott approximációs tag az eredeti jel legkisebb frekvenciájú komponenseit tartalmazza.




2.1. ábra. A DWT szűrőbank-interpretációja.  $h_k$  az alul-,  $g_k$  a felüláteresztő szűrőket jelöli.

A kétdimenziós transzformáció az előzőekben csak annyiban tér el, hogy minden jel két dimenziós (ezért nevezhetjük őket „képeknek” is), így horizontális, vertikális, és diagonális irányban is elvégezzük a transzformációt – tehát minden lépésben 3 db részleteket tartalmazó, és egy approximációs tagot fogunk eredményül kapni. Egy ilyen transzformáció eredménye látható a 2.2. ábrán.

A 3.4. pontban használt DTCWT leírása a függelékben található.

### 2.3.2. DWT alkalmazásának motivációja

A DWT alkalmasnak bizonyult elkészült kerekárnyék-detektorok által produkált falszpozítívok számának csökkentésére [Yos04]. Ez az eredmény adta az ötletet, hogy az eljárás akár a teljes szimmetriaanalízis elvégzésére is alkalmas lehet. Míg azonban [Yos04] a DWT-t a különböző frekvenciák szeparált regisztrációjára használja, a dolgozatban tárgyalt módszer a transzformáció regularitásának biztosítására használja



2.2. ábra. A DWT eredménye  $k=1,2$  esetén, minden lépésben a horizontális (jobbra fent), vertikális (balra lent), és diagonális (balra fent) tagokat, illetve az utolsó approximációs tagot (jobb oldali legalsó kép) ábrázolva.

transzformációs apparátust. Mivel az  $n$ -ed fokú DWT a kiindulási kép méretét dimenzióként a  $2^n$ -edére csökkenti (ezért használják a DWT-t tömörítési eljárásként is), az elmozdulásmezőre alkalmazva az eljárást annak kisfrekvenciás volta biztosítható. Az előző pontban említettek mellett tehát ez egy további módszerként kínálkozik arra, hogy a regisztrációt elvégezzük, a kép regularitásának megőrzése mellett – anélkül, hogy a költségfüggvényt különböző simasági függvényekkel torzítanánk. A cél tehát az, hogy a regisztrációt a transformált tartományban, a legkisebb frekvenciát reprezentáló approximációs tagot gradiens-módszerrel változtatva végezzük.

## 3. Az algoritmus megvalósítása

### 3.1. Az algoritmust körülvevő rendszer

A teljes algoritmus struktúrája alapvetően három részből áll. Első lépésként meg kell találnia a mellkasröntgen-felvételen azt a területet, mely a regisztráció tárgyát képezi. Ez egyrészt a tüdőhatárok megtalálását, másrészt a tüdő határain belül az algoritmus magja által feldolgozható részegységek elkülönítését foglalja magába. A regisztrálandó terület azonosítása után az egyes elkülönített ROI-k regisztrációjának kell következnie, melynek végeztével a regisztrációs feladat tulajdonképpen befejeződött. A keletkezett különbségi kép, illetve a számított elmozdulásmező ezután átadható a vizsgáló szakembernek, illetve további döntéstámogató alkalmazásoknak, melyek képesek például kóros kerekárnyékok identifikálására.

A ROI-k meghatározása tehát az előbbieknél megfelelően több részfeladatot is tartalmaz, mielőtt az eredmény átadható lenne az algoritmus magjának, ami a tényleges regisztrációt végzi. A továbbiakban kifejtett részfeladatokat a 3.1. ábra szemlélteti.

#### 3.1.1. Tüdőhatárok egyszerűsítése

A tüdőhatárok megkeresése a teljes CAD-alkalmazás egyik részfeladata, melynek eredményei a redundancia elkerülése érdekében felhasználhatóak a szimmetriaanalízis során is. A tüdőhatárokat tehát az alkalmazás – a röntgenfelvétel mellett – bemenetként kapja, így az egyetlen további feladat a tüdő határainak egyszerűsítése. Az egyszerűsítés azért szükséges, mert a tüdőhatárokat az alkalmazás csak egy, valamilyen sűrűséggel mintavételezett pontsorozat formájában kapja, a ROI-k kijelölése azonban szisztematikusan, az egész tüdőt minimális átfedéssel lefedve kell, hogy történjen. A regisztrációt végző algoritmus a DWT tulajdonságai miatt<sup>6</sup> előre meghatározott méretű képeken dolgozik, így a megtalált határokon belüli terület felbontása is ekkora régiókra kell, hogy történjen. Az átfedéseknek a redundancia minimalizálása miatt minél kisebbnek kell lenniük, azonban teljes elkerülésük több okból sem tanácsos. Egyrészt a korábbiaknak megfelelően előfordulhat, hogy – például egy eltolás eredményeképp – egyes képletek lekerülnek az ellenoldali képről, vagy mások megjelennek rajta a képen kívüli területről. Másrészt a természet sokkal sokszínűbb annál, mintsem hogy bármely tüdő szélessége egy előre meghatározott képméret egész számú többszöröse lenne, ezért természetes, hogy a képek között függőleges és vízszintes irányban is átfedések lesznek.

Az egyszerűsítés logikája, hogy nem a pontos tüdőhatárokat, hanem csak azok sarokpontjait használjuk fel a ROI-k kijelölésére. Ennek érdekében az algoritmus először kijelöl öt karakterisztikus pontot mindkét tüdőhatár mentén, mely a felosztás

<sup>6</sup>A diadikus skálázás, és a szimmetria miatt a transzformált régió mérete 2 hatványa – vagy annak többszöröse – kell, hogy legyen, és négyzet alakú.




3.1. ábra. A teljes program vázlata

alpjául fog szolgálni. Ezek:

1. A körvonal a kép felső szélének közepéhez legközelebb eső pontja,
2. a körvonal a kép jobb felső sarkához legközelebb eső pontja,
3. a jobb alsó sarokhoz legközelebb eső pont,
4. a kép alsó szélének közepéhez legközelebb eső pont, valamint
5. a kép középvonalának közepéhez legközelebb eső pont.

A felsorolt pontok mentén a tüdő a szükséges pontossággal behatárolható, a szívárnyék legnagyobb része pedig kikerül a vizsgált területéről. A határvonalak megtalálása után a felső határoló-egyenes mentén, majd lefelé haladva – az oldalsó határ-egyeneseken belül maradva – megkapjuk a ROI-kat.



3.2. ábra. Az algoritmus által kijelölt egyszerűsített tüdőhatárok, valamint a gerinc vonalának egyszerű közelítése

### 3.1.2. Ellenoldali régiók megkeresése

A bal tüdő ROI-jainak megtalálása után a jobb tüdőben az ezeknek leginkább megfelelő területeket az alkalmazás keresztkorrelációs módszerrel keresi meg. A módszer lényege, hogy a ROI-t a két tüdő határvonalának egymáshoz legközelebbi pontjainak felező merőlegesére – mely a gerincoszlopot hivatott jelképezni – tükrözve kijelölhető az a terület, ahol az ellenkező oldali ROI valószínűleg elhelyezkedik.

A ROI méreténél a jobb tüdőben egy jóval nagyobb területet kijelölve – mivel az előbbi felező merőleges csak jelképesen felel meg a gerincnek, illetve mivel még a pontos gerincvonal ismeretében sem feltétlenül lenne tökéletesen szimmetrikus a két oldal – határozható meg pontosan, hogy a kijelölt területen belül pontosan hol helyezkedik el a keresett ROI. Ennek legegyszerűbb módja az ellenoldali ROI határait a kijelölt területen folyamatosan eltolva bejárni a terület egészét, eközben kiszámítva a ROI és az ellenkező oldali (eltolt) ROI közti normalizált keresztkorrelációs koefficienszt:

$$\gamma(u, v) = \frac{\sum_{x,y} [f(x, y) - \bar{f}_{u,v}] [g(x-u, y-v) - \bar{g}_{u,v}]}{\sqrt{\sum_{x,y} [f(x, y) - \bar{f}_{u,v}]^2 \sum_{x,y} [g(x-u, y-v) - \bar{g}_{u,v}]^2}}. \quad (3.1)$$

Ez a módszer minden eltolás esetén egy, a két kép közti hasonlósággal arányos mérőszámot szolgáltat. Az így kapott korrelációs együtthatók maximuma a ROI-hoz

legnagyobb ellenoldali ROI-t fogja számunkra kijelölni.

Megjegyzendő, hogy az ellenoldali kép folyamatos tologatása szintén felfogható egy regisztrációs lépésnek, ami azonban csak merev transzformációt feltételez a két kép között, nevezetesen egy eltolást. Tehát ez a fázis felfogható elsődleges regisztrációként, mely a képek közti transzformáció nagy amplitúdójú eltolási komponensét kompenzálja. Mindezek után az alkalmazás elküldi a ROI-t és ellenoldali párját a voltaképpen regisztrációs algoritmusnak.

### 3.2. Az algoritmus szerkezete

A wavelet-transzformációt használó algoritmus a 2.2. pontban leírt módszer számításait a transzformált tartományban végzi, az alapelv azonban ugyanaz. A  $\nabla J(\mathbf{u})$ ban szereplő parciális deriváltak alakja tehát:

$$\frac{\partial J}{\partial \mathbf{U}_a} = \mathscr{W} \{ [f(\mathbf{x} + \mathbf{u}(\mathbf{x})) - g(\mathbf{x})] \frac{\partial f}{\partial \mathbf{x}} \}_a, \quad (3.2)$$

ahol  $\mathbf{U}_a$  az elmozdulásmező wavelet-transzformáltja. Az alsó index az approximációs tagra utal. Ennek megfelelően az elmozdulásmező változtatása az  $n$ -edik lépésben a következő egyenlet szerint történik:

$$\mathbf{U}_a^{n+1} = \mathbf{U}_a^n + \eta \frac{\partial J^n}{\partial \mathbf{U}_a^n}. \quad (3.3)$$

Természetesen, mivel az elmozdulásmezőt csak transzformált-tartományban módosítjuk, az algoritmusnak minden lépésben szintetizálnia kell az elmozdulásmezőt az  $\mathbf{U}_a^n$  koefficiensekből, majd alkalmazni az így kapott transzformációt a képen, hogy  $\mathbf{U}_a^{n+1}$  számítható legyen. Ennek megfelelően az algoritmus lépései:

1. Elmozdulásmező szintézise;
2. Elmozdulásmező alkalmazása az  $f(\mathbf{x})$  képre;
3. 3.2. egyenlet analízise, azaz  $\frac{\partial J}{\partial \mathbf{U}_a}$  előállítás;
4. Elmozdulásmező megváltoztatása a 3.3. egyenlet szerint;
5. Torzulás vizsgálata.

A 2. lépés kivitelezésével kapcsolatosan megemlítendő, hogy – mivel a kép diszkrét formában áll rendelkezésre – az  $f(\mathbf{x} + \mathbf{u}(\mathbf{x}))$  függvény előállításakor interpolációra van szükség. Az algoritmus kétdimenziós lineáris interpolációt használ, melynek eredményeképp a kép torzul. A torzulás – ez voltaképpen homályosodás – mértéke az emberi szem számára nehezen észrevehető, jelfeldolgozási szempontból nagyfrekvenciás, kis amplitúdójú zajként jelenik meg a végső különbségi képen. Az algoritmus futásának ellenőrzése az utolsó lépés során történik, mely az előző pontban ismertetett megfontolások szerint jár el.

Az algoritmus a transzformációhoz Ricker waveletet használ<sup>7</sup> az anya-wavelet simasága miatt. További előnye, hogy mivel a wavelet egy közelítése előállítható Gaussok különbségéből, szükség esetén a számítási idő csökkentése is szóba jöhet a transzformációs tulajdonságok megváltozása nélkül. Az anya-wavelet alakja 1D-ben:

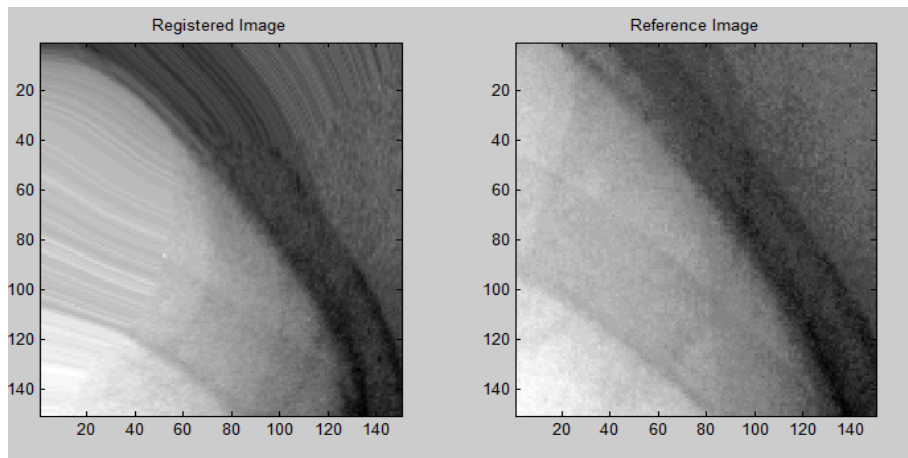
$$\psi(t) = \frac{2}{\sqrt{3\sigma\pi^{\frac{1}{4}}}} \left( 1 - \frac{t^2}{\sigma^2} \right) e^{-\frac{t^2}{2\sigma^2}} \quad (3.4)$$

<sup>7</sup>Angolszász nyelvterületen „mexikói kalap” wavelet

### 3.3. Torzulás követése

Mivel a keresett transzformációnak regulárisnak kell lennie, a regisztrált képek a legkritkább esetben fognak egymásnak tökéletesen megfelelni, különösen, ha az egyik képen kóros képlet is található. A helyzetet árnyalja, hogy elképzelhetőek extrém anatómiai variációk, lényegi intenzitáskülönbségek a képek között, illetve elégtelen minőségű elsődleges regisztráció is, melyek mind azt eredményezik, hogy a két kép erősen eltér egymástól.

Ilyen esetekben elképzelhető olyan reguláris transzformáció is, mely a diagnosztika munkáját nehezíti. Az ilyen transzformációk a kép széleit transzformálják a képen belülre. Minden további nélkül elképzelhető, hogy a kép közepén egy nagy amplitúdójú, vízszintes eltolás legyen megfigyelhető a referenciaképhez képest. Ha viszont ugyanez az eltolás a kép szélén jelentkezik, és a regisztrált képről hiányzik egy képlet, ami a referenciaképen még látható, akkor az algoritmus egyetlen választása a kép szélét „beterjeszteni” a képen belülre. Egy ilyen képpár kész regisztrációját illusztrálja a 3.3 ábra. Elkerülhetetlen tehát a torzulás követése, és a regisztráció leállítása, amennyiben a kapott képpár rosszul kondicionált a regisztráció szempontjából. Hasonló esetek akkor is bekövetkezhetnek, ha a képek intenzitás-eloszlása, vagy a rajtuk szereplő képletek elhelyezkedése szerencsétlen, azaz egymásnak nem megfelelő képletek egyszerűen, reguláris transzformációval egymásba olvashatóak.



3.3. ábra. Képszélek miatti torzulás illusztrációja egy torzuláskövetést nem használó, regularizált Démon-algoritmuson alapuló regisztrációs algoritmus használatával. A torzulást az okozza, hogy a két kép közti merev komponens túl nagy, nagyon el kell tolni a regisztrált képet, ezáltal a kép szélei „beterjednek” a képbe.

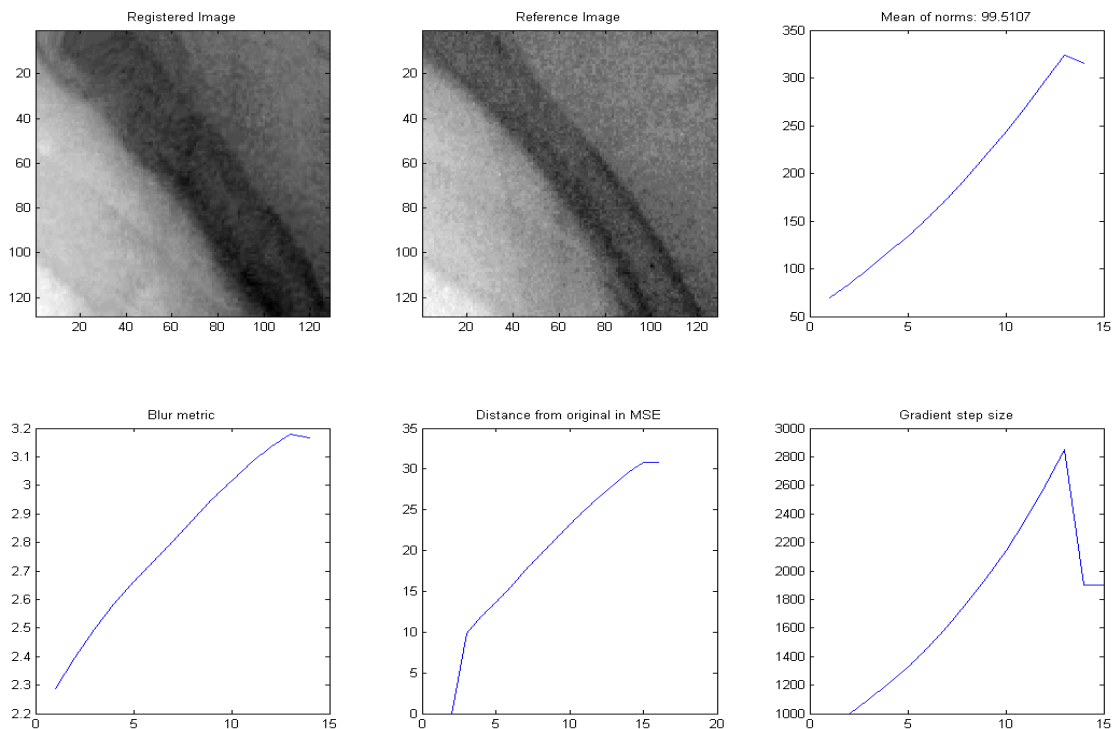
A torzulás követése egyszerűen megvalósítható: torzulás akkor következik be, ha van olyan tartomány, mely felett a transzformáció mértéke – melyet az elmozdulásmező  $\mathbf{u}$  vektorainak  $\|\mathbf{u}\|$  normáival jellemezhetünk – szignifikánsan nagyobb az átlagosnál. Ekkor ugyanis a kérdéses régióba kezd beterjedni egy képlet, a szomszédos régiók azonban nem változnak hasonló mértékben, tehát valószínűsíthető,



hogy itt egy nem kívánatos transzformáció történik. Ez természetesen csak akkor igaz, ha már történt lényegi regisztráció, tehát az  $\|\mathbf{u}\|$ -k nem elhanyagolhatóak. Az ellenőrzést elég elvégezni az elmozdulásmező wavelet-koefficiensein, mely így kevés számítást igényel.

Elméletileg előfordulhat azonban, hogy a két kép közötti transzformáció egy adott tartományra korlátozódjon, és valóban, egyes esetekben ez a módszer túl korán leállítja a regisztrációt, ezzel rontva annak minőségét. A transzformáció „értelmes” voltát ellenőrizni viszont vagy emberi felügyelettel, vagy valamilyen intelligencia implementációjával (pl. neurális hálózat) lenne célravezető. A futási idő jelentős megnövelése mellett mindkét megoldás további megoldandó problémák sokaságát vetné fel. A további fejlesztési lehetőségeket nyitva hagyva, a dolgozat megelégszik a fent vázolt módszer alkalmazásával.

Egy további leállítási feltétel a túl nagy normák jelenléte, mivel ez a tapasztalatok szerint a képet jelentős mértékben torzító oszcillációhoz vezet a lokális minimum körül, ami szintén nem kívánatos. A fenti két módszerrel a torzulások kontrollálhatóak, a számítás közben okozott overhead pedig csekély mértékű.



3.4. ábra. A torzuláskövető rendszer egy ROI regisztrációja közben. A képeken a feliratoknak megfelelő mennyiségek szerepelnek, az optimalizációs lépésszám függvényében. A jobb felső képen az eltolási mező transzformáltjának legnagyobb abszolút értékű tagjának nagysága látható, a tagok abszolút értékének átlaga a kép felett szerepel.

A rendszer megvalósítása során fontos volt a futás folyamatos ellenőrizhetősége, ez nem csak a fejlesztési időt csökkenti, de jobban analizálhatóvá teszi az eredményeket. A 3.4. ábrán a 3.3. ábrának jórészt megfelelő ROI regisztrációjának leállítása utáni eredmény látható. A regisztráció alatt folyamatosan követhető a regisztrált kép változása, illetve a fentiekben tárgyalt jellemző értékek. Az átlagos négyzetes hiba, valamint a bátorsági tényező aktuális értéke szintén ellenőrizhető.

### 3.4. Az algoritmus továbbfejlesztése

Egyre több figyelmet kap a DWT egy továbbfejlesztése, mely ugyanazt a matematikai apparátust felhasználva számos tekintetben kedvezőbb transzformációs tulajdonságokat mutat [SBK05]. Ilyenek például az eltolási és forgatási invariancia, illetve a robusztusság a koefficiensek inverz-transzformáció előtti manipulálására nézve. Az említett módszer a szakirodalomban a Dual-Tree Complex Wavelet Transform elnevezést kapta, így a továbbiakban a dolgozat is DTCWT-ként referál a módszerre.

A részletekbe menő leírást mellőzve<sup>8</sup> a módszer lényege abban áll, hogy a transzformáció alapjául szolgáló waveleteknek komplex értéket ad. Ha emellett az is biztosított, hogy a használt waveletek valós része a képzetes rész Hilbert-transzformáltja legyen, javíthatóak a transzformáció tulajdonságai. Nyilvánvalóan a megkötés teljesítése nem triviális feladat, ennek részleteivel azonban a dolgozat nem foglalkozik, mivel első közelítésben csak a módszer kipróbálása volt a cél, valamint az algoritmus futási idejére gyakorolt hatásának elemzése. Emiatt egy szabadon hozzáférhető, MATLAB alatti transzformációs eszköz használata volt a legkézenfekvőbb lépés [CL10].

Megemlítendő, hogy eleinte a wavelet-transzformáció a MATLAB wavelet-toolbox szolgáltatásaival valósult meg. A DTCWT kipróbálása után azonban egyértelműen kiderült, hogy a toolbox-ban realizált transzformáció szokatlanul rosszul optimalizált, ezért – mivel a DTCWT tartalmaz DWT-t is – a végleges alkalmazás DWT-hez is [CL10] algoritmusát használja.

---

<sup>8</sup>A módszer részletesebb ismertetése a függelékben található.

## 3.5. Verifikáció és elemzés

### 3.5.1. Az algoritmus általános tulajdonságai

A teljesítmény értelmezéséhez és értékeléséhez érdemes összefoglalásként felvázolni az algoritmus főbb tulajdonságait. Az algoritmus a regisztrációt két részben végzi, előbb nagyobb léptékben, egy ROI-n belül állandó eltolást feltételezve. Ezután a finomabb torzulások követésére egy elasztikus transzformációt alapul vevő, optimalizációs megközelítést alkalmaz, négyzetes kritériumfüggvényt használva.

Az algoritmus legfontosabb jellemzője, hogy a wavelet-tartományban dolgozik. Ennek egyik következménye, hogy habár wavelet-tartományban az elmozdulásmező tetszőleges lehet, végső soron mégis egy bázisfüggvény-alapú elmozdulásmező lesz az eredmény, ahol is a bázisfüggvények maguk az egyes – eltolt – waveletek. Más szempontból az is megállapítható, hogy a regularizációs lépés ebben az esetben szükséges, az elmozdulásmező regularitását ugyanis a mező számításának módja biztosítja. További előnye, hogy az ellenoldali régiók kijelölése, és a regisztrációs lépések is függetlenek egymástól, azaz az algoritmus átalakítás nélkül párhuzamosítható, tehát futási idő tekintetében jelentős tartalékokkal rendelkezik.

### 3.5.2. Szintetikus tesztek

Első közelítésben a módszer verifikációja egy mesterségesen előállított kép segítségével történt. Az első feladat tehát két kép közötti, ismert transzformáció megtalálása volt. Hangsúlyos azonban, hogy a helyes megoldás megtalálása csak olyan transzformációk esetén kívánatos, melyek regulárisak.

A kérdéses kép egy valós mellkasröntgen-felvétel egy része, éppen az algoritmusnak megfelelő méretben – ebben a fázisban a képméret még nem lényeges kérdés, csak a megfelelő működés<sup>9</sup>. A képen alkalmazott torzítás egy 10 pixellel való függőleges eltolás, tehát egy merev transzformáció. Hosszas tesztelések után – melyekre a torzulás monitorozásának, és az adaptív bátorsági tényező érzékenységének finomhangolása miatt volt szükség – a 3.5. ábra szerinti eredmény adódott.

Látható, hogy a két kép közötti merev transzformáció kompenzálása megtörténik. Az algoritmus szinte hibátlan eredményt szolgáltat, a képet csak csekély mértékben torzítva. Megjegyzendő, hogy a teszt jól kondicionált esetben történt, az alkalmazás szempontjából azonban a pontos illeszkedés mellett az is fontos, hogy az algoritmus minél változatosabb intenzitás-eloszlású képeken jól működjön.

DTCWT alkalmazásával az eredmény hasonló (3.5. ábra), bár az elmozdulásmező valamivel kevésbé látszik regulárisnak. Természetesen ezzel kapcsolatban érdemi kijelentés csak elegendő mennyiségű kép regisztrációja után fogalmazható meg. További különbség, hogy már szintetikus teszteken is – az elméletnek megfelelően<sup>10</sup> –

---

<sup>9</sup>A későbbiekben sor fog kerülni a megfelelő képméret kiválasztására is.

<sup>10</sup>A DWT számításigénye  $N$  pixelre általában  $O(N)$  nagyságrendű, de függ a használt wavelettől, illetve a megvalósítás módjától is (erről bővebben:[Mal99]). A DTCWT a komplex tagok miatt négyszer annyi műveletet igényel, mint a valós transzformáció (ld. függelék).

érezhető a DTCWT lassú működése a DWT-hez képest.

### 3.5.3. Optimális képméret megválasztása

A regisztrációs algoritmusok működőképessége tehát igazolt. Nyilvánvaló azonban, hogy mind a futási idő, mind a minőség szempontjából fontos tényező a ROI-k mérete. A DWT diadikus skálázása miatt, ha a regisztráció során a wavelet-koefficiensek száma  $n^2$ , az elmozdulásmező – és ezzel a regisztrált ROI-k – elemszáma  $(n * 2^k)^2$ , ahol  $k$  a skálázások száma. Kérdés azonban, hogy 16x16, vagy 768x786 pixel méretű ROI-k esetén lesz e eredményesebb az algoritmus. A kérdés megválaszolásához további tesztek szükségesek.

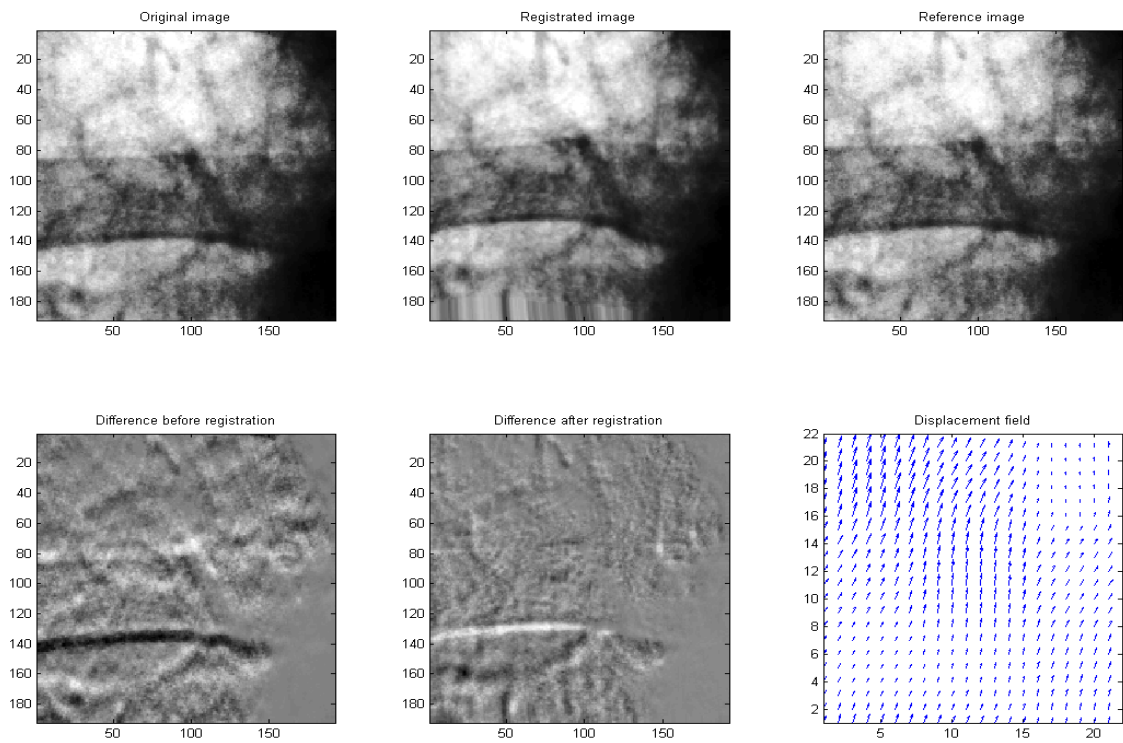
Milyen kritérium szerint állapítható meg, hogy egy adott ROI regisztrációja eredményes volt e? Vizsgálható, hogy milyen pontosan találta meg a keresett transzformációt, azaz, hogy mekkora a számított és a valós elmozdulásmező közötti átlagos különbség. Ehhez azonban elengedhetetlen a ROI és ellenoldali párja között fennálló transzformáció ismerete. Mivel ez szimmetriavizsgálat esetén nem áll rendelkezésre, ezzel az objektív kritériummal csak szintetikus tesztek végezhetőek.

Egy ilyen lehetőség, hogy ha minden regisztrálandó kép egy mellkasröntgen felvétel egy – a tüdőhatárokon belüli – ROI-ja, akkor a hozzá tartozó referenciakép ezeknek a ROI-knak egy ismert elmozdulásmezővel való torzítása legyen. Így a regisztráció után csak meg kell vizsgálnunk az ismert, és a számított vektorok különbségeinek átlagos normáját, és egy objektív mérőszámot kapunk arra nézve, milyen távol van a regisztráció eredménye a helyes megoldástól. Ismert torzításként legjobb egy lineáris és egy elasztikus transzformáció valamilyen kombinációját választani, természetesen minden ROI esetében mást és mást. A választott eltolási mezők alakja:

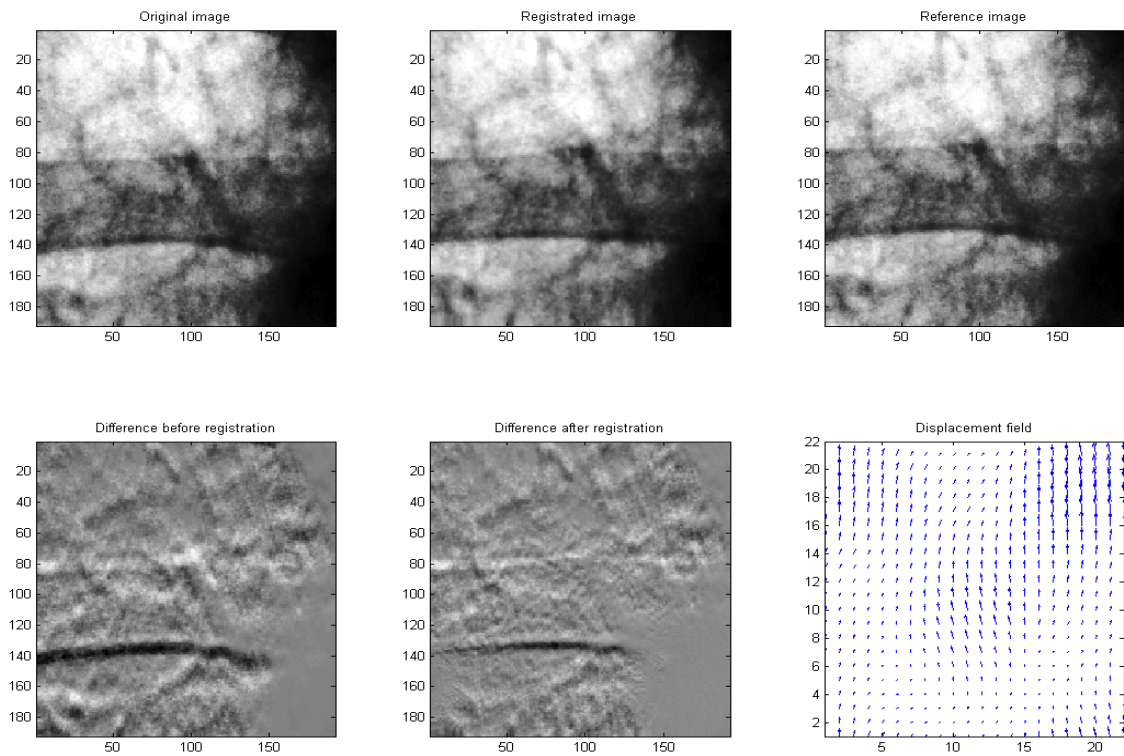
$$\mathbf{u}(\mathbf{x}) = \begin{pmatrix} c_1 + c_2 * \sin(x_1) \\ c_1 + c_3 * \cos(x_2) \end{pmatrix}, \quad (3.5)$$

ahol  $c_1$ ,  $c_2$ , és  $c_3$  normális eloszlású pszeudorandom számok – várható értékük nulla, szórásuk rendre 8, 5, illetve 5. Néhány példát a 3.7. ábra szemléltet. A kérdés eldöntése tehát minden méretre a tüdőhatárokon belül véletlenszerűen kiválasztott 200 db ROI segítségével történt. A ROI-kra a 3.5. egyenlet szerinti elmozdulásmezők által leírt transzformációkat alkalmazva, majd a kapott képeket az eredetire regisztrálva kapott eredmények összesítését az 1. táblázat szemlélteti. A táblázatban a megoldástól való átlagos távolságok normáinak kezdeti négyzetes hibával súlyozott átlaga szerepel. Ennek oka, hogy a képek kevésbé részletgazdag részei – melyeken épp emiatt a kezdeti hiba sem nagy – nyilván kevésbé regisztrálódnak. Ezeket a részeket is ugyanakkora mértékben figyelembe venni, mint azokat, ahol tényleges regisztrációra volt szükség, torzítaná az eredményeket. Ugyanebben a táblázatban szerepelnek az egy felvétel teljes regisztrációjára vonatkozó becsült futási idők is, ezek azonban nem 200-200, csak 20-20 futás eredményei.


Az eredmények alapján látható, hogy a 256x256 pixeles felbontás rendelkezik a



3.5. ábra. A DWT-t használó algoritmus eredménye szintetikus képen



3.6. ábra. A DTCWT-t használó algoritmus eredménye szintetikus képen



3.7. ábra. Néhány véletlenszerűen generált elmozdulásmező az optimális képméret kiválasztásához. Látható, hogy előfordulhatnak szinte kizárólag merev, illetve csak elasztikus komponensek is, a kettő valamilyen kombinációja mellett.

legjobb futási idővel, emellett minősége a negyedik legjobb a jelöltek közül. Mivel minőségben nincsenek akkora különbségek, mint futási időben, és alkalmazhatóság szempontjából a futási idők éppen olyan fontosak, mint a regisztráció minősége, a dolgozat a továbbiakban minden algoritmust erre a felbontásra fog vizsgálni.

### 3.5.4. Alkalmazási tesztek

Az utolsó megválaszolatlan kérdés, hogy valós mellkasröntgen-felvételeken alkalmazva őket, mennyire használhatóak a fentiekben leírt és elemzett algoritmusok. A verifikációs tesztképek halmazát a JSRT adatbázisból származó felvételek alkották

1. táblázat. A DWT alapú regisztrációs algoritmus eredményei a ROI-méret függvényében. Az átlagos futási idő egy ROI-ra értendő, az átlagos távolság pedig a valós és a számított  $\mathbf{u}$  vektorok különbsége normáinak kezdeti hibával súlyozott átlaga.

| ROI mérete (pixel) | Átlagos futási idő (mp) | Átlagos ROI-szám tüdőként | Becsült teljes futási idő (mp) | Átlagos távolság a helyes megoldástól (pixel) |
|--------------------|-------------------------|---------------------------|--------------------------------|---|
| 64x64              | 0,50                    | 190                       | 95                             | 4,04  |
| 96x96              | 0,84                    | 90                        | 75,6                           | 3,7   |
| 128x128            | 1,01                    | 51                        | 51,51                          | 3,0   |
| 192x192            | 1,84                    | 27                        | 49,68                          | 2,36  |
| 256x256            | 2,92                    | 16,0                      | 46,72                          | 2,58  |
| 384x384            | 7,77                    | 7,4                       | 57,5                           | 1,96  |
| 512x512            | 11,09                   | 5,5                       | 61                             | 1,58  |

[SKI<sup>+</sup>10].

A „használhatóság” fogalma jelen esetben több oldalról is megközelíthető. Használható egy regisztrációs eljárás akkor, ha a regisztráció minősége megfelelő. Az előbbiekben alkalmazott objektív mérce, mivel a keresett transzformáció nem ismert, nem alkalmazható. Szintén csalóka a regisztrált kép – az átlagos négyzetes hiba csökkenésével jellemezhető – közeledése a referenciaképhez, mert nem ad információt a torzulás mértékéről, és a lényeges – aszimmetriában rejlő – információ kiemeléséről. Radiológus szakember bevonásával értékelhető lenne az eredmény oly módon, hogy egy adott skálán a szakértő megadja, milyen mértékben tekinti sikeresnek a regisztrációt a diagnózis megkönnyítése szempontjából. Mivel szakértő bevonására a dolgozat írásakor nem volt lehetőség, egy olyan értékelési rendszert kellett felállítani, mely laikus szemmel is képes kijelentéseket tenni a regisztráció minőségéről. Az eredmény ennek megfelelően a következő kategóriákba volt besorolható:

- A: ha a regisztráció eredménye jó. Érdemi regisztráció történt, melynek eredményeképp a különbségi kép simább, átláthatóbb, vagy jobban kiemel egy árnyékot, mely csak az egyik képen van jelen. Mivel itt már a teljes alkalmazás verifikációja a cél, ezért érdemes a kategóriát két részre bontani: tartalmazza  $A_1$  azokat az eseteket, mikor már az elsődleges regisztráció is elégséges a transzformáció kompenzálására,  $A_2$  pedig a jó minőségű másodlagos regisztrációt felmutató eseteket.
- B: ha a regisztráció eredménye nem elégséges. A két kép között ezekben az esetekben látható különbség van, de a képek hasonlóak. Vagy azért elégtelen az eredmény, mert érdemi regisztráció nem történt, vagy, mert bár történt regisztráció, laikus szemmel látható, hogy nem emelte ki eléggé a két kép közti különbséget.
- C: ha a regisztráció eredménye rossz. Ez azt jelenti, hogy az eredményül kapott különbségi kép átláthatatlanabb az eredetinél, zajosabb, esetleg valamilyen artifakt jelenik meg, mely a képek alapján nem lenne indokolt.

Természetesen a felvázolt szempontrendszer nemcsak, hogy nem objektív, de egy laikus megfigyelő általi előfeltevések és az ide vonatkozó szakértelem hiánya által is torzított. Mivel azonban radiológus segítségének igénybevételére a dolgozat keretei között nem volt mód, a verifikációnak jobb híján egy egészségügyi mérnök anatómiai és élettani ismereteire kellett támaszkodnia. A dolgozat természetesen fenntartja az igényt a további, alaposabb verifikációra.

További használhatósági szempont, hogy az algoritmus futási ideje megfelelő e. Egy radiológus egy képet átlagosan 30-60 másodpercig vizsgál, így elvárható, hogy a CAD rendszerek futási ideje ebbe a nagyságrendbe essen. Természetesen szerencsés esetben az alkalmazás már azelőtt megkapja a képet, hogy az a radiológus elé kerülne, de nagyságrendileg mindenképp irányadó lehet a radiológus „adatfeldolgozási idejéhez” viszonyítani – különösen, hogy az algoritmus a CAD rendszernek csak egy részét képezi.



2. táblázat. A regisztrációs algoritmusok verifikációs eredményei. A futási eredmények értelmezése:  $A_1$  - jó minőségű elsődleges,  $A_2$  - jó minőségű másodlagos, B - elégtelen, C - rossz minőségű

| Algoritmus                       | Átlagos futási idő (mp) | Nem regisztrálható ROI-k (%) | Futási eredmények (%) |       |      |     |
|----------------------------------|-------------------------|------------------------------|-----------------------|-------|------|-----|
|                                  |                         |                              | $A_1$                 | $A_2$ | B    | C   |
| DWT normál képeken               | 39,4                    | 70,9                         | 22,5                  | 31,5  | 40,4 | 5,6 |
| DTCWT normál képeken             | 40,1                    | 68,9                         | 36,9                  | 32,6  | 30,5 | 0   |
| DWT bordaárnyék-mentes képeken   | 208,9                   | 70,5                         | 22                    | 38,4  | 32,9 | 6,7 |
| DTCWT bordaárnyék-mentes képeken | 208,3                   | 65,6                         | 33,3                  | 35,2  | 29,6 | 1,9 |

A teljes rendszer lehetőséget kínál a bordaárnyékok eltávolítására is. Mivel bordaárnyék-mentes képek előállítására más alrendszereknek is szüksége lehet, érdemes megvizsgálni, nem lenne-e szerencsésebb ilyen, bordaárnyék-mentes képeken végezni a regisztrációt. Az algoritmusok verifikációja erre a kérdésre is kitért. Az algoritmusokként 20 képen való futtatás eredményeit a 2. táblázat szemlélteti.

Amint látható, a futási időre előírt követelményeket a DWT-t használó algoritmus teljesíti, sikeressége azonban mérsékelt. Ennek legfőbb oka a nem megfelelően összepárosított, és ezért nem regisztrálható képek magas aránya. A nem regisztrálható ROI-k az elsődleges regisztrációs lépés után sem voltak kellő átfedésben ellenoldali párjukkal, a gerincvonal kijelölésének elégtelensége miatt. A gerincvonal kijelölése<sup>11</sup> ugyanis nem veszi figyelembe sem a tüdőhatárok kijelölésének hibáit, sem a gerinc esetleges hajlását, vagy függőlegestől való eltérését. Emiatt gyakran pontatlan a ROI-párok kijelölése, azaz akkora eltolás marad a képek között az elsődleges regisztráció után is, melyet a másodlagos nem tud kompenzálni – hiszen utóbbi kis mértékű, elasztikus transzformációkat feltételez. Az ebből adódó hibák megelőzéséhez egy robotus gerincvonal-detektáló algoritmusra lenne szükség, melynek kidolgozása igen összetett feladat, így a dolgozat kereteit nagymértékben meghaladná.

Megfigyelhető ugyanakkor, hogy amely esetben érdemi regisztráció történhetett volna, előfeldolgozás nélkül az esetek felében, míg a bordaárnyékok eltávolításával az esetek kétharmadában történt jelentős javulás a különbségi képen, a két eredeti kép különbségéhez képest. A regisztráció sikeressége azonban sok esetben elmarad az elvárttól. Ennek oka többnyire a képek intenzitás-eloszlásának markáns különbözősége, jellemzően az egyik oldalon egy nagyobb denzitású borda, vagy sűrű vénás fonat jelenléte miatt, azaz valamilyen anatómiai variáció következtében. Ez a jelenleg rávilágít egy fontos szempontra a regularizációval kapcsolatban is.

A bordaárnyékok elhagyásával bekövetkező jelentős javulás ugyanis magyarázható azzal, hogy a lágy szövetek regisztrációja más jellegű regularizációt igényel, mint a csontoké. Nyilvánvaló, hogy csontok esetében kisebb a lehetséges anatómiai variációk száma, illetve azok bonyolultsága sem éri el a lágy szövetek esetében

<sup>11</sup>Emlékeztetőül, a gerincvonal modellje a két tüdőhatár egymáshoz legközelebbi pontjainak felező merőlegese.

láthatóakat. Egy reguláris transzformáció nem lehet olyan jellegű, hogy a csontok – vagy a tüdőhatárok – meghajoljanak, szélük hullámossá váljon stb., míg erek esetében ez könnyen elképzelhető – a csontok és a lágy szövetek egy röntgenképen viszont átfedésben vannak. Így tehát az a transzformáció, mely lágy szövetek esetén még regulárisnak minősíthető, bordák esetén már nem az – ezért a regisztrációt a torzuláskövető rendszer korábban, vagy épp túl későn állítja le. A regularizáció és a torzuláskövetés tehát egy rendkívül komplex kérdéskörként jelenik meg, mely további vizsgálatokra adhat okot.

A DTCWT-t használó megoldás futási ideje az elméletileg indokoltnál is jobban meghaladja az előírt korlátokat, tehát nemcsak, hogy a transzformációhoz kell több idő, az optimalizáció is tovább tart. Másrészt megfigyelhető, hogy a hibás találatok száma csökkent. Ennek oka nem az, hogy az elsődleges regisztráció más eredménnyel járt, hanem hogy a DTCWT ugyanazokkal a beállításokkal nagyobb transzformációkat képes realizálni, ezáltal nagyobb eltolások kompenzálására képes. Ez a tulajdonság a magyarázat a rossz minőségű regisztráció megnövekedett arányára is: egyes esetekben az eredményül kapott transzformáció túl nagy mértékben torzít. A módosított algoritmus számításigénye miatt azonban kijelenthető, hogy ilyen követelmények mellett a DTCWT komoly átalakítás nélkül nem alkalmazható regisztrációra, annak ellenére, hogy eredményei sok esetben jobbak a hagyományos DWT-vel elérteknél.

A szimmetriaanalízis tehát nem eredménytelen, kérdéses azonban, hogy ilyen mutatók mellett alternatívát jelent e az elterjedtebb módszerekkel szemben. A következőkben a dolgozat ezt a kérdéskört járja körül.

## 4. Összehasonlítás más algoritmusokkal

### 4.1. Démon-algoritmus

#### 4.1.1. Elméleti alapok

A Démon-algoritmus egy textúra alapú képregisztrációs eljárás, mely szerkezetileg analóg a 2.4. egyenlet által leírt módszerrel. Elméleti alapjai azonban más talajról, a képregisztrációs probléma diffúziós folyamatként való leírásából származnak[Thi96].

A módszer lényege, hogy a referenciaképen található képleteket képzeletben kontúrokkal körülvéve, melyek mentén – hasonlóan ahhoz, ahogy Maxwell tette a gázte-  
reket elválasztó membrán esetében – démonokat helyez el. Ezek a démonok képesek eldönteni a regisztrálandó kép megfelelő pontjairól, hogy a referenciaképen lévő, a körvonal által körülvett képlethez tartoznak e, vagy nem. Ennek megfelelően mozgatják a regisztrált képet addig, míg a referenciaképpel átfedésbe nem kerül.

Legegyszerűbb esetben a kép minden egyes képpontjára egy démon kerül, mely meghatározott erővel mozgatja a regisztrált kép megfelelő pixelét. Az egyes képpontokra ható erők eredőjéből számítható a teljes transzformáció, azaz az elmozdulásmező. A korábbiaknak megfelelő szimbólumrendszer használatával jellemezve az  $i$ -edik lépésben az elmozdulásmező változtatásának értéke:

$$\mathbf{u}_{i+1} = \mathbf{u}_i + \eta \frac{(g(\mathbf{x}) - f(\mathbf{x} + \mathbf{u}(\mathbf{x}))) \nabla g}{\|\nabla g(x)\|^2 + (g(\mathbf{x}) - f(\mathbf{x} + \mathbf{u}(\mathbf{x})))^2} \quad (4.1)$$

A démon algoritmus fenti, legegyszerűbb megvalósítása nem igényli az egyes pontokra ható erők explicit számítását. Más módszerek esetében – például ha csak bizonyos képletek körvonala mentén találhatóak démonok – erre szükség lehet. Természetesen a fenti egyenletnek megfelelő transzformáció irreguláris, azaz elég iterációt elvégezve tökéletesen egymásba alakítja a két képet. Ennek megelőzése végett egyrészt szükség van a transzformáció regularizálására, másrészt a kép torzulásának monitorozására is. A regularizáció az elmozdulásmező Gauss-kernellel történő szűrésével történik, minden változtatás után. Az algoritmus lépései tehát:

1. Inicializáció
2. Az elmozdulásmező a 4.1. egyenletnek megfelelő módosítása
3. Elmozdulásmező szűrése Gauss-kernellel
4. Elmozdulásmező alkalmazása a regisztrált képre
5. Az így kapott kép elemzése torzulás szempontjából
6. Túlzottan nagy/kis torzulás esetén  $\eta$  csökkentése/növelése, szükség esetén az utolsó reguláris állapot visszaállítása

7. Konvergencia elérése esetén kilépés, különben újratekés 2-tól

A monitorozás nem a 3.1. pontban leírtaknak megfelelően történik, mivel a Démon-algoritmus nem wavelet-tartományban dolgozik, az amplitúdót túl sok pontban kellene ellenőrizni. Ehelyett a ko-okkurrencia mátrix segítségével meghatározott kölcsönös entrópia megváltozásával ellenőrizhető a torzulás mértéke. Erről bővebben a függelék ad tájékoztatást.

**4.1.2. Futási eredmények**

A Démon-algoritmus esetében a funkcionalitás nem is lehet kérdés. Amennyiben az implementáció helyes, az algoritmusnak működni kell, hiszen már számos esetben bizonyított. Ennek okán a szintetikus tesztek elhagyva csak valós ROI-párok is tesztelhető az algoritmus funkcionalitása. Egy ilyen eredményt mutat be a 4.1. ábra. Amint látható, az implementáció helyes, a regisztráció megtörténik, és a torzulás sem nagy mértékű, a monitorozásnak köszönhetően.


Kérdés, hogy hogyan teljesít ez a megoldás a dolgozatban tárgyalthoz képest. Ennek illusztrálására készült a 4.2. ábra, mely ugyanazon a képpáron történt regisztrációt mutat, mint az előző esetben, most azonban DWT-t használva. Amint látható, ez esetben nincs lényegi különbség a két megoldás között. A Démon algoritmus által számított elmozdulásmező inkább globális jellegű, viszont egy kicsit nagyobb normákkal rendelkezik az ideálisnál, tehát a torzulás miatti leállítás ezen a képen túl későn történt. A DWT alapú megoldás ezzel szemben lokálisabb jellegű eredményt ad, emiatt kevésbé képes nagymértékű globális elmozdulások kompenzálására, másrészt viszont a transzformáció kevésbé is torzít.

Az előzőekben ismertetett használhatósági kritériumokat alkalmazva vizsgálható a Démon-algoritmus használhatósága is. Az előzőleg használt 20 bordaárnyék-mentes képen való verifikáció eredményeit – a korábbiakkal összehasonlítva – a 3. táblázat tartalmazza.

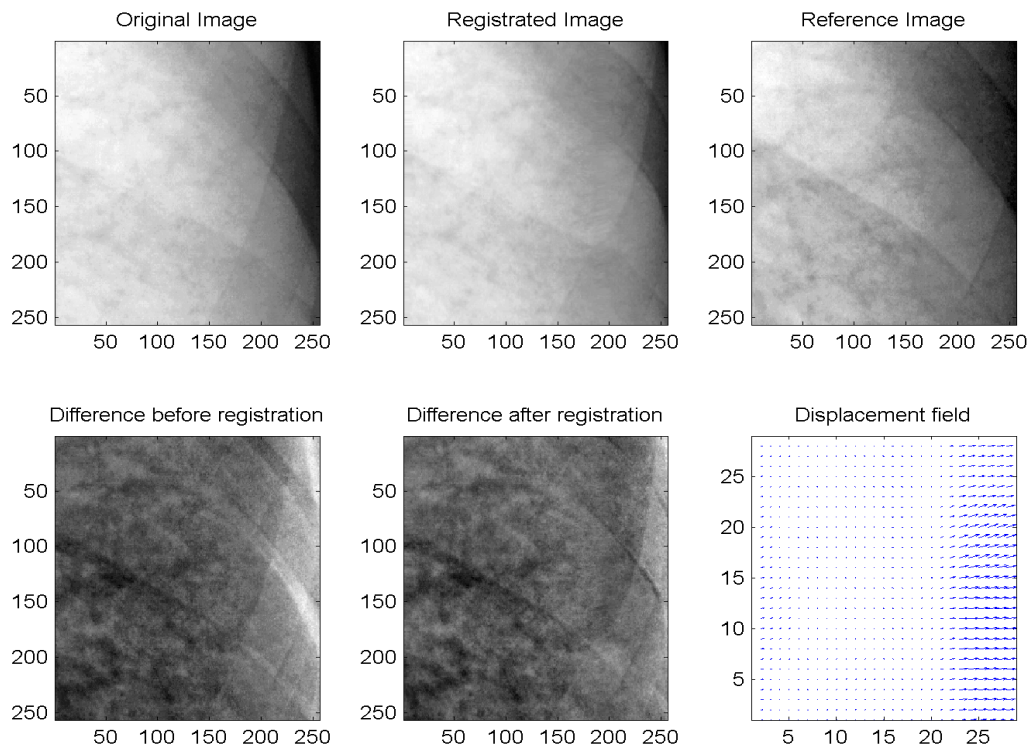
3. táblázat. A Démon-algoritmus verifikációs eredményei. A futási eredmények értelmezése:  $A_1$  - jó minőségű elsődleges,  $A_2$  - jó minőségű másodlagos, B - elégtelen, C - rossz minőségű

| Algoritmus | Átlagos futási idő (mp) | Nem regisztrálható ROI-k (%) | Futási eredmények (%) |       |      |     |
|------------|-------------------------|------------------------------|-----------------------|-------|------|-----|
|            |                         |                              | $A_1$                 | $A_2$ | B    | C   |
| Démon      | 118,8                   | 64,3                         | 31,3                  | 42,8  | 23,2 | 2,7 |
| DWT        | 40,1                    | 68,9                         | 36,9                  | 32,6  | 30,5 | 0   |
| DTCWT      | 221,2                   | 65,6                         | 33,3                  | 35,2  | 29,6 | 1,9 |

Amint látható, a Démon-algoritmus futási ideje csak csekély mértékben haladja meg az elvártakat, regisztrációs teljesítménye pedig átlagosan jobb, mint a dolgozatban bemutatott algoritmusoké. Látható, hogy a nem regisztrálható ROI-k száma itt a legalacsonyabb, azaz az algoritmus képes nagyobb eltolások kompenzálására is,



4.1. ábra. A Démon-algoritmus eredménye egy valódi ROI-páron



4.2. ábra. A DWT alapú algoritmus eredménye a 4.1. ábrának megfelelő képpáron

annak árán azonban, hogy egyes esetekben a túl nagy torzulások akadályozhatják a diagnosztika munkáját. Bár ezek az esetek ritkák, előfordulási gyakoriságuk a másik két algoritmus esetében kisebb. A DWT alapú megoldás futási ideje alapján kitűnő jelölt szűrővizsgálati alkalmazásokhoz.

Kijelenthető tehát, hogy a dolgozatban bemutatott algoritmusok eredményessége nagyságrendileg azonos egy már kiforrott, széles körűen használt algoritmuséval. Ez az algoritmus textúra alapú, így az alternatív lehetőségek vizsgálata nem lenne teljes egy jellemzőpont-alapú megoldás alkalmazhatóságának elemzése nélkül. Az egyik legelterjedtebb ilyen módszer a SIFT algoritmuson alapul.

## 4.2. SIFT alapú regisztráció vizsgálata

### 4.2.1. Elméleti alapok

A Scale Invariant Feature Transform (SIFT) algoritmus az előbbiektől teljesen eltérő módon működik. A 2.1. pontban leírtaknak megfelelően két szerkezeti egység vizsgálendő jellemzőpont-alapú algoritmusok esetén: a detektor és a deskriptor.

#### – A detektor működése

A detektor alapvetően két részfeladatot lát el [Low04]. Az első a tér leképezése egy skálatérbe (scale-space), ahol olyan pontok kereshetők, melyek függetlenek a kép skálázásától. Az algoritmus leképezést különböző  $\sigma$ -val rendelkező Gauss-eloszlásokkal való konvolúción keresztül valósítja meg. A konvolvált képeket ezután egymásból páronként kivonva olyan függvényeket állít elő, melyek kiválóan alkalmasak skálázástól független jellemzőpontok elkülönítésére (DoG-képek: Differences of Gaussian). A skálázástól való függetlenség elérése érdekében a szűrt képeket feleakkora frekvenciával újrámintavételezve megismétli a DoG függvények előállítását – egészen addig, amíg megfelelően kis felbontást el nem ér. A skálatér tehát különböző oktávokból áll, minden oktávban különböző mértékben skálázott DoG képekkel. A jellemzőpontok ezután a keletkezett DoG képek skálatérbeli szélsőértékei lesznek (tehát egy adott pixel intenzitását a saját, és a két szomszédos DoG képen is összehasonlítja a környezetével). A detektor szerkezete tehát:

1. Skálatérbeli leképezés oktávonként:  $L(\mathbf{x}, \sigma_k) = f(\mathbf{x}) * g(\mathbf{x}, \sigma_k)$ , és  $\sigma_k = k\sigma$
2.  $L(\mathbf{x}, \sigma_k)$  képek skálázása
3. 1. ismétlése, ha még nem áll rendelkezésre elegendő oktáv
4.  $D(\mathbf{x}, \sigma) = L(\mathbf{x}, \sigma_j) - L(\mathbf{x}, \sigma_k)$  DoG képek előállítása
5. DoG képek skálatérbeli szélsőértékeinek keresése
6. Szélsőértékek pixelnagyságon belüli lokalizációjának megállapítása 3D görbeillesztéssel
7. Szélsőértékek szűrése, nem megfelelő jellemzőpontok elvetése

Az előbbi felsorolás utolsó pontja egyben a detektor által elvégzendő második részfeladat, azaz a rosszul kondicionált jellemzőpontok eltávolítása. A jellemzőpontok lehetnek kevésbé kontrasztosak, ezért nem hordoznak elég információt a környezetükre vonatkozóan, vagy elhelyezkedhetnek éleken, melyek megtartása azt eredményezné, hogy egy adott él mentén sok jellemzőpont lenne – ebből a szempontból szerencsésebb csak a sarkokat eltávolítani.

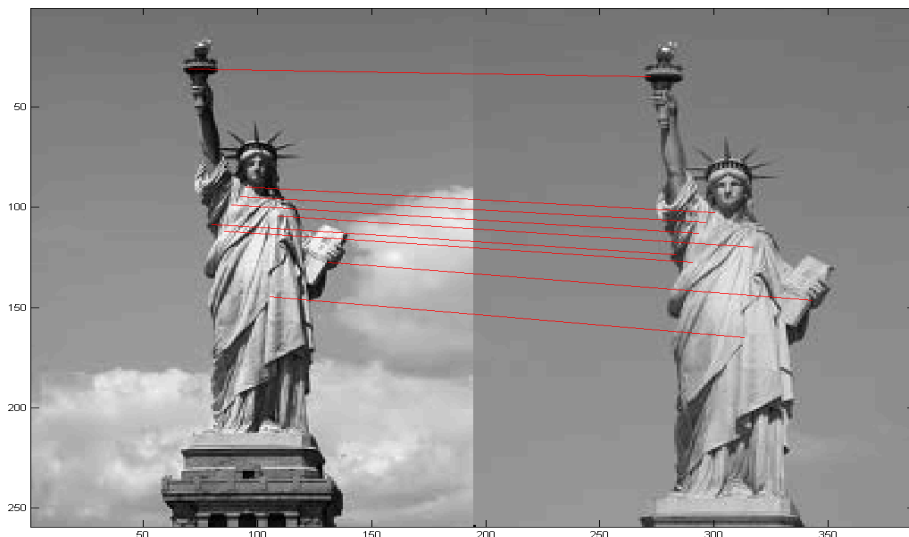
– **A deskriptor**

A deskriptor olyan jellemzők halmaza, melyeket a jellemzőpontokhoz rendelve egyértelműen azonosítják a pontot, függetlenül attól, hogy melyik képen helyezkedik el. Az algoritmus elsőként orientációkat rendel a jellemzőpontokhoz, a forgatási invariancia elérése érdekében. Az orientáció megállapításához a jellemzőpont környezetének gradienseit számolja ki (helyesebben azok irányát, nagyságukkal súlyozva), és ezek közül a leggyakrabban előfordulót választja a jellemzőpont orientációjának. A jellemzőpontot körülvevő területet ezután  $4 \times 4$  kisebb régióra, ún. rekeszre osztja, majd minden rekeszben a gradiens vektorok irány szerinti hisztogramját állítja elő, 8 irány mentén. A jellemzőpontot leíró struktúra tehát egy  $4 \times 4 \times 8$  elemű vektor lesz.

A regisztráció ezután a jellemzőpontok egymásnak való megfeleltetését jelenti, azaz a különböző képeket olyan pontpárok keresését, melyek deskriptorai nagymértékben megegyeznek. Ha csak egy objektum helyének, vagy elmozdulásának megállapítása a cél, itt a feladat már véget is ért, ha azonban a teljes elmozdulásmezőre szükség van – mint orvosi célú képfeldolgozás esetén –, akkor a megtalált pontok közötti interpoláció elvégzése is szükséges. Az interpoláció előnyös, ha a detektor sok jellemzőpontot talál.

**4.2.2. Futási eredmények**


A SIFT algoritmus szándéka, ahogy ezt a neve is mutatja, olyan jellemzőpontok párosítása, melyek különbözően skálázott képeken találhatóak. Ennek megfelelően az algoritmus főként a gépi látás területén alkalmazható, objektum-felismerés és -követés megvalósítására. Egy példa a futás eredményére a 4.3. ábrán látható.



4.3. ábra. A SIFT algoritmus futásának eredménye egy próbaképpáron. Az egymásnak megfelelő pontok pirossal összekötve.



Az algoritmus komplexitása miatt a megvalósítás előtt egy, az internetről le-tölthető<sup>12</sup> próbakód lefuttatása tűnt célszerűnek, manuálisan előfeldolgozott mell-kasröntgen-felvételekre. Nem triviális ugyanis, hogy az algoritmus mellkasröntgen-felvételek esetén is olyan eredményekkel szolgál, melyek indokolnák a megvalósítást. A 4.4. ábrán látható képek ugyanarról a mellkasról készültek.



4.4. ábra. A SIFT algoritmus futásának eredményei mellkasröntgen-felvételen, az egymás-nak megfelelő pontok pirossal összekötve. A két képpár azonos, az egyik tüdő-tükrözése láthatóan nincs nagy hatással a minőségre.


A jellemzőpontok megtalálásával a mellkasröntgen-felvételen sincs probléma, a 4.3. ábrához hasonlóan az algoritmus a 4.4. ábrán is hozzávetőlegesen 200 jellemzőpon-tot talál. Látható azonban, hogy a deskriptor még fejlesztésre szorul, hiszen az egy-másnak megfelelő pontok megtalálása csak néhány esetben kielégítő. A 4.4. ábrán látható, hogy a képek orientációjának azonos irányba való beállítása az algoritmus teljesítményét nem javítja számottevően.

Elmondható tehát, hogy az eszköz ebben a formában szimmetriaanalízisre nem alkalmazható. Még ha a keresendő régiók lokalizáltságára tehető is javaslat az al-goritmussá számára, mivel a két képen található régiók alapvetően nem felelnek meg egymásnak – tehát nem ugyanarról a képletről van szó –, így nem is várható el, hogy a deskriptorok megfelelő mértékben hasonlítsanak egymásra. Ha viszont az algorit-mus a deskriptorok kisebb fokú egyezését írja csak elő, megnövekszik a fals pozitívok száma, az algoritmus teljesen különböző képleteket feleltet meg egymásnak, ahogy azt a 4.4. ábrán tette.

A módszer azonban érdeklődésre tarthat számot a képregisztráció egy másik orvosi alkalmazási területén, nevezetesen időbeli különbségképzés esetében. Ekkor ugyanis az egymásnak megfelelőtetendő régiók valóban azonosak, tehát a deskriptorok

<sup>12</sup><http://www.cs.ubc.ca/~lowe/keypoints/>, 2011 július

hasonlósága várhatóan nagyobb mértékű lesz. Egy ilyen, egy páciensről a betegség különböző állapotaiban készült képekből álló képpár látható a 4.5. ábrán. A látványos eredmény is alátámasztja, hogy a problémát a két tüdő képleteinek túl nagy amennyiben a regisztrálandó képen valóban ugyanaz a képlet szerepel, mint a referenciaképen, a SIFT kiválóan működik. Mivel az időbeli különbségképzés kérdését a dolgozat nem tárgyalja, a megközelítés további analízise nem szükséges.



4.5. ábra. A SIFT algoritmus futásának eredményei ugyanarról a páciensről készült képek összehasonlításakor. Az egymásnak megfelelő pontok pirossal vannak összekötve

## 5. Konklúzió és kitekintés

A dolgozat egy wavelet-transzformáción alapuló regisztrációs algoritmus ismertetését és verifikációját tartalmazta, valamint összehasonlítását más regisztrációs eljárásokkal.

A szakirodalom rövid áttekintése során ismertette a probléma elméleti hátterét, a formalizált megoldási módszereket, részletesen kitérve azokra, melyeket az implementáció során használt. A tárgyalt algoritmus köré épült rendszer elvégzi a mellkasröntgen-felvétel optimális méretű ROI-kra bontását, ezután két lépésben regisztrálja a kapott régiókat. Az első lépés során a képek közötti eltolást kompenzálja, keresztkorrelációs módszerrel. A második lépés során az elasztikus komponensek kompenzációjára kerül sor, wavelet-transzformációt használva regularizáció helyett. A regisztráció során az algoritmus folyamatosan ellenőrzi a kép torzulását is.

A JSRT adatbázisból származó mellkasröntgen-felvételeken történt verifikáció eredményei alapján az algoritmus képes a regisztrációs feladat elvégzésére. A regisztráció minősége, bár többségében megfelelő, sok esetben nem kielégítő. Ez alapvetően egyedi anatómiai variációk, illetve a torzuláskövetés megvalósításával kapcsolatban felmerült problémák eredménye. A torzuláskövetés illetve a regularizáció kérdésköre tehát további megfontolásokat igényel. Annyi azonban elmondható, hogy regisztrációra mindkét módszer alkalmas, a futási időre vonatkozó követelményeket azonban a DTCWT alapú algoritmus nem teljesíti – regisztrációs eredményei viszont valamivel jobbak, mint DWT használata esetén.

Az alkalmazás verifikációja után egy további textúra alapú eljárás, a Démon-algoritmus implementációja is elkészült. Az algoritmushoz egy módosított torzulásmonitorozó eljárás is készült, így komoly vetélytársává vált a DWT alapú algoritmusoknak. A Démon-algoritmus teljesítményét a korábbiakkal összehasonlítva kijelenthető, hogy bár a regisztrációs eredmények hasonlóak, a Démon-algoritmus tekinthető a tárgyalt megoldások közül a legsikeresebbnek. Futási ideje azonban több, mint kétszerese a DWT alapú algoritmusénak, emiatt szűrővizsgálati alkalmazások esetén – mivel teljesítményben a két megoldás közel áll egymáshoz – a DWT alapú algoritmus a legjobb jelölt.

A dolgozat röviden vizsgálta továbbá a SIFT algoritmust is, azonban az eredmények alapján megoldás csak komoly módosításokkal lenne alkalmas szimmetriaanalízisre. Megjegyzendő azonban, hogy ugyanarról a páciensről készült képek összehasonlítására, tehát időbeli különbségképzésre a módszer alkalmas lehet.

A szimmetriaanalízis szempontjából legnagyobb súlyú felmerült probléma a gerincvonal helyének megállapításával függ össze. Nyilvánvalóvá vált ugyanis, hogy a használt becslés a gerincvonal helyének megállapításra csak az esetek mintegy egyharmadában alkalmazható. A szimmetriaanalízis érdemi elvégzéséhez tehát nem csak egy jó regisztrációs algoritmusra van szükség, hanem a gerincvonal valamilyen becslésére is, e nélkül ugyanis az ellenoldali ROI-k kijelölése – még keresztkorrelációs keresést használva is – rendkívül pontatlan. További felmerült lehetőség a szüksé-

ges regularizáció további elemzése, illetve egy olyan regularizációs kritérium kidolgozása, mely a megengedett torzulás mértékét a képen látható képletek típusától teszi függővé. Emellett megfontolandó az elkészült algoritmus verifikációját radiológus bevonásával végezni, így a dolgozatban bemutatott kritériumrendszer valóban a diagnosztikai hasznosságot, és nem csak a regisztráció – valamilyen szubjektív szempontrendszer szerinti – minőségét tükrözné.

A dolgozatban bemutatott teljes rendszer tehát a CAD alkalmazásba való integráció előtt fejlesztésre szorul, a fentiekben összefoglalt szempontok szerint. A DWT-n alapuló megközelítés azonban alapvetően alkalmas mellkasröntgen-felvételek regisztrációjára, mind a regisztráció minősége, mind futási idők szempontjából.

## Függelék

### DCTWT összefoglaló

A DTCWT a 2.3. pontban leírtaktól annyiban tér el, hogy a waveletek nem valós, hanem komplex értékűek. A transzformáció során, amennyiben a használt waveletek valós része a képzetes rész Hilbert-transzformáltja, a transzformáció elvégezhető a valós és a képzetes rész alkalmazásával külön-külön is [SBK05]. Az alkalmazott anya-waveletek tehát:

$$\Psi_c(x) = \Psi_r(x) + j\Psi_i(x),$$

a transzformáció eredménye pedig:

$$W_x^{\Psi_c}(a, b) = W_x^{\Psi_r}(a, b) + jW_x^{\Psi_i}(a, b).$$

A módszer előnye, hogy bár speciális waveletekkel, de ugyanaz a wavelet-transzformációs struktúra használható hozzá, mint DWT esetében, csupán kétszer kell lefuttatnunk az algoritmust, és eredményül is két képet kapunk, egy valós, és egy képzetes részt. Két dimenzióban ez négyszer akkora számítási igényt jelent, hiszen a különböző irányultságú waveletek összeszorozásával keletkező kétdimenziós waveletek szintén komplexek lesznek, azaz a komplex számok szorzási szabályait követve:

$$\begin{aligned} & (\Psi_r(x_1) + j\Psi_i(x_1)) * (\Psi_r(x_2) + j\Psi_i(x_2)) = \\ & = \Psi_r(x_1) * \Psi_r(x_2) - \Psi_i(x_1) * \Psi_i(x_2) + j(\Psi_i(x_1) * \Psi_r(x_2) + \Psi_r(x_1) * \Psi_i(x_2)) \end{aligned}$$

A négy tag miatt látatóan négy transzformációra lesz szükségünk.

### Ko-okkurrencia mátrix

A felhasznált mérőszámok a képen előforduló intenzitásértékek statisztikai elemzését követően állítják elő. Az elemzés első lépése az árnyalatok területbeli függését jellemző ún. ko-okkurrencia mátrix előállítás [HSD73]. A mátrix egy eleme,  $P_{i,j}$  azon szomszédos pixelpárok száma, ahol a két intenzitásérték  $i$  illetve  $j$ . [HSD73] különböző irányokra bontja a szomszédossági viszonyok vizsgálatát, ez azonban jelen esetben nem indokolt, mivel alapvető feladatát a következőkben tárgyalt mérőszám a fenti definícióval is ellátja. A mátrixban egyrészt az egyes elemek invariánsak például az objektumok eltolására a képen, másrészt normálásukkal az intenzitáspárok eloszlását kapjuk.

A ko-okkurrencia mátrix elemeinek [HSD73] által említett elemzési lehetőségei közül az algoritmus felügyeletére eleinte entrópia-mérőszámok használtak, azonban ez a későbbiekben feleslegesnek bizonyult. A kép torzulása ugyanis jól követhető a képen a ko-okkurrencia mátrix diagonális voltának az ellenőrzésével. Ami a helyzetet tovább egyszerűsíti, hogy a torzulás jellemzően egy bizonyos szűrkeárnyalatot terjeszt el a képen, azaz az ezzel szomszédos pixelek száma nő, így hisztogramjuk

egyre magasabb lesz. Ez a viselkedés egyszerűen ellenőrizhető a deriváltak változásának nyomon követésével. Amennyiben a regisztráció előtt, soronként kiszámolt maximális derivált-értéknél átlagosan magasabb deriváltak kezdenek megjelenni, az torzulásra utal. Ekkor, némi várakozási idő után, a torzuláskövető-rendszer leállítja a regisztrációt. A tesztek tanulsága szerint ezzel a módszerrel a Démon-algoritmus teljesítménye jelentősen növelhető.

## Ábrák jegyzéke

|      |  |    |
|------|--|----|
| 2.1. | A DWT szűrőbank-interpretációja . . . . .                                      | 10 |
| 2.2. | A DWT eredménye $k=1,2$ esetén . . . . .                                       | 11 |
| 3.1. | A teljes program vázlata . . . . .   | 13 |
| 3.2. | Az algoritmus által kijelölt egyszerűsített tüdőhatárok . . . . .              | 14 |
| 3.3. | Képszélek miatti torzulás illusztrációja . . . . .                             | 17 |
| 3.4. | A torzuláskövető rendszer egy ROI regisztrációja közben . . . . .              | 18 |
| 3.5. | A DWT-t használó algoritmus eredménye szintetikus képen . . . . .              | 23 |
| 3.6. | A DTCWT-t használó algoritmus eredménye szintetikus képen . . . . .            | 23 |
| 3.7. | Néhány véletlenszerűen generált elmozdulásmező . . . . .                       | 24 |
| 4.1. | A Démon-algoritmus eredménye egy valódi ROI-páron . . . . .                    | 30 |
| 4.2. | A DWT alapú megoldás eredménye egy valódi ROI-páron . . . . .                  | 30 |
| 4.3. | A SIFT algoritmus futásának eredménye egy próbaképpáron . . . . .              | 33 |
| 4.4. | A SIFT algoritmus futásának eredményei mellkasröntgen-felvételen . . . . .     | 34 |
| 4.5. | A SIFT algoritmus eredményei ugyanarról a páciensről készült képeken . . . . . | 35 |

## Hivatkozások

- [BK89] Ruzena Bajcsy and Stane Kovačič. Multiresolution elastic matching. *Computer Vision, Graphics, and Image Processing*, 46, 1989.
- [BN96] Morten Bro-Nielsen. *Medical Image Registration and Surgery Simulation*. PhD thesis, IMM-DTU, 1996.
- [Bro92] L.G. Brown. A survey of image registration techniques. *ACM Computing Surveys*, 1992.
- [CL10] Shihua Cai and Keyong Li. Matlab implementation of wavelet transforms. <http://taco.poly.edu/WaveletSoftware/index.html>, 2010.
- [HSD73] R. Haralick, K. Shanmugam, and I. Dinstein. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 1973.
- [JF93] Calvin R. Maurer Jr. and J. Michael Fitzpatrick. *Interactive image-guided neurosurgery*, chapter A Review of Medical Image Registration. American Association of Neurological Surgeons, 1993.
- [KHN10] Tsuyoshi Kawaguchi, Yoshitomi Harada, and Ryoichi Nagata. Image registration methods for contralateral subtraction of chest radiographs. In *3rd International Conference on Biomedical Engineering and Informatics*, 2010.
- [KSW08] Uwe Kiencke, Michael Schwarz, and Thomas Weickert. *Signalverarbeitung - Zeit-Frequenz-Analyse und Schätzverfahren*. Oldenbourg, 2008.
- [LCC05] Xingang Liu, Wufan Chen, and Guangjie Chen. A new hybridized rigid-elastic multiresolution algorithm for medical image registration. In *IEEE Engineering in Medicine and Biology 27th Annual Conference*, 2005.
- [LMVS03] D. Loeckx, F. Maes, D. Vandermeulen, and P. Suetens. Temporal subtraction of thorax cr images using a statistical deformation model. *IEEE Transactions on Medical Imaging*, 22(11), 2003.
- [Low04] David G. Lowe. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60(2), 2004.
- [Mal99] Stéphane Mallat. *A Wavelet Tour of Signal Processing*. Academic Press, 1999.
- [MV98] J. B. Antoine Maintz and Max A. Viergever. A survey of medical image registration. *Medical Image Analysis*, 2(1), 1998.



- [NHK09] Ryoichi Nagata, Yoshitomi Harada, and Tsuyoshi Kawaguchi. An improved contralateral subtraction scheme for detection of pulmonary nodules in chest radiographs. In *TENCON – IEEE Region 10 Conference*, 2009.
- [NOTO02] Keiichi Nakagawa, Akira Oosawa, Hiroshi Tanaka, and Kuni Ohtomo. Clinical effectiveness of improved temporal subtraction for digital chest radiographs. In *SPIE 4686*, 2002.
- [SBK05] Ivan W. Selesnick, Richard G. Baraniuk, and Nick G. Kingsbury. The dual-tree complex wavelet transform. *IEEE Signal Processing Magazine*, November 2005.
- [SKI<sup>+</sup>10] J. Shiraishi, S. Katsuragawa, J. Ikezoe, T. Matsumoto, T. Kobayashi, K. Komatsu, M. Matsui, H. Fujita, Y. Kodera, , and K. Doi. Development of a digital image database for chest radiographs with and without a lung nodule: receiver operating characteristic analysis of radiologists' detection of pulmonary nodules. *American Journal of Roentgenology*, 174, 2010.
- [Thi96] J.-P. Thirion. Non-rigid matching using demons. In *Computer Vision and Pattern Recognition*, 1996.
- [vGtHRV01] Bram van Ginneken, Bart M. ter Haar Romeny, and Max A. Viergever. Computer-aided diagnosis in chest radiography: A survey. *IEEE Transactions On Medical Imaging*, 20(12), 2001.
- [Yos04] Hiroyuki Yoshida. Local contralateral subtraction based on bilateral symmetry of lung for reduction of false positives in computerized detection of pulmonary nodules. *IEEE Transactions on Biomedical Engineering*, 51(5), 2004.
- [ZF03] Barbara Zitovač and Jan Flusser. Image registration methods: a survey. *Image and Vision Computing*, 21, 2003.