



Budapesti Műszaki és Gazdaságtudományi Egyetem

Villamosmérnöki és Informatikai Kar

Méréstechnika és Információs Rendszerek Tanszék

Fegyver Zoltán

Automatikus módszer mikroaneurizmák szemfenéki felvételeken történő detektálására

TANSZÉKI KONZULENS

dr. Pataki Béla

BUDAPEST, 2011

TARTALOMJEGYZÉK


1. Bevezetés	3
2. Anatómiai áttekintés	5
2.1 Az aneurizmák kialakulása.....	5
2.2 A szem anatómiája.....	6
2.3 Szemfenék és szemfenéki felvételek.....	7
3. Irodalmi áttekintés	9
3.1 A ROC adatbázis.....	9
3.2 A mikroaneurizmák detektálásának nehézségei.....	10
3.3 Az algoritmusok általános felépítése.....	11
3.4 Előfeldolgozás.....	11
3.4.1 A kép átméretezése.....	11
3.4.2 A zöld színcsatorna kiválasztása.....	12
3.4.3 Medián szűrés.....	12
3.4.4 Gauss szűrés.....	13
3.4.5 A háttér becslése.....	13
3.4.6 Csúcsok kiemelése.....	13
3.5 A jelöltállítás folyamata.....	14
3.5.1 Illesztett szűrés Gauss-felülettel.....	15
3.5.2 Vérérek szegmentálása.....	16
3.5.3 A tényleges jelöltállítás.....	16
3.6 A klasszifikáció.....	17
3.6.1 A leggyakrabban használt mérőszámok.....	17
3.6.2 Az alkalmazott döntéshozó rendszerek.....	18
4. Az elvégzett munka	19
4.1 Az alapötlet és motiváció.....	19
4.2 Az előfeldolgozás lépései.....	20
4.2.1 A simított bázist alkalmazó JPEG rekonstrukció.....	21
4.2.1.1 A simított bázisú rekonstrukció alapjai.....	21
4.2.1.2 Rekonstrukciós eredmények.....	24
4.2.2 A ROI kijelölése.....	25
4.2.3 Háttérbecslés, árnyékkorrektúra.....	26
4.3 A jelöltállítás.....	26
4.4 A klasszifikáció.....	27
4.4.1 Koordináta transzformáció.....	28
4.4.2 Szegmentálás és határoló pontok.....	31
4.4.3 Az alkalmazott mérőszámok.....	33
4.4.3.1 A gradiens vektorokból képzett kovariancia mátrix.....	33
4.4.3.2 A gradiens vektorokból képzett poligon.....	34
4.4.3.3 A mérőszámok definíciói.....	35
4.4.4 A jelöltek klasszifikálása.....	36
5. Eredmények	37
5.1 Gradiens alapú mérőszámokkal nyert eredmények.....	37
5.1.1 Összevetés Mizutani eredményével.....	38
5.1.2 Összevetés a ROC verseny eredményeivel.....	38
5.2 A gradiens alapú mérőszámok vizsgálata.....	41
5.3 Az eredmények összefoglalása.....	43
6. Kitekintés	44
7. Irodalomjegyzék	45

1. BEVEZETÉS

Az automatizált rendszerek térhódítása folyamatosan zajlik napjainkban. Ez nem meglepő, hiszen alkalmazásuk számos előnnyel jár, többek között precizitásuk s hatékonyságuk is igen nagy, idő- és költséghatékonyak egyaránt. Az iparban ma már szinte elképzelhetetlen egy összetettebb folyamat megvalósítása emberi erőforrásokat támogató egységek nélkül. Hasonló folyamat figyelhető meg az egészségügy területén is: számos olyan rendszer – hardver és szoftver egyaránt – került és kerül kifejlesztésre, mely jelentősen megkönnyíti az orvosok munkáját, támogatja a helyes diagnózis felállítását.

Ugyanakkor pontosan az egészségügy területe az, amely rámutat, hogy az automatizált rendszerek terjedése ellenére az emberi szaktudás elengedhetetlen értéket képvisel és nem kiváltható. Nem lehetséges ugyanis olyan algoritmus megalkotása, melynek robusztussága az emberi teljesítményt – legalábbis a diagnózisok pontosságát illetően – felülmúlja. Az orvosok munkájának sebessége és hatékonysága a rendelkezésükre bocsájtott megfelelő segédeszközökkel ugyanakkor jelentősen növelhető: emiatt érdemes tehát döntéshozást megkönnyítő eszközöket fejleszteni az orvosok számára, és megtalálni az emberi-gépi együttműködés megfelelő formáját és helyes mértékét.

A fenti gondolatmenet illusztrációjaként tekintsük a diabétesz kérdését. A diabétesz mára már népbetegséggé vált hazánkban a 20 és 69 év közötti lakosság mintegy 7.6%-át érintve. Meg kell jegyezni, hogy ez az érték csak az ismert betegek számát jelenti. A WHO adatai alapján a valós esetszám ennek a kétszerese körül mozoghat. A Központi Statisztikai Hivatal diabéteszes betegek számát mutató adatsora látható az *1. ábrán*.



1. ábra, a háziorvosokhoz bejelentkezett 19 éves és idősebb diabéteszes betegek száma Magyarországon

A növekvő tendencia sajnálatos, a folyamat nyilvánvalóan kezelésre szorul. Emiatt is kitűzött cél olyan hatékony szűrőprogram kidolgozása Magyarországon, mely lehetővé teszi a betegek minél előbbi kiszűrését, a korai diagnózist, s ez által eredményesebb kezelésüket.

A cukorbetegség első és jellegzetes tünetei a retina vérerezettségének elváltozásaiban jelentkeznek, a retina vérerezettségéről pedig a szemfenéki felvételek nyújtanak információt. A szemfenéki felvételek kiértékelése egy igen hosszúságú folyamat és nagy figyelmet igényel. Nem nehéz elképzelni, hogy amennyiben a fent említett szűrőprogram kiteljesedik, milyen szakembergárdát igényelne, és mekkora feladatot jelentene a felvételek feldolgozása. Emiatt is fontos olyan algoritmusok megalkotása, melyek ezt a munkát támogatni képesek, például a gyanúsítást ítélt elváltozásokat előre bejelölve az orvosok számára.

A diabétesz problémája nemcsak Magyarországot, hanem a világ más fejlett országait is érzékenyen érinti, a hatékony szűrés világméretű akut feladat. Emiatt állnak napjainkban is folyamatos fejlesztés alatt a szemfenéki felvételek feldolgozását segítő algoritmusok: ez egy aktívan fejlődő, fontos terület.

Dolgozatomban a szemfenéki felvételek feldolgozásának egyik részfeladatát, a mikroaneurizmák hatékony detektálási lehetőségét vizsgálom: ezek retinán történő megjelenése ugyanis a kezdődő diabétesz indikátora. Rövid anatómiai áttekintés után az irodalomban fellelhető algoritmusokat elemzem, majd pedig rátérek gradiens-vektorok analízisén alapuló módszerem tárgyalására. Az algoritmusom által szolgáltatott eredményeket kiértékelem, megvizsgálom módszerem előnyeit, hátrányait egyaránt. Dolgozatomat lehetséges jövőbeni fejlesztési irányvonalakkal és lehetőségekkel zárom.

2. ANATÓMIAI ÁTTEKINTÉS

Jelen fejezet célja, hogy rövid, általános áttekintést adjon az aneurizmák kialakulásáról, a szem anatómiai felépítéséről, a szemfenékről és a szemfenéki felvételek alkalmazásáról.

2.1 AZ ANEURIZMÁK KIALAKULÁSA

Az aneurizma az érfal normálistól eltérő tágulata. Kialakulásának kiváltó oka az, hogy – leggyakrabban valamilyen betegség következményeként – a vérér fala meggyengül, és nem tud rugalmasan ellenállni a rá jutó terhelésnek. A vérér fala alapvetően három szövettanilag megkülönböztethető rétegből áll.

- *Belső réteg (tunica intima)*: az ér legbelső rétege, amely a vérrel közvetlen módon érintkezik. A hámsejtek egy alaphártyán helyezkednek el, amelyet pedig lazarostos kötőszövet vesz körül.
- *Középső réteg (tunica media)*: a nagy artériák falában ez a réteg nagyrészt elasztikus, rugalmas rostokból áll, míg a kisebb artériákban inkább körkörös lefutású simaizomsejtek alkotják.
- *Külső réteg (tunica adventitia)*: leginkább a vénák falában fejlett, kollagén, rugalmas rostok és simaizomsejtek építik fel.

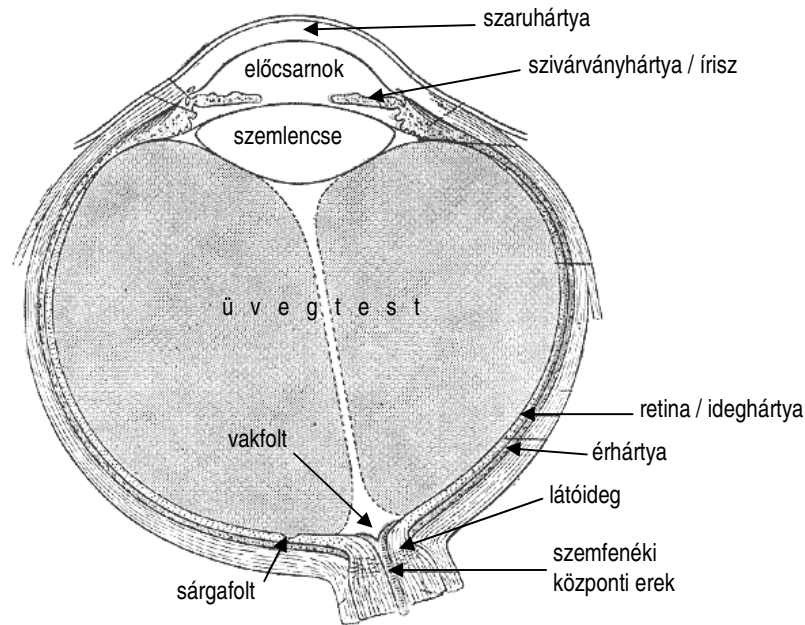
A három réteg jelenléte a nagy erektől fogva egészen a hajszálerekig megfigyelhető, azonban a rétegek egymáshoz viszonyított aránya és felépítése az érpálya egyes szakaszainak függvénye. Amennyiben valakinél az ér falait veszélyeztető betegség – mint például az ér-elmészesedés – áll fenn, a falak meggyengülnek, s az ér egy vagy több rétegét érintő tágulat kezd el kialakulni. A vérértágulatok veszélyét leginkább a Laplace-Frank törvény jellemzi szemléletesen:

$$falfeszülés = \frac{nyomás \times sugár}{falvastagság}, \quad (1)$$

azaz a vérér falára ható tangenciális feszülés egyenesen arányos az érfalra ható nyomás, valamint az ér sugarának szorzatával; illetve fordítottan arányos az ér falának vastagságával. Egy lassan táguló, duzzadó aneurizma egyre fokozódó feszülést eredményez az ér falában, ez pedig előbb-utóbb annak felszakadásához vezet. A vérértágulat felszakadása különféle szövődeményekkel járhat, ez az aneurizma testben való elhelyezkedésétől függ. Szemfenéki vérér esetében ez látásromlás, míg egy aortai aneurizma esetén akár halál is lehet.

2.2 A SZEM ANATÓMIÁJA

Az aneurizmák kialakulásának áttekintése után érdemes a szem felépítésével is röviden megismerkedni. Látószervünket a szemgolyó, a szemideg és a látópálya alkotja. További járulékos egységei a szemmozgató izmok, a szemhéjak és a könnyrendszer. A szemgolyó felépítéséről a 2. ábra mutat be egy vázlatos, áttekintő képet.



2. ábra, a szem felépítése

A szem egy rendkívül összetett optikai rendszer. A szaruhártya a szem védelmét látja el, illetve a beérkező fénysugarat is megtöri, a szivárványhártya pedig a szembe jutó fény mennyiségét szabályozza. Ennek a szabályozási folyamatnak köszönhető a pupilla – amely tulajdonképpen a szivárványhártyán lévő rés – átmérőjének változása. A szembe jutó fény újra megtörik, ezúttal a szemlencsén: ez egy rugalmas lencse, melynek alakját kis izmok változtatják, attól függően, hogy közelre, vagy távolra szeretnénk-e látni, a szabályozás célja pedig, hogy mindig éles kép vetüljön a retinára. A szaruhártya és a szemlencse közötti előcsarnokot az ún. csarnokvíz tölti ki, míg a szemlencse és a retina közötti térben az üvegtest foglal helyet.

A retina fényérzékeny sejteket tartalmazó hártya, mely mögött az érhártya helyezkedik el. Ez nevének megfelelően erekkel dúsán átszőtt, s tápanyaggal látja el a retina idegsejtjeit. A látóideg és a vérerek belépési helye a vakfolt: az ide vetülő fényt nem érzékeljük. A sárgafolt ellenben a legérzékenyebb retinaterület, az éleslátás helye.

2.3 SZEMFENÉK ÉS SZEMFENÉKI FELVÉTELEK

Szemfenéknek a szemgolyó hátsó felének belső falát nevezzük, ahol a retina, valamint az érhártya található. Vizsgálata orvosi diagnosztikai szempontból jelentős, hiszen nem csak közvetlenül a szem állapotára, hanem a szervezet egyéb betegségeire is következtethetünk belőle, és a szemfenéki erek állapotából vonatkoztathatunk a test más területén található – például a vesei – hajszálérhálózat állapotára. A szemfenéki felvételeket leggyakrabban az alábbi betegségek megállapítására használják:


- *Diabétesz*: a retinán található hajszálerek fala elveszti rugalmasságát, így azokon mikroaneurizmák jelennek meg. Ezek kihasadhatnak, a vér kiömölhet, a szemfenéken pontszerű, vagy tócsás vérzések jelennek meg, míg a sárgafolt helyén vizenyő is előfordulhat.
- *Magas vérnyomás*: ekkor az arteriolák, azaz az odavezető kiserek összeszűkülnek, míg a vénák kissé kitágulnak. A szűkülés miatt az arteriolákban megnő a vérnyomás, így ahol ezek s a vénák keresztezik egymást, a nyomáskülönbség miatt utóbbiak összelapulnak. A véna ekkor vagy megfelelően idomul, így a keringés helyreáll, vagy elzáródik. Utóbbi esetben a vér nem tud megfelelően eláramlani, ennek eredményeként a retinán bevérzések keletkezhetnek.

A szemfenéki felvétel készítése egy kis zseblámpához hasonló, ún. oftalmoszkóp nevű eszközzel történik, egy ilyen mutat be a *3. ábra*. A fényt a retina helyes megvilágításához megfelelő intenzitással kell a szembe juttatni: a műszer részint emiatt, részint a retináról való megfelelő képalkotás céljából egy összetett lencserendszert is tartalmaz. Ezen kívül a nagyobb fényintenzitás eléréséhez a páciens szemébe a felvétel készítése előtt megfelelő szert cseppentenek, melytől kitágul a pupilla, így a szemfenék könnyebben megvilágíthatóvá válik.



3. ábra, a HS-OP10 típuszámú oftalmoszkóp

A 4. ábra egy általános szemfenéki felvételt ábrázol, és egyben illusztrálja a gyakran vizsgált területeket, képleteket.



4. ábra, szemfenéki felvétel

A felvételen megfigyelhetők az előző fejezetben említett alkotók. A vakfolt a látóideg belépési helye. Az is látszik, hogy a szem vérkeringését biztosító artériák, vénák itt hatolnak be, s innen ágaznak szét, gazdagon behálózva a szemfeneket. Az éleslátás helye, a sárgafolt sötétebb árnyalatú területként jelenik meg. A kutatási vizsgálódások leggyakoribb célpontjai, a vérerek meglehetősen változatosságot mutatnak elhelyezkedésben és vastagságban egyaránt.

Dolgozatom a szemfenéki felvételeken történő mikroaneurizma-keresést tárgyalja. Ahogy említésre került, a cukorbetegség egyik első jele az apró vérértágulatok megjelenése a szemfenéken. Ezek időben történő detektálásával a retina és a vérerek jelentős mértékű károsodása megelőzhetővé válik, hiszen a bajt észlelve a beteg személy kezelése időben elkezdhető. Ellenkező esetben a mikroaneurizmák, nagy társaikhoz hasonlóan, elrepednek, bevérzéseket okoznak, maradandóan károsítva ezzel a szemfeneket.

A mikroaneurizmák detektálása nagy kihívást jelent az algoritmusok számára, nehezen megoldható feladat. Mégis, a téma fontossága és aktualitása miatt is döntöttem úgy, hogy megvizsgálom ezen feladat fejlesztési lehetőségeit egy saját módszer kidolgozásán keresztül.

3. IRODALMI ÁTTEKINTÉS

Jelen fejezetben tekintem át a mikroaneurizma-detektálás általánosabb vonatkozásait, és az irodalomban fellelhető módszereket tárgyalom röviden.

3.1 A ROC ADATBÁZIS

2007-ben az University of Iowa rendelkezésre bocsájtott egy szemfenéki felvételeket tartalmazó adatbázist, mely alkalmas a mikroaneurizma-detektáló algoritmusok tesztelésére. Az adatbázis 100 felvételt tartalmaz, ebből 50 esetben áll rendelkezésre információ az aneurizmák elhelyezkedéséről. A referenciaadatok elkészítése során a felvételeket egymástól függetlenül négy specialista értékelt ki, és csak azon jelöltek kerültek be az adatbázisba, melyeket mind a négy szemész valós aneurizmaként jelölt meg. Ezt az 50 képet lehet felhasználni az algoritmus tanítására, és a másik 50 felvételen lehetséges az algoritmus éles tesztelése.

A publikálók jóvoltából a fent említett adatbázis köré verseny is szerveződött, az ún. *Retinopathy Online Challenge*, a versenyre leggyakrabban ROC-ként hivatkoznak. [Niemeijer10] A tesztalmazra kapott eredmény beküldhető az adatbázis készítőinek, akik a kiértékelés után visszaküldik az algoritmus hatékonyságát jellemző mérőszámokat. A dolgozat írásakor 9 különféle módszer állt versenyben, ebből kettő magyar fejlesztés, az egyik listavezető. A verseny 2009 óta tart, nemrégiben is került fel új eredmény, ami alátámasztja a bevezetőben tett állítást, mely szerint a szemfenéki felvételek elemzése fontos, dinamikusan fejlődő terület.

A szemfenéki felvételek JPEG formátumúak, amely veszteséges tömörítési módszert jellemez. Ez a visszafordíthatatlan információvesztés nehézségeket okoz az aneurizmák detektálása során, jelentősen megnöveli a zaj mértékét.

A felvételeket több, különböző felbontású kamerával készítették, azok alapértelmezett beállítását használva. A szemfenéki felvételek felbontás-adatait az *1. táblázat* tartalmazza:

1. táblázat, a rendelkezésre álló, referenciaadatokkal rendelkező képek paraméterei


Felbontás	Darabszám
768×576	22
1059×1061	3
1389×1388	25

3.2 A MIKROANEURIZMÁK DETEKTÁLÁSÁNAK NEHÉZSÉGEI

A mikroaneurizmák a szemfenéki felvételeken apró, vöröses foltokként jelennek meg. Az objektumok kis mérete már önmagában nehezítő tényező, amit csak tovább fokoz a JPEG tömörítésből eredő zaj. A képadatbázishoz több megjegyzést is fűztek a rá alapozó cikkekben [Mizutani09, Cree08]:

- *Téves jelölések az adatbázisban:* Több cikk is utal rosszul jelölt, vagy nem látható aneurizmákra. Ezeken kívül előfordulnak olyan jól azonosítható elváltozások, melyek ugyanakkor nincsenek bejelölve. Mizutaniék az adatbázisban szereplő 336 aneurizmából 140-et jelöltek meg nem láthatóként.
- *Kis kontrasztú felvételek:* több olyan kép is szerepel az adatbázisban, melyek kis kontraszttal rendelkeznek, s melyek normál esetben nem mennének át egy képminőséget vizsgáló előszűrésen.
- *Nagy zajjal terhelt képek:* Cree megjegyzése szerint az adatbázisban szerepelnek olyan zajos képek, amilyenekre több mint 3000, más forrásból származó szemfenéki felvétel között sem látott példát.

A nem látható aneurizmák esetét az alábbi 5. ábra illusztrálja:




5. ábra, a bal oldalon látható, a jobb oldalon nem látható aneurizma

A fenti ábrán megfigyelhető, hogy a képek rendkívül zajosak, ami előrevetíti a helyes előfeldolgozás fontosságát, ez ugyanis elengedhetetlen a későbbi minél jobb eredmények eléréséhez. Így nem is meglepő, hogy az irodalom részletesen foglalkozik az előfeldolgozási módszertannal, illetve [Antal10] külön cikkben ír az előfeldolgozási s jelöltállító módszerek ideális kombinálásáról.

3.3 AZ ALGORITMUSOK ÁLTALÁNOS FELÉPÍTÉSE

A legtöbb módszer három fő, egymást követő lépésből áll, ez az általános felépítés a publikált algoritmusok nagy részére teljesül. Az lépéseket a 6. ábrán szemléltetve:



6. ábra, a szemfenéki felvételek feldolgozásának három fő lépése

Az előfeldolgozás feladata a zaj kiszűrése, és a kép előkészítése a további feldolgozásra. A jelöltállítás során adjuk meg az objektumok egy olyan halmazát, melyet a továbbiakban vizsgálni fogunk különféle tulajdonságok szerint. Az objektumok végleges besorolásáról a klasszifikációs lépés dönt.

Természetesen az előfeldolgozás, a jelöltállítás és a klasszifikáció is összetett folyamat, az egyes blokkok további részfeladatokra oszthatóak: a következő alfejezetekben veszem sorra, s fejtem ki ezeket.

3.4 ELŐFELDOLGOZÁS

Az előfeldolgozás fontos lépés a szemfenéki felvételek szoftveres kiértékelése során: az itt nyert kimenetre tudunk ugyanis alapozni a továbbiakban. Alkalmazásoktól függően több előfeldolgozási lépés követheti egymást, a lehetőségek tárháza igen széles. Szükséges lépés például a képfeldolgozási feladat skála-független működéséhez a kép átméretezése. A zajcsökkentésre a medián és Gauss-szűrést használják leggyakrabban. Az előfeldolgozás során elvégzett fontos műveletek még például a háttér becslése, vagy a csúcsok kiemelése.

3.4.1 A KÉP ÁTMÉRETEZÉSE


Amint az a 3.1 fejezetben látható volt, a rendelkezésre álló felvételek különböző felbontással rendelkeznek. Ennek következményeként az aneurizmák mérete is különböző. Ez paraméterezési nehézségeket okozna az algoritmusok alkalmazásakor, a módszereket fel kellene készíteni a skála-független működésre. A probléma kiküszöbölésére leginkább két út kínálkozik:

- A skála-független működés biztosítása például dinamikus paraméterezéssel.
- A kép átméretezése oly módon, hogy az egyes aneurizmák mérete közel azonos legyen minden esetben.

Az irodalomban az utóbbira leltem csak példát. A képet tehát a feldolgozás megfelelő fázisában a legkisebb vagy a legnagyobb képméret szélességéhez igazítva méretezzük át: mindkettő esetre leltem irodalmi utalást. Az átméretezésnek köszönhetően az algoritmus paramétereit elegendő egyféle képszélesség várható jellemzőihez igazítani.

3.4.2 A ZÖLD SZÍNCSATORNA KIVÁLASZTÁSA


A ROC adatbázis képei RGB képek, tehát mind a három színcsatornával rendelkeznek. A színes orvosi képek feldolgozása során általánosan elterjedt gyakorlat, hogy a zöld színcsatornát választjuk ki, s ezzel dolgozunk tovább, ugyanis ez rendelkezik a legnagyobb kontraszttal. A zöld csatorna mellett ugyanakkor nem elhanyagolható a másik kettőből ki- nyerhető információ sem. [Cree08] több olyan paramétert megjelöl, melyeket a vörös és kék csatorna intenzitásértékei alapján számít ki. Az R, G, B színcsatornákból készített, normált-hisztogramokat mutat be egy mintaképre a 7. ábra.



7. ábra, RGB kép és sorban az R, G és B csatornákból készített hisztogram

3.4.3 MEDIÁN SZŰRÉS


A medián szűrés a statisztikus szűrők egyik legegyszerűbbike. Egy $n \times n$ méterű ablakot végigtolunk a képen, és minden egyes lépésnél sorba rendezzük az ablakba eső intenzitás-értékeket. Medián szűrés esetén az így nyert rendezett adatsor mediánját – azaz a középső értékét – adjuk értékül az ablak közepére eső képpontnak. A szűrő jól teljesít a pont- illetve vonalszerű zajok elnyomása esetén. A szemfenéki felvételek feldolgozásakor is alkalmaznak medián szűrést, általában 3×3 -as ablakkal [Mizutani09, Cree08] – illusztráció az 8. ábrán.



8. ábra, a 3×3 -as ablakkal történő medián szűrés hatása

3.4.4 GAUSS-SZŰRÉS


A Gauss-szűrés célja szintén a képen megjelenő zaj csökkentése: ez esetben a képet egy kétdimenziós, adott szórású Gauss-felülettel konvolváljuk. Minél nagyobb a felület szórása, annál inkább elnyomódik a zaj, ám egyre elmosódottabbá is válik a kép, amint az a 9. ábrán látható. A Gauss-szűrést például [Lazar11] is alkalmazza, ő 1.4 szórású felületet javasol.



9. ábra, bal oldalon egy 1.25 szórású Gauss-felület, jobb oldalon a Gauss-szűrés eredménye

3.4.5 A HÁTTÉR BECSLÉSE

A szemfenéki felvételek általában nem egyenletesen megvilágítottak, ami problémát okozhatna a képfeldolgozás során. A megvilágítási eltérések kiküszöbölésére első lépésként becslést tesznek a kép háttérére. Ez a lépés kiszűri a nagyfrekvenciás összetevőt, melyet a vérerek és az aneurizmák generálnak, miközben meghagyja a lassú intenzitásváltozásokat. A háttér becslésére gyakori módszer egy 25×25 -ös, vagy még nagyobb ablakkal történő medián szűrés. [Xu10, Sopharak11] A módszer hatása követhető szemmel a 10. ábrán.




10. ábra, a háttérkép becslése 25×25 ablakméretű medián szűréssel

3.4.6 CSÚCSOK KIEMELÉSE

Ez a lépés szorosan összefügg a háttérkép becslésével. Jelentősége abban áll, hogy egy szemfenéki felvételen nem lenne értelme szegmentációra intenzitásküszöböt alkalmazni úgy, hogy a háttér nem egyenletesen megvilágított.

Emiatt szinte mindegyik algoritmus esetében alkalmazott lépés az ún. árnyékkorrigált kép létrehozása, melyet úgy generálnak, hogy a háttérképből kivonják az eredeti képet. A háttér alacsonyfrekvenciás változása eltűnik, ám az éles csúcsok megmaradnak. [Streeter03]



11. ábra, eredeti és árnyékkorrigált kép

A fenti 11. ábrán jól láthatóan eltűnt a háttér lassú változása, érdemes például a sárgafolt területét megtekinteni. Az is megfigyelhető, hogy az eredeti felvételen negatív csúcsok, mint a vérerek, vagy a mikroaneurizmák, lettek kiemelve a korrigált képen. Mivel a háttér lassú változása eltűnt, a csúcsok magassága így immár összevethető.

3.5 A JELÖLTÁLLÍTÁS FOLYAMATA

A jelöltállítási folyamat feladata egy olyan kiinduló objektumhalmaz előállítás, amely elemeire később adott paramétereket számíttatunk ki, a klasszifikációt pedig az így kinyert paraméterek értékei alapján végezzük el. Nagyon fontos a jelöltek helyes felvétele. Ügyelni kell arra, hogy a halmaz mérete ne legyen túl nagy, hisz ez megnöveli a fals pozitív találatok valószínűségét, ám az sem engedhető meg, hogy már a kiinduló halmaz előállítás során sok igazi jelöltet veszítsünk el egy esetleges rossz beállítás miatt.


[Antal10] munkájában részletesen elemzi a lehetséges előfeldolgozási és jelöltállítási módszerek kombinációinak kimenetelét, és ez alapján ezek optimális összehangolására tesz javaslatot. Módszerükkel 98.5%-os true pozitív találati arányt értek el – a 336 adatbázisban szereplő aneurizmából 331 került a jelöltek közé, 46434 fals pozitív találat mellett.

A jelöltállítás problémája a miatt is érdekes kérdés, mivel az előzőekben már tettem utalást olyan irodalmi hivatkozásra, mely szerint az adatbázis tartalmaz hibákat: nem, vagy csak nagyon nehezen megtalálható jelölteket. Kérdéses, hogy egy kevésbé képzett szemész a nehezen látható jelöltek közül mennyit ítélne meg valósnak.

Az is árnyalja ezt a helyzetet, hogy a diabéteszes retinopátiát már egy mikroaneurizma megjelenése is bizonyítja, az aneurizmák száma a retinopátia előrehaladottságát mutatja meg. Át kell tehát gondolni, mi a célunk: egy olyan eszközt kifejleszteni, amely minden aneurizmát megtalál, de nagy fals pozitív aránnyal, vagy olyan eszközt, amely jó hatásfokkal jelzi a retinopátia meglétét, s szinte alig talál fals jelöltet. [Cree08] tárgyalja ezt a kérdést részletesebben: az ő rendszerük a ROC versenyen más algoritmusokhoz képest viszonylag gyengén teljesített, ugyanakkor gyakorlati alkalmazása során igen jó eredményt produkált a diabéteszes retinopátia detektálásában.


3.5.1 ILLESZTETT SZŰRÉS GAUSS-FELÜLETTEL

A mikroaneurizmák modellje leggyakrabban adott szórású Gauss-felület. [Serrano04] Egy gyakorlati mintát és vele párhuzamosan egy Gauss-felületet mutat be a 12. ábra.



12. ábra, mikroaneurizma és 1.50 szórású Gauss-felület összehasonlítása

A jelöltállítás induló lépéseként alkalmazott módszer az illesztett szűrés, melynek alapja az, hogy adott jelet keresve adott szűrővel történő konvolúció esetén a jel-zaj viszony akkor lesz maximális, ha a szűrő alakja megegyezik a jel alakjával. [Chaudhuri89] Aneurizmát tehát egy Gauss-felülettel történő konvolúcióval érdemes keresni.



13. ábra, illesztett szűrés hatása, 1.00 szórású Gauss-felületet alkalmazva


A 13. ábrán megfigyelhető, hogy az árnyékkorrigált képhez képest egy elmosódottabb, ugyanakkor tisztább képet kaptunk. A kép közepén található aneurizma megőrizte jellegét, a kisebb zajok eltűntek. Az ábrán az is látható, hogy a vérerek is hasonlóan jól reagálnak az illesztett szűrésre, szintén magas csúcsokat képeznek, sok fals pozitív jelöltet adva. Emiatt elterjedt módszer a vérerek szegmentálása, mellyel a csúcsok nagy része kiszűrhető.

3.5.2 VÉREREK SZEGMENTÁLÁSA

A vérerek szegmentálása illesztett szűréssel történik. [Chaudhuri89] Egy ér keresztmetsete Gauss jellegű, alakja jellemzően hosszúkás: ennek megfelelően a vérér illesztett szűrője egy elnyújtott Gauss felület lesz. A szűrés során a felületet több irányba is elforgatják, és mindegyikkel külön-külön konvolválják. Egy adott pontra számított végeredmény a különböző szögek mellett kapott intenzitásértékek maximuma lesz, azaz az eredménykép egy $V(x, y)$ pontjára:

$$V(x, y) = \max(\gamma_1(x, y), \gamma_2(x, y), \dots, \gamma_n(x, y)), \quad (2)$$

ahol $\gamma_1, \gamma_2, \dots, \gamma_n$ a megfelelő szögek mellett nyert szűrt értékek. Vérérként ezután a V kép pontjainak legnagyobb intenzitással bíró adott százalékát jelölik meg, és alakjuk alapján szűrik az így kapott objektumokat. A folyamat kimenete egy maszk, mely tartalmazza az erezettséget. A jelöltállítás során tehát az ide eső jelöltekkel nem kell foglalkozni. (14. ábra)



14. ábra, vérerdetekálás illesztett szűrővel: az illesztett szűrő és az eredménykép

3.5.3 A TÉNYLEGES JELÖLTÁLLÍTÁS

A fenti két lépés elvégzése után tehát rendelkezésünkre áll egy illesztett szűrt kép, mely kiemeli a Gauss-jellegű felületeket, és kaptunk egy képet, mely az erezettséget tartalmazza. Ezen képek alapján történik meg a jelöltek halmazának felállítása.

Az illesztett szűrt képet először küszöbözik, azaz definiálnak egy értéket, és azon képpontokkal dolgoznak tovább, melyek intenzitása a küszöb fölé esik. [Martins08] Így kapnak egy kezdeti objektumhalmazt, melyből kiszűrjük azon elemeket, melyek az erekre esnek.

A megmaradt objektumokon további műveleteket végeznek, hogy valódi alakjukat megkapják: a küszöbözés csak durva becslésre jó. E célból alkalmaznak ún. régió-növelő algoritmusokat, melyek megvizsgálják adott objektum környezetét, és az intenzitásértékek alapján döntést hoznak, hogy a határpontokat hozzácsatolják-e az objektumhoz, vagy sem. A leggyakrabban alkalmazott régió-növelő módszer [Spencer96] munkája nyomán ismert.

3.6 A KLASSZIFIKÁCIÓ

Az előző lépések eredményeül rendelkezésre áll egy objektumhalmaz: ennek elemeiről szeretnénk eldönteni, hogy mikroaneurizmák-e, vagy sem. Ehhez minden egyes objektumra ún. feature-eket számítanak, amelyek tulajdonképpen az objektum bizonyos tulajdonságaiból generált mérőszámok. A kinyert mérőszámok segítségével pedig valamilyen döntéshozó rendszert (SVM, Bayes-klasszifikátor, neurális hálózat, döntési fa) taníttatnak.

3.6.1 LEGGYAKRABAN HASZNÁLT MÉRŐSZÁMOK

A definíciók során C -vel jelölöm a jelöltet alkotó pontok halmazát, O -val pedig a jelölt határoló-pontjait. $I_{g,i}$ jelöli a zöld csatorna, $I_{f,i}$ pedig az illesztett szűrt kép i . képpontjának intenzitásértékét. A gyakran használt mérőszámokat a 2. táblázat tartalmazza:

2. táblázat, a leggyakrabban alkalmazott mérőszámok

Név (Jelölés)	Kiszámítás
Terület (A)	$A = \sum_{i \in C} 1$
Kerület (P)	$P = \sum_{i \in O} 1$
Cirkularitás (c)	$c = \frac{P^2}{4\pi A}$
Zöld-intenzitás (z)	$\tilde{z} = \sum_{i \in C} I_{g,i}$
Szűrt-intenzitás (s)	$s = \sum_{i \in C} I_{f,i}$
Átlagos zöld-intenzitás (z_a)	$\tilde{z}_a = \frac{\tilde{z}}{A}$
Átlagos szűrt-intenzitás (s_a)	$s_a = \frac{s}{A}$

A fenti mérőszámokat [Martins06] alapján soroltam fel. [Cree06] által használt leíró az oldalviszony, melyet az adott objektum szélesség-magasság aránya határoz meg. Definiál olyan mérőszámokat is, melyek hasonlóak az *intenzitás*, *átlagos intenzitás* értékekhez, azonban átlag és szórás szerint normáltak: minden adatsorból tehát kivonja annak átlagát, és elosztja annak szórásával.

3.6.2 AZ ALKALMAZOTT DÖNTÉSHOZÓ RENDSZEREK

A fenti és hozzá hasonló mérőszámok segítségével igyekszünk egy adott objektumról meghatározni, hogy valódi aneurizma, vagy fals jelölt. Az irodalomban többféle döntéshozó rendszert is alkalmaznak:

- **Bayes-klasszifikátor:** [Cree08] cikke tesz említést erről, és ugyanitt említi meg, hogy ez a módszer csaknem ugyanolyan jó eredményeket produkált, mint más, kifinomultabb klasszifikációs módszerek.
- **Neurális hálózat:** [Mizutani09] háromrétegű feed-forward hálózatot használ, és [Martins08] is hasonlót alkalmaz.
- **LDA (lineáris diszkrimináns analízis), SVM (support vector machine), ADTree:** Az ADTree egy döntési fához hasonló módszert jelöl. [Streeter03] vizsgálja a három felsorolt rendszert hatékonyság szempontjából, s eredményei alapján a legegyszerűbb, LDA módszerhez képest az összetettebb módszerek alkalmazása nem hoz számottevő javulást.


4. AZ ELVÉGZETT MUNKA

Ebben a fejezetben dokumentálom az általam elvégzett munkát, jellemzem módszerem működését. Elemzem annak eredményeit, kitérek erősségeire és gyengeségeire egyaránt.

4.1 AZ ALAPÖTLET ÉS MOTIVÁCIÓ

Algoritmusom alapötlete – a gradiensvektorok és azok irányultságának felhasználása – már régebben megszületett, a 2010-es évben is ezen alapuló TDK dolgozatot készítettem: ekkor szemfenéki felvételeken történő vérérkeresést, és mellkasi röntgenfelvételen történő légmelldetektálást valósítottam meg. A dolgozat eredményei alapján döntöttem úgy, hogy folytatom a munkát, és az aneurizmák detektálására is kísérletet teszek jelen módszerrel.

A képfeldolgozási feladatok során gyakran alkalmazunk küszöbértéket, ami azonban nagyban függhet a kép intenzitás és kontrasztviszonyaitól. Egy jó küszöbérték megtalálása nehéz feladat, és megnehezíti a robusztus rendszerek megalkotását. A kép gradiens-értékeit gyakran használják például élek detektálására, azonban a gradiensvektorok irányának felhasználása nem túl gyakori az irodalomban, ez pedig intenzitás- s kontrasztviszonyoktól egyaránt független érték. A 15. ábrán két eltérő, 1.50 és 2.00 szórású Gauss-felület látható, rendre 1.00 és 0.10 csúcsmagassággal. A gradiensvektorok iránya, illetve hosszainak aránya is mindkét esetben változatlan. Célszerű tehát a gradiensvektorok irányinformációinak felhasználása, amely érzékenyebb képanalízist tesz lehetővé. Ugyanakkor, amint látni fogjuk, a módszer előnye egyben annak hátránya: az irányinformációk önmagában való alkalmazása túl sok fals pozitív jelöltet generál, így azok hatékony kiszűréséről gondoskodni kell.

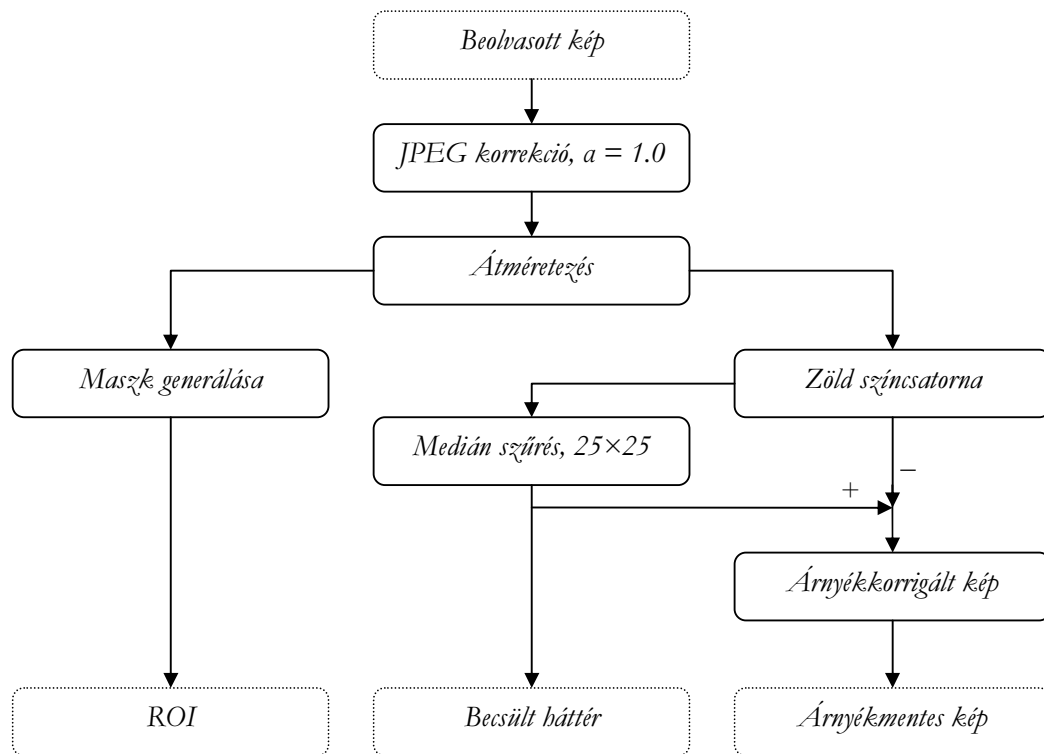


15. ábra, két eltérő szórású és amplitúdójú Gauss-felület és gradiens-vektorai

A ma alkalmazott aneurizma detektáló módszerek egyre jobb hatékonyságot érnek el, ugyanakkor még nem használják ki a gradiensvektorokból kinyerhető információt. Célom, hogy a gradiensvektorok vizsgálatával olyan, eddig nem alkalmazott mérőszámokra tegyek javaslatot, melyek más módszerekkel kombinálva képesek azok hatásfokát feljavítani, s így az eredményességet növelni.

4.2 AZ ELŐFELDOLGOZÁS LÉPÉSEI

Az előfeldolgozási lépéseket az alábbi 16. ábra illusztrálja:



16. ábra, az előfeldolgozás lépései


Az előfeldolgozás folyamatában nagyrészt követtem az irodalomkutatás során fellelt módszereket, s ugyanakkor alkalmazok olyan egyedi megoldásokat is, mellyel más leírásban nem találkoztam.

Az előfeldolgozási folyamatból kihagytam a medián illetve Gauss-szűrést. Ezt a saját, JPEG műtermékek hatását csökkentő algoritmusom alkalmazása miatt tettem meg: ez a módszer legalább olyan hatékonyan csökkenti a zajt, mint a Gauss-szűrés, amint arra a JPEG korrekcióval foglalkozó fejezetben rá fogok mutatni. A medián szűrés mellőzésének okát pedig a jelöltállításról szóló fejezetben részletezem.

A kép átméretezéséről a 3.4.1 fejezetben írtam. Én a legkisebb képszélességhez való igazodást használtam, tehát minden képet 768 képpont szélességűre méreteztem. A kapott eredmények ugyanis – legalábbis az én algoritmusom esetében – nem tértek el a legkisebb és legnagyobb képmérethez igazodó átméretezés esetén. A nagyobb feldolgozási sebesség érdekében esett választásom a kisebb képméretre.

4.2.1 SIMÍTOTT BÁZIST ALKALMAZÓ JPEG REKONSTRUKCIÓ

A kutatásom során – ahogyan az már említésre került – rendelkezésre álló felvételek JPEG formátumúak, s az oftalmoszkóp alapértelmezett tömörítési rátájának megfelelően lettek kódolva. A JPEG formátum közismerten veszteséges tömörítést jelöl: a hatékonyság egyre nagyobb növekedése jelentős adatvesztéssel társulhat. Ez a miatt okoz nehézségeket, mivel a mikroaneurizmák detektálása esetén apró foltokat keresünk, azonban a tömörítés okozta zaj képes akár teljesen elnyomni a hasznos jelet, amint a 17. ábrán is látható.




17. ábra, blokkosodás egy ROC adatbázisból származó képen, az aneurizma a kép közepén található

Megfigyelhető, hogy kép középpontjában található aneurizma folytonossága az erős tömörítés miatt megszakad, csak az emberi felismerés teszi lehetővé, hogy az objektumot mégis aneurizmaként azonosítsuk. Továbbá az ábrán az egyes blokkok széleinél megjelenő műtermékek is szembeűnőek. Az orvosi felvételeken alkalmazott tömörítés hatásával több cikk is foglalkozik. [Basu03, Cree08]JPEG] Munkám során [Bonet06] alapötletétől indulva egy simított bázis alapú JPEG rekonstrukciós módszert implementáltam és fejlesztettem tovább.

4.2.1.1 A SIMÍTOTT BÁZISÚ REKONSTRUKCIÓ ALAPJAI

Az alapötlet kifejtéséhez a JPEG formátumról lényegileg annyit kell megemlíteni, hogy DCT (*Discrete Cosine Transform*) alapú eljárást használ. A betömörítés során képet 8×8 -as egységekre bontják, és egy-egy ilyen területelemre számítják annak DCT együtthatóit. Ezen együtthatók a kisfrekvenciás komponensek esetén már igen kicsik, így ezeket elhanyagolják: ezzel nyernek tulajdonképpen tömörítési lehetőséget, s ugyanitt keletkezik a veszteség is az eljárás során. A 8×8 -as feldarabolásnak, és ezek egyenkénti feldolgozásának köszönhető a blokkhatárokon megjelenő műtermék, hiszen a betömörítés során a szomszédos blokkok nincsenek hatással egymásra, így a visszaállítás során a folytonosságuk megszakadhat. Minél nagyobb a tömörítési ráta, a blokkosodás egyre inkább előtűnik a képen, jelentősen rontva a sikeres képfeldolgozás esélyét.

A kép visszaállításánál az aktuális 8×8-as terület a DCT bázisfüggvényeknek a blokk DCT együtthatóival súlyozott összegeként áll elő. A DCT bázisfüggvényei láthatóak az alábbi 18. ábrán:



18. ábra, DCT bázisfüggvények


A simított bázisú rekonstrukció alapötlete az, hogy az egymás melletti blokkok nem függetlenek egymástól, hanem az átmenet a határaikon folytonos – legalábbis normál orvosi felvételeket feltételezve. A rekonstrukció során így a bázisfüggvényeket kiterjesztjük – azaz túl fognak lógni a 8×8-as területegységeken –, és az átlógó területeket megfelelő súllyal a szomszédos blokkokhoz is hozzáadjuk.

Súlyfüggvényként egy szigmoid-jellegű függvényt alkalmaztam:

$$f(x, \alpha, c) = \frac{1}{1 + e^{-\alpha(x-c)}}, \quad (3)$$


ahol α a függvény vágási sebességét adja meg, c pedig a görbe azon pontját, ahol az a 0.50 értéket felveszi. Az x értéket a 8×8-as blokk középpontjától mérjük.

Az c paraméter értéke 4 lesz: így kapunk két szomszédos blokk középpontjától egyenlő távolságra 0.50 értéket, tehát egyenlő súlyozást. Az α paraméter változtatásának hatását mutatja be a 19. ábra. Látható, hogy $\alpha \rightarrow \infty$ esetén közelítjük az eredeti rekonstrukciós módszert, az átmenet binárisává válik.



19. ábra, a szigmoid függvénykülönböző α értékek esetén, rögzített $c = 4$ érték mellett

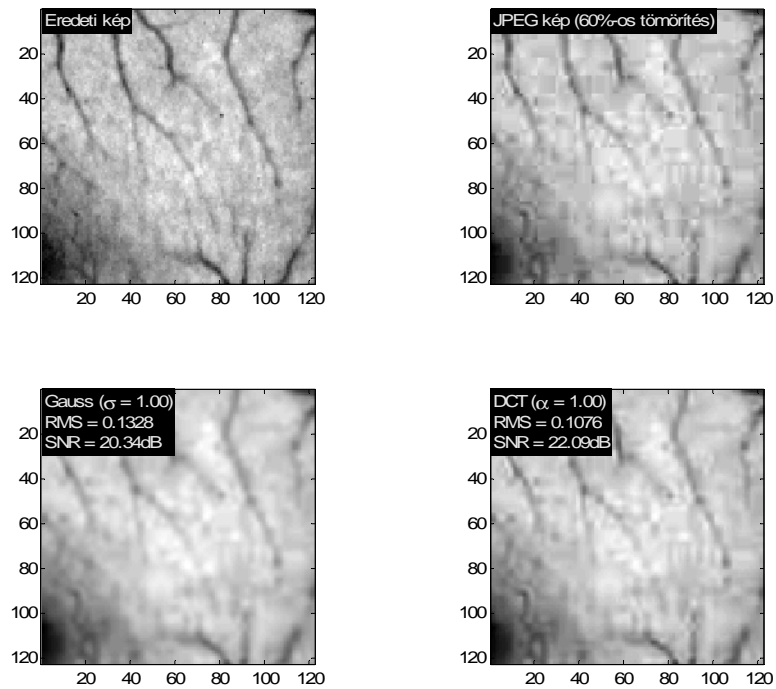
Az önmaguk ismétlésével kiterjesztett, valamint a blokk középpontjától való távolság függvényében súlyozott bázisokat mutatja be a 20. ábra.



20. ábra, a kiterjesztett és súlyozott bázisfüggvények, $a = 1.00$

4.2.1.2 REKONSTRUKCIÓS EREDMÉNYEK

A 21. ábrán egy tömörítés-mentes felvételre nyert eredmények láthatóak. A referencia-képet először betömörítettem, majd külön-külön vizsgáltam a tömörített képen alkalmazott Gauss-simítás és a simított bázisú rekonstrukció hatását. A két képre kapott jel-zaj viszony és RMS érték kedvezőbb a simított bázison alapuló módszer esetén, ráadásul a Gauss-simított kép esetében néhol még mindig megfigyelhető a blokkhatárokon keletkezett zaj. Ennek mértéke a Gauss-szűrő szórásának növelésével csökkenthető lenne ugyan, de ekkor a jel-zaj viszony tovább romlana. Ez az oka, amiért az előfeldolgozás során nem alkalmazok Gauss-szűrést, hanem helyette a simított bázisú rekonstrukciót alkalmazom.



21. ábra, a kapott eredmények Gauss-simítás és simított bázisú rekonstrukció esetén

A fenti mérőszámok a referenciaképhez viszonyítva értendők, s definíciójuk az alábbi:


$$RMS = \sqrt{\frac{\sum_x \sum_y (R(x, y) - S(x, y))^2}{xy}} \quad (4)$$

$$SNR = 20 \log \left(\frac{xy}{\sum_x \sum_y |R(x, y) - S(x, y)|} \right) \quad (5)$$

ahol $R(x,y)$ jelöli a referencia-, míg $S(x,y)$ a mintakép adott pozíciójában lévő képpont intenzitásértékét.

A módszer előnye, hogy elnyomja a blokkhatáron keletkező zajt, ugyanakkor megőrzi a számunkra fontos struktúrákat. Ezen felül a blokkok közepén található intenzitásértékek szinte változatlanok maradnak, a simítás a blokkhatárookra terjed ki. A módszer alkalmazása tehát célszerű az előfeldolgozás során.

Az alfejezet elején látható képre kapott eredményt mutatja be a 22. ábra. A művelet jól láthatóan helyreállította a kép közepén látható, teljesen eltorzult aneurizmát is; megőrizte a fontos struktúrákat, és jelentős mértékben lecsökkentette a tömörítés okozta zajt.




22. ábra, az alfejezet elején található mintára kapott eredmény

4.2.2 A ROI KIJELÖLÉSE

A ROI (*Region of Interest*) a feldolgozandó kép számunkra érdekes területét jelöli. Ennek ismerete alapján nem kell végeznünk fölösleges számításokat a kép olyan részein, melyeken esély sincs jelöltek, elváltozások detektálására.

Az első lépés, hogy előtérként jelöljük meg a zöld csatorna 16-nál nagyobb intenzitású képpontjait: a valós szemfenék legtöbb képpontja ilyen. Kitöltjük az előtérrel fellelhető kisebb lyukakat, melyeket például egy rendkívül sötét aneurizma okozhat. Ezt követően azt az objektumot hagyjuk meg, amely a teljes képméret legalább 50%-át kiteszi. Az így kapott eredményt utolsó lépésként erodáljuk a kisebb zajok eltüntetésére érdekében. Egy bemeneti kép, és a kapott maszk látható a 23. ábrán.



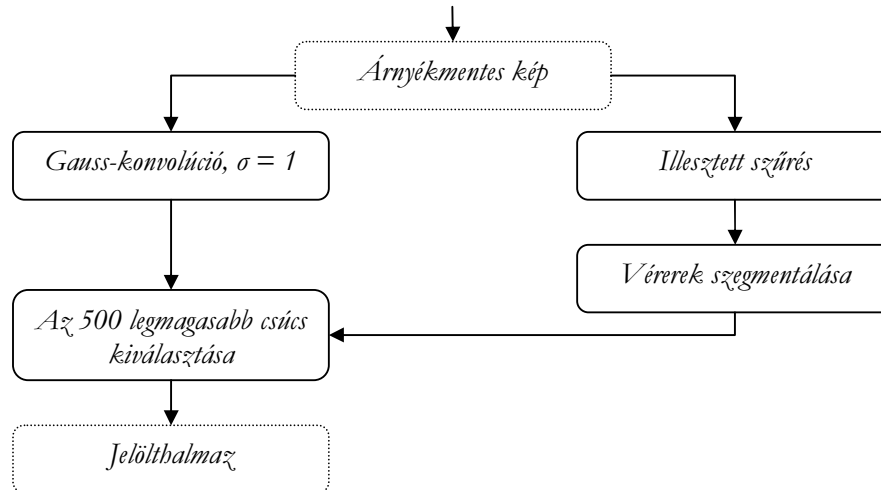
23. ábra, bemeneti kép és a hozzá tartozó maszk

4.2.3 HÁTTÉRBECSLÉS, ÁRNYÉKKORREKCIÓ

Az irodalmi módszerekkel egyezően a zöld színcsatornával dolgozom tovább, a háttér becslését én is 25×25 ablakméretű medián szűrővel végzem. Az árnyékkorrigált képet az eredeti és a simított kép különbségeként képezem.

4.3 A JELÖLTÁLLÍTÁS

Jelöltállítási módszerem folyamatát mutatja be az alábbi 24. ábra:



24. ábra, a jelöltállítás folyamata

Jelöltállítási módszerek tesztelésére, fejlesztésére ezen dolgozat keretein belül nem nyílt kifejezetten lehetőségem, így a legegyszerűbb utat választottam, mely azért még elegendő számú jelöltet szolgáltat a gradiens alapú aneurizma-detektálás fejlesztéséhez.


A jelöltállítás első lépése illesztett szűrés, amely kiemeli az aneurizmákat. Szűrőként egy 1.0 szórású Gauss-felületet használok a 3.5.1 fejezetben említettek miatt. Ezután jelöltnek egy szűrt képen az 500 legmagasabb csúcsot tekintem. A küszöbszám választásához megvizsgáltam, hogy egy képen, adott K legmagasabb csúcs választása esetén, mind az 50 képet vizsgálva az azokon található 336 aneurizma közül hány esik bele a generált $50 \times K$ elemű halmazba. Az eredményeket a 3. táblázat tartalmazza:

3. táblázat, a legmagasabb K csúcs halmazába eső aneurizmák száma és az összes jelöltek száma

K	Helyes, összes	K	Helyes, összes
50	108, 2500	500	198, 25000
100	130, 5000	750	209, 37500
250	162, 12500	2000	245, 100000

A küszöb kiválasztása során figyelembe vettem [Mizutani09] eredményeit is, akik 140 aneurizmát jelöltek meg nehezen láthatóként. Ezen aneurizmákat megvizsgálva, azok alakja kis mértékben közelíti a Gauss-felületet, így az illesztett szűrés kisebb értéket fog rájuk adni. Azt feltételeztem tehát, hogy ezzel a 140 aneurizmával nem számolva nagyjából 190-210 aneurizma az, amelyet egy egyszerű illesztett szűréssel kinyerhetek. A fals pozitív jelöltszám csökkentése érdekében pedig az 500 és 750 értékek közül az előbbit választottam. Az így nyert jelöltek túlnyomó többsége a Mizutani által jól láthatónak ítélték közé tartozik.

A vérerek szegmentálását a 3.5.2 fejezetben tárgyaltaknak megfelelően végeztem. A szűrő egy $\sigma_x = 6.00$ és $\sigma_y = 1.25$ szórású Gauss-felület volt. A szűrt képen vérérként a képpontok legnagyobb intenzitással bíró 10%-át jelöltem meg: Az így kapott objektumokra végeztem el az alakvizsgálatot, és szűrtem ki a kerekdedeket, amint a 25. ábra illusztrálja.



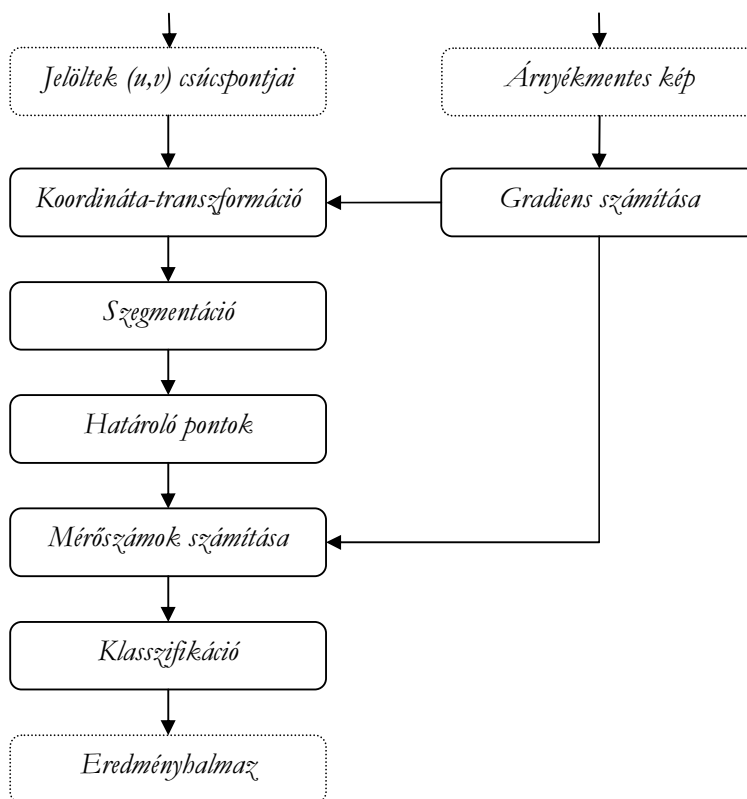
25. ábra, a vérszegmentálás folyamata

A bal felső ábrán szerepel a kiindulási árnyék-korrigált kép, a jobb felső ábra mutatja az illesztett szűrés eredményét. A bal alsó ábrán az intenzitás alapján felső 10%-ba került képpontok láthatóak, a kerekded objektumok szűrése utáni állapotot a jobb alsó ábra mutatja.

4.4 A KLASSZIFIKÁCIÓ

Az irodalmi módszerektől eltérően a jelöltállítás során nem alkalmaztam régiónövelő algoritmust. Nálam ez a részlépés már inkább a klasszifikációhoz tartozik, itt történik meg az aneurizma területének becslése a gradiensvektorok feldolgozása alapján.

A klasszifikáció folyamata az alábbi 26. ábrán látható:




26. ábra, a klasszifikáció folyamata

A jelöltállítás eredményeül a csúcsok koordinátáit tartalmazó (u,v) halmazt kapom, a gradiens-vektorokat pedig az árnyékmentesített képből számítom. A klasszifikáció során az ezen vektorokból kinyert információk alapján dolgozok, s állítom elő a mérőszámokat.

4.4.1 KOORDINÁTA-TRANSZFORMÁCIÓ


A koordináta transzformáció szerepének kifejtése előtt tekintsük a 27. ábrát, s figyeljük meg a gradiensvektorok elhelyezkedését és irányát.



27. ábra, egy valós és az ideális aneurizma gradiensvektor-tere

A valós aneurizma alakja s vektortere jól közelíti az ideálist. A vektorok sugárirányban, kifelé mutatnak az aneurizma középpontjából, hosszuk az aneurizma határoló-pontjaiban a legnagyobb. Ezen tulajdonságok azok, melyeket ki fogok használni a továbbiakban.

A szimmetria miatt végzem el az aneurizma környezetén a koordináta-transzformációt, és építék fel az így kinyert vektorokból egy táblázatot. A folyamatot a 28. ábra illusztrálja.




28. ábra, a koordináta-transzformáció

Az x-ek jelölik a mintavételi pontokat, melyeket a középponttól kiindulva egyenletes távolságonként veszek fel. Miután egy irány mintavételezése véget ért, a következő irányra lépek, és folytatom a mintavevést. Eközben az ábrán illusztrált táblázat megfelelő mezőjét kitöltöm a mintavételi pontban vett gradiensvektor értékkel: mivel az adatok csak a diszkrét pontokban állnak rendelkezésre, így az aktuális értéket bilineáris interpolációval kapom meg. Képletekkel felírva a műveletet, az (x, y) mintavételi pontok koordinátái:

$$(x, y) = (u + d \cos \beta, v + d \sin \beta), \quad (6)$$

$\beta \in \{0, \Delta\beta, 2\Delta\beta, \dots, 360^\circ - \Delta\beta\}$, $\Delta\beta = 18^\circ$, $d \in \{0, \Delta d, 2\Delta d, \dots, 10\}$, $\Delta d = 0.5$, (u, v) pedig az aktuálisan vizsgált aneurizma középpontja. A d paraméter maximális 10 értéke megfelelő, mivel egy 768 képpont széles felvételen egy aneurizma átlagosan 5-7 képpont átmérőjű. A művelet eredményét mutatja be a 29. ábra.



29. ábra, a koordináta-transzformáció kiindulási képe, eredménye és a referencia vektormező

Az ábrán illusztráltam a táblázat minden egyes mezőjéhez tartozó referenciavektort is: amely egy egységnyi, sugárirányú vektor. A valós kapott értékek láthatóan jól közelítik az ideálist; az aneurizmától távolodva, abból kiérve pedig a vektorok iránya egyre zajosabb. Rendelkezésre áll tehát a valós és a referencia vektorhalmaz. Innen két értéket számítok ki minden egyes vektorra, melyek jellemzik annak jóságát, s így közvetve a vektortér általános jóságát is:

- $|\bar{a}_{\text{vetített}}|$: a vektor ideális-, azaz sugárirányba vetített hossza
- $\cos \varphi$: a vektor és az ideális irány által bezárt szög koszinusza

A skalárszorzat segítségével mind a két érték könnyen kiszámítható, hiszen:


$$\bar{a} \cdot \bar{b} = |\bar{a}| |\bar{b}| \cos \varphi, \quad (7)$$

ahol $|\bar{a}|$ jelöli az éppen vizsgált vektort, $|\bar{b}|$ pedig az egységnyi hosszú referenciát, tehát $|\bar{b}| = 1$. A számítandó értékek:

$$|\bar{a}_{\text{vetített}}| = |\bar{a}| \cos \varphi = \bar{a} \cdot \bar{b} \quad (8)$$

$$\cos \varphi = \frac{\bar{a} \cdot \bar{b}}{|\bar{a}|} \quad (9)$$


Grafikusan ábrázolva az előző ábrán kapott vektortérre a számított értékeket (30. ábra):



30. ábra, a számított jósági értékek ábrázolása

4.4.2 SZEGMENTÁLÁS ÉS HATÁROLÓ PONTOK

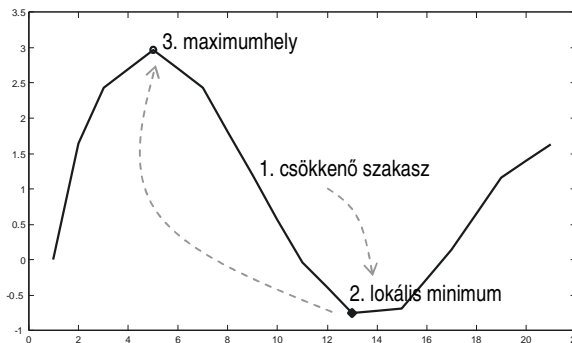
Az aneurizma Gauss-felülettel való közelítéséből az is adódik, hogy a gradiensvektorok hossza az aneurizma középpontjától távolodva adott jelleg szerint változik. Egy 1.0 szórású félbevágott Gauss-függvényt és annak deriváltját illusztrálja a 31. ábra. A jobb láthatóság érdekében a derivált-függvény normált, a Gauss-függvény pedig negált, hiszen az aneurizma intenzitása a környezetétől alacsonyabb.



31. ábra, Gauss-függvény (szaggatott vonal) és annak deriváltja (folytonos vonal)


Látható, hogy a derivált a maximális értékét a Gauss-függvény szórásának megfelelő helyen veszi fel. Amennyiben megkeressük az $|\vec{a}_{\text{vetített}}|$ értékeket tartalmazó mátrixban az oszlopok maximumhelyeit – tehát az egyes irányok mentén nyert gradiensvektorok közül a leghosszabbak távolságát a középponttól, megkapjuk a vizsgált aneurizma határoló pontjait minden irányra. Az $|\vec{a}_{\text{vetített}}|$ mátrix alkalmazása amiatt célszerű, mivel ez mutatja meg adott vektor sugárirányú komponensének hosszát.

A maximumhely keresése az alábbi módon zajlik: minden egyes oszlopra megkeresem az első olyan szakaszt, melynek három egymást követő eleme monoton csökken, majd a kapott szakasz utáni első lokális minimumhelyet veszem. Maximumot az adott oszlop első eleme s a kinyert minimumhely között keresem. Az egyes lépéseket a 32. ábra mutatja be.




32. ábra, a maximumhely keresési folyamata egy valós oszlop értékeire

Az oszlopokra elvégezve a műveletet, minden irányra megkapom az aneurizma határpontjainak középponttól mért becsült helyét. Három esetet mutat be a 33. ábra, a módszer megfelelően körülkeríti az objektumot.



33. ábra, három illusztráció az aneurizma szegmentálására

Ezen információk birtokában legenerálható az objektum pontjait tartalmazó maszk, melyet a 34. ábra illusztrál.




34. ábra, maga az objektum, illetve annak belső pontjait leíró maszk

Felmerülhet a kérdés, hogy miért nem alkalmaztam a mások által használt régiónövelő algoritmust. Ezen algoritmus működése intenzitásértékeken alapul: egy (x, y) pontot akkor vesz hozzá az aktuális objektumhoz, amennyiben teljesül rá az alábbi feltétel:

$$I_{x,y} \geq I_{max} - 0.5(I_{max} - I_{bg}), \quad (10)$$

ahol $I_{x,y}$ a képpont intenzitását jelöli. I_{max} az objektum középpontjának intenzitása, I_{bg} pedig a középpont helyén becsült háttérintenzitás. Előfordulhat olyan eset – például két aneurizma egymás közelében, vagy egy aneurizma egy vérér közelében helyezkedik el –, amikor az intenzitásérték nem csökken a megadott küszöb alá, és így a két szomszédos objektum összeolvad. A gradiens alapú módszer az ilyen esetek egy részét kiszűri, helyesen kerítve körül az objektumot, mivel figyelembe veszi nemcsak az intenzitásértékeket, hanem annak változásait is. Egy ilyen esetet mutat be a 35. ábra.



35. ábra, a régiönövelő módszer és a gradiens alapú módszer összehasonlítása

Az intenzitáson alapuló régiönövelő módszer összevonta a véreter az aneurizmával, míg a gradiens alapú módszer sikeresen körülhatárolta. Ez utóbbi módszer további előnye, hogy működéséből fakadóan automatikusan szolgáltatja az egyes irányokban mérhető maximális gradiens-értékeket és azok helyét. Az aneurizma kinyert határoló pontjai az objektum-háttér átmenet karakterisztikus pontjainak felelnek meg.

4.4.3 AZ ALKALMAZOTT MÉRŐSZÁMOK


Ebben az alfejezetben részletezem az általam definiált mérőszámokat. A definíciók előtt azonban tekintsünk át néhány, mérőszámok számításához használt adathalmazt és azok tulajdonságait. G_A -val jelölöm az aneurizma területére, G_p -vel pedig a határpontjaira eső gradiensvektorok halmazát – mindkettőt a sugárirányra vetített vektorokból képezem. $X(G)$ -vel és $Y(G)$ -vel hivatkozok az adott G vektorhalmaz X és Y komponenseiből képzett halmazokra. D_i az adott határpontnak az objektum középpontjától vett távolságát jelenti.

4.4.3.1 A GRADIENS VEKTOROKBÓL KÉPZETT KOVARIANCIA MÁTRIX

A tapasztalataim alapján egy aneurizmára eső gradiensvektorok x, y komponenseiből képzett cov_{G_A} kovariancia-mátrix jól felhasználható a jó jelöltek azonosítására.

$$cov_{G_A} = \begin{bmatrix} cov(X(G_A), X(G_A)) & cov(X(G_A), Y(G_A)) \\ cov(Y(G_A), X(G_A)) & cov(Y(G_A), Y(G_A)) \end{bmatrix} \quad (11)$$

A cov_{G_A} mátrix sajátértékeit jelöljük λ_1 és λ_2 -vel. A sajátértékek gyakorlati jelentése ebben az esetben a következő: az origóba eltoljuk a G_A vektorait, s ezek végpontjaiból ponthalmazt képzünk. Az így nyert ponthalmaznak a cov_{G_A} mátrix sajátvektorai által meghatározott irányokra vett szórása lesz λ_1 és λ_2 . Gauss-felület esetén a végpontok minden irányban azonos valószínűséggel fordulnak elő, így λ_1 és λ_2 közel azonos értékű lesz, míg vérér vagy zaj esetén a két vektor aránya torzul. A λ_1 és λ_2 értékek jelentését, illetve torzulásukat illusztrálja a 36. ábra.

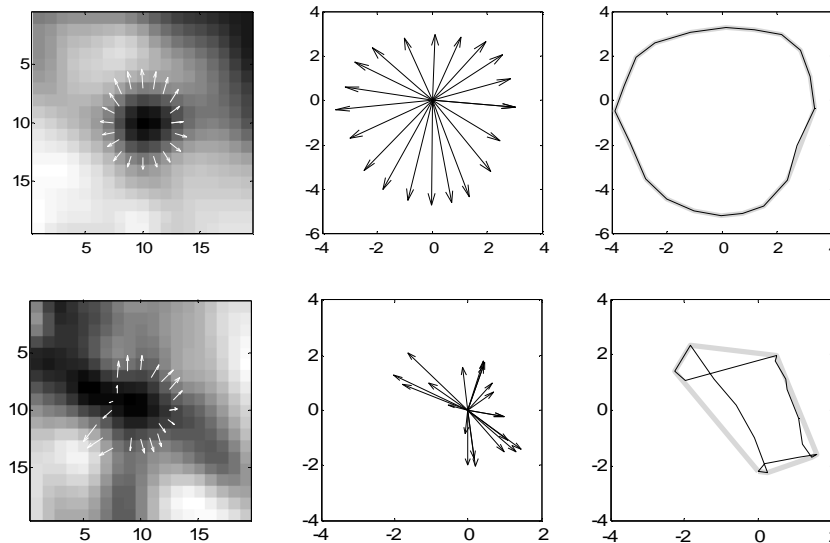


36. ábra, a kovariancia-mátrix sajátértékeinek jelentése, illetve torzulása

A bal oldali ábra egy jó jelöltet mutat be, míg a jobb oldali egy fals találatot illusztrál. A nyilak a sajátvektorok irányába mutatnak, hosszuk pedig a hozzájuk tartozó sajátértékeknek felel meg. Jól látható a második esetben a torzulás.

4.4.3.2 A GRADIENS VEKTOROKBÓL KÉPZETT POLIGON

A gradiens vektorokból képzett poligonhoz a G_p halmazt használom fel, vektorait az előzőekhez hasonlóan az origóba tolom el. A vektorok végpontjai adják meg a poligon csúcsait, a poligon oldalainak képzésénél pedig megtartom a gradiensvektorok sorrendjét, tehát két szomszédos határpontra eső gradiensvektor határozza meg a poligon egy oldalát. A ponthalmaz ideális esetben egy kört alkotna, de még némileg torzult felületek esetén is jellemző rá a konvex alak. A fals jelöltek esetén nagy valószínűséggel fordulnak elő eltorzult poligonok, így ez a tulajdonság is felhasználható a mérőszámok képzésénél.



37. ábra, a G_p gradiens vektorokból képzett poligon, középen az origóba tolt gradiensvektorok

A 37. ábra felső része egy jó, míg az alsó egy fals találatra generált poligont ábrázol. Halványzürkével a poligon konvex befoglalóját jelöltem, a különbség szembetűnő.

4.4.3.3 A MÉRŐSZÁMOK DEFINÍCIÓI

4. táblázat, a gradiens vektorok alapján definiált mérőszámok és leírásuk

Megnevezés	Számítási mód	Leírás
Sajátértékek	λ_1, λ_2	A 4.4.3.1 fejezetben leírtaknak megfelelően a két sajátérték nagysága jól jellemzi az objektum alakját.
Szimmetria	$\frac{\min(\lambda_1, \lambda_2)}{\max(\lambda_1, \lambda_2)}$	Szintén a 4.4.3.1 fejezetben leírtak alapján egy eloszlás minél jobban közelíti az ideális, a sajátértékei annál egyezőbbek, a hányados annál jobban közelíteni fogja az 1.0 értéket.
Gradiens-összeg	$\sum G_p $	A határpontokon lévő gradiens-hosszok összege mutatja meg, milyen karakteres az objektum-háttér átmenet.
Fázismedián	$\text{medián}(\varphi(G_p) - \varphi(S_p))$	A fázismedián megmutatja, mekkora a G_p halmaz egyes elemeinek a hozzájuk tartozó S_p sugár-irányoktól mért szögeltéréseinek mediánja. Ideális esetben ez nyilván zérus.
Fázisszórás	$\text{szórás}(\varphi(G_p) - \varphi(S_p))$	A fázisszórás szintén a G_p halmaz tagjainak ideális iránytól való eltérését jellemzi. Tapasztalataim alapján minél kisebb ez az érték, annál jobb az adott jelölt.
Határsimaság	$\sum_i 1 : D_i - D_{i+1} < 1.5$	Egy jó jelölt szomszédos határpontjainak a középponttól mért távolsága igen ritkán tér el 1.5 képponttól nagyobb mértékben. A határsimaság megmutatja, mennyire teljesül ez a feltétel az objektumra.
Konvexitás	$\frac{\text{poligonTerület}}{\text{konvexTerület}}$	A jó aneurizma-jelölt a 4.4.3.2 fejezetben leírt konvex alakú poligont generál, ekkor a hányados 1.0 értéket vesz föl. Minél extrémebb alakot ölt a poligon, annál kisebb lesz a hányados, mivel a konvex befoglaló területe annál jobban eltér a poligon tényleges területétől. (Amint az a 37. ábrán látható volt.) Ez a jelenség a fals jelöltekre jellemző.

Főkomponens-analízis segítségével megvizsgáltam azt, hogy ezek közül melyek nem visznek be értékes információt a számításokba, melyek nem segítik a jelöltek klasszifikálását – tehát elhagyhatóak.

Eredményeim alapján a *gradiens-összeg* mérőszám volt ilyen, melynek jelentését jobban átgondolva ez valóban lehetséges. A G_p halmaz elemei a határpontokon elhelyezkedő, így a legnagyobb hosszal rendelkező vektorok: nyilván ezek lesznek azok, melyek leginkább meghatározzák a λ_1 és λ_2 értékeit.

4.4.4 A JELÖLTEK KLASSZIFIKÁLÁSA

Kutatásom során több klasszifikációs lehetőséget kipróbáltam, mint például a döntési-fa, az SVM vagy a neurális hálózat. Tapasztalataim alapján a legutóbbi szignifikánsan jobb eredményeket szolgáltatott: klasszifikációra így [Mizutani09] cikkében leírtakhoz hasonlóan egy előrecsatolt neurális hálózatot használok hiba-visszaterjesztéses tanulási módszerrel.

A neurális hálózathoz szükséges tanítóhalmazt biztosítani. Mivel a rendelkezésre álló adatbázisban 50 képhez vannak megadva a referencia adatok, ezzel a halmazzal dolgoztam. Első lépésként végigfuttattam az 50 képre a jelöltállítást, és mindegyik kép minden jelöltjére eltároltam a kinyert mérőszámokat. Így végül egy olyan saját adatbázishoz jutottam, amely tartalmazta az összes lehetséges jelölt minden adatát, nagyban felgyorsítva a klasszifikációs folyamat kialakítását és tesztelését.

Az 50 képet két 25-ös csoportra osztottam. A tanító halmaz 122, a teszthalmaz pedig 76 aneurizmát tartalmaz. A pontos számadatokat az *5. táblázat* tartalmazza.

5. táblázat, a tanító és teszthalmazok adatai

	Képek száma	Összes aneurizma	Jelöltállításon átment
<i>Összesen</i>	50	336	198
Tanítóhalmaz	25	213	122
Teszthalmaz	25	123	76

A neurális hálózat tanítására használt végső adatsor előállítására az alábbi módon zajlik. Veszem a tanító halmaz 25 képéhez tartozó 25×500 jelöltet – hiszen a jelöltállítást során az 500 legmagasabb csúcsot hagytam meg, tehát ennyi jelöltem van egy képre –, s kiválogatom a valódi aneurizmákhoz tartozó adatsorokat. Ezután a maradék fals jelöltekből egyenletes eloszlás szerint 250 adatsort adok hozzá a tanító adathalmazhoz, mely így összesen $122 + 250$ objektum adatait tartalmazza.

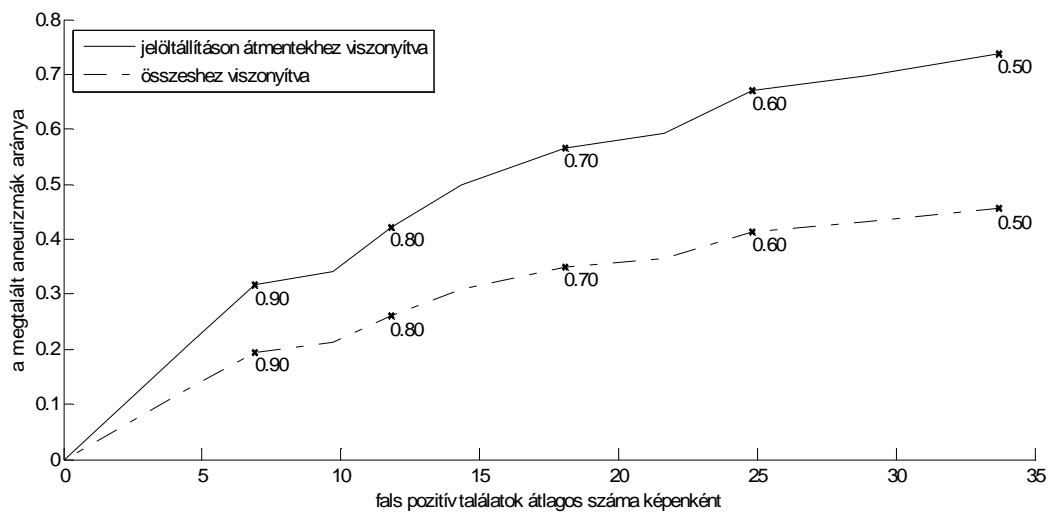
A neurális hálózat tanítása során variáltam a rétegek számát és az ezekben elhelyezkedő neuronok számát is, majd figyelemmel kísértem a különböző struktúrák mellett kapott eredményeket. A végső, legsikeresebb struktúra két rejtett réteget tartalmaz, egyenként 2-2 neuronnal: az ezzel a hálózattal kapott végeredményeket a következő fejezetben elemzem részletesen.

5. EREDMÉNYEK

Az előző fejezetben tárgyaltam algoritmusom alapjait, jellemeztem a jelöltállítási illetve klasszifikációs módszeremet. Jelen fejezet célja, hogy a kapott eredményeket áttekintsem, ezeket kielemezzem, rámutatva a gradiensen alapuló mérőszámok alkalmazásának előnyeire és hátrányaira egyaránt.

5.1 GRADIENS ALAPÚ MÉRŐSZÁMOKKAL NYERT EREDMÉNYEK

A 4.4.4 fejezetben tárgyaltaknak megfelelően a klasszifikációt egy neurális hálózattal végeztem el. A tesztalmazra kapott eredményeket a 38. ábra mutatja be.



38. ábra, a neurális hálózattal nyert eredmények

Az fent látható grafikon vízszintes tengelyén a fals pozitív találatok átlagos képenkénti száma, a függőlegesen pedig a megtalált aneurizmák aránya követhető szemmel. Az arányt a jelöltállításon átment aneurizmák számához, valamint a tesztalmaz képein található összes aneurizma számához képest is mértem.

A neurális hálózat kimenete minden bemeneti mérőszám-halmazra egy numerikus érték, mely jelzi, hogy a találat milyen mértékben lett aneurizmának ítélve: ez minél jobban közelíti az 1.0 értéket, annál valószínűbb, hogy aneurizmáról van szó. Definiálható tehát egy küszöbérték, amely alatt hamisnak, fölötte pedig jónak tekintjük az aktuális jelöltet. Ez a küszöbérték is ábrázolva van a 38. ábrán. Látható, hogy a küszöb csökkentésével nő a megtalált aneurizmák száma, ám ezzel párhuzamosan megnő az egy képre eső fals pozitív találatok száma is.

5.1.1 ÖSSZEVETÉS MIZUTANI EREDMÉNYÉVEL

Az enyémhez hasonló jellegű kiértékelést [Mizutani09] tett. Eredményeink összevetése amiatt érdekes, mivel ő volt, aki megkülönböztette a jól látható jelölteket a nagyon nehezen láthatóaktól. A 4.3 fejezetben leírtak alapján a jól látható jelöltekre nyert halmazaink igen egyezők, így az ezekre kapott mérőszámok összevetése is informatív. Eredményeink a 6. táblázatban találhatóak. Az itt szereplő arányszámaim a 0.6 küszöbérték alkalmazásakor kapott értékeket tükrözik.

6. táblázat, Mizutani és a saját eredményeim összevetése

	Fals pozitív találatok képenkénti átlagos száma	Jó találatok aránya az összes aneurizmához viszonyítva	Jó találatok aránya a jól látható aneurizmákhoz viszonyítva
Mizutani	27.04	0.449	0.648
Saját	24.84	0.415	0.671

Mizutani intenzitás alapú, én pedig tisztán gradiens alapú mérőszámokat alkalmazok. Amint látható, a két módszer közel azonos arányszámokat szolgáltat. Nálam kisebb a fals pozitív találatok képenkénti átlagos száma. Érdekes jelenség, hogy az összes és a jól látható aneurizmákra kapott arányszámok megfordultak: ennek oka az eltérő teszhalmaz méret.

Az összevetés alapján elmondható, hogy algoritmusom közel megegyező hatékonyságú Mizutaniéhoz viszonyítva.

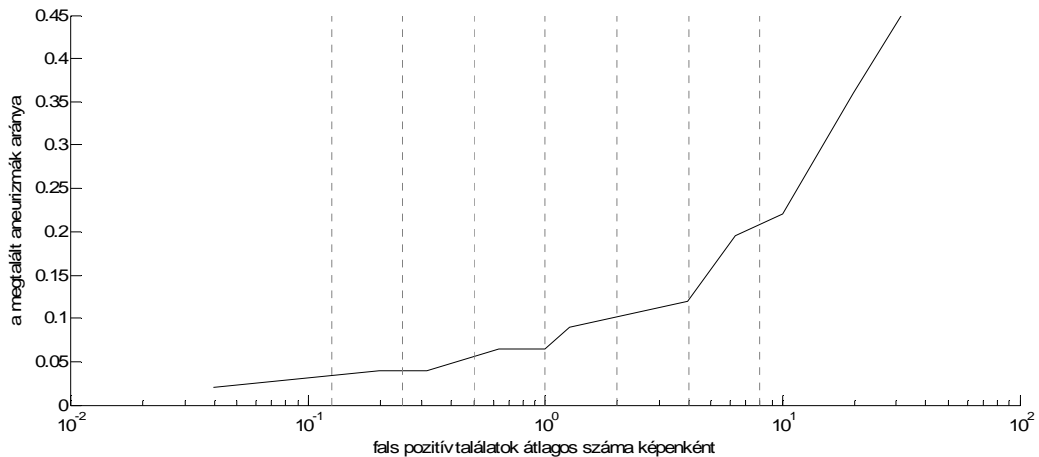
5.1.2 ÖSSZEVETÉS A ROC VERSENY EREDMÉNYEIVEL

Ahogy már említettem, a ROC adatbázis köré verseny szerveződik, az itt résztvevő algoritmusok eredményei hozzáférhetőek. Célszerű tehát ezekkel is összevetni módszerem eredményességét. Ehhez először ki kell térni a ROC esetén alkalmazott hatékonyságmérési módszertanra.

A különféle algoritmusok kimenetétől minden aneurizmaként klasszifikált jelölt kap egy valószínűségi értéket, mely megmutatja, mennyire biztosnak ítéli az algoritmus, hogy a jelölt valóban aneurizma. Ilyen például esetemben a neurális háló kimeneti értéke. Eredményes működéskor azt várjuk, hogy valószínűség szerint csökkenő sorrendben haladva kezdetben nagyon sok jól megjelölt aneurizmát találunk a kimeneti halmazban, majd a valószínűség csökkenésével egyre több fals találatra bukkanunk.

A ROC kiértékelés során először az általam 38. ábrán bemutatotthoz hasonló grafikont készítünk, melyet ezután mintavételezünk az egy képre eső átlagos fals pozitív találatok száma szerint, az $\frac{1}{8}$, $\frac{1}{4}$, $\frac{1}{2}$, 1, 2, 4, 8 helyeken. Célszerű a vízszintes tengelyen logaritmikus skálát felvenni az ábrázolás során. Az így kinyert értékek átlaga lesz az algoritmust jellemző végső mérőszám.

Algoritmusom során valószínűségi értéként a neurális hálózat kimeneti értékét adtam. Módszerem eredményeinek ROC kiértékelését a 39. ábra illusztrálja.



39. ábra, algoritmusom ROC kiértékelése 0.6 küszöbszám esetén és a mintavételi pontok

A mintavételi pontokban felvett értékeket, más módszerek értékeivel párhuzamosan, pedig a 7. táblázat tartalmazza:

7. táblázat, a mintavételi pontokban felvett értékek


Algoritmus	$\frac{1}{8}$	$\frac{1}{4}$	$\frac{1}{2}$	1	2	4	8	átlag
Saját	0.035	0.041	0.054	0.065	0.109	0.118	0.208	0.090
Wakiato	0.055	0.111	0.184	0.213	0.251	0.300	0.329	0.296
IRIA Group	0.041	0.160	0.192	0.242	0.321	0.397	0.493	0.264
Fujita Lab	0.181	0.224	0.259	0.289	0.347	0.402	0.466	0.310
DRScreen	0.173	0.275	0.380	0.444	0.526	0.599	0.643	0.434

A táblázatba a három legrosszabbul és a jelen pillanatban legjobban teljesítő módszer eredményeit jegyeztem fel. A különbség szembeötlő, az algoritmusom ezen értékelés szerint jócskán elmarad a többi módszertől.

A 38. ábrán látható görbe a versenyben résztvevő algoritmusok által szolgáltatottakkal ellentétben nem fut fel hirtelen, meredekebb szakasza a képenkénti átlagos négy fals találat után kezdődik. Ez azt sejteti, hogy a neurális háló ugyan hatékonyan megkülönbözteti a jó jelölteket a hamisaktól, ám az általa szolgáltatott valószínűség már nem áll arányban a jelölt jóságával, legalábbis nem olyan mértékben, mint arra számítani lehetne. Két okot tartok valószínűnek, amely ezt a jelenséget okozza:

- A tanítóhalmaz relatív kis mérete.
- A gradiens alapú mérőszámok használata.


Bővebb magyarázatot az utóbbi állítás igényel. A 4.1 fejezetben már utaltam rá, hogy ami a gradiens alapú mérőszámok előnye, az egyben a hátránya is: nem veszi figyelembe az intenzitásviszonyokat. Például egy aneurizma-jelölt kontrasztviszonyaira nem lehet belőlük mélyebb következtetéseket levonni. Módszerem így érzékeny a Gauss-felülethez hasonló zajokra, illetve a vérereken is gyakran ad fals találatot. Ezen eseteket a 40. ábra illusztrálja:



40. ábra, a felső sorban véreren talált, az alsóban a zaj miatt generált fals találatok láthatóak

Az ábrán látható találatok mindegyike 0.90 fölötti valószínűséggel rendelkezik neurális hálózatom kimenete alapján. Alakjuk valóban jól közelíti az ideális esetet, de a környezetük, intenzitásuk elemzése alapján azonban jó eséllyel kiszűrésre kerülnének. Ezt a miatt nem állítom biztosan, mivel számos olyan esettel találkoztam, amikor egy elváltozás rendkívül hasonlított egy aneurizmához, ám mégsem szerepelt a ROC adatbázisban megjelölve.

Néhány ilyen esetet mutat be a 41. ábra.



41. ábra, a (ROC adatbázis alapján) jó találatok a felső, a hamisak az alsó sorban helyezkednek el

A fenti ábrákról még figyelmes szemlélődés után sem lehetne egyértelműen eldönteni, hogy melyik tartalmaz igazi s melyik hamis jelöltet. Ez is jól mutatja a feladat összetettségét és az emberi szaktudás elengedhetetlen voltát.

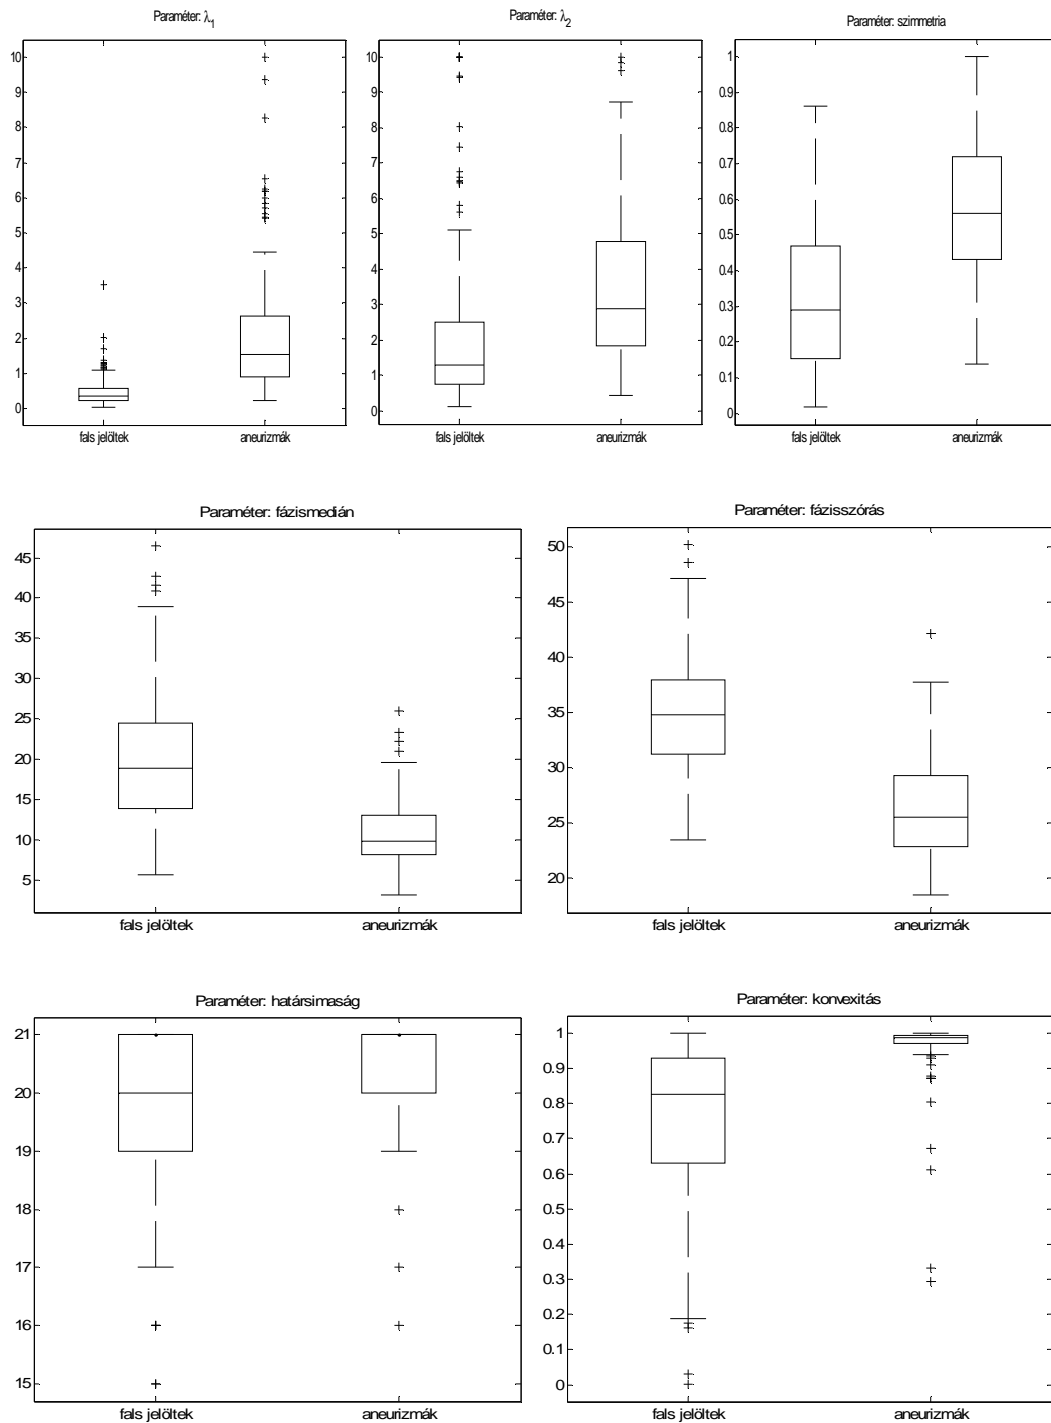
5.2 A GRADIENS ALAPÚ MÉRŐSZÁMOK VIZSGÁLATA

Az előző fejezetben kifejtettem, hogy a gradiens alapú mérőszámok önálló alkalmazása – dolgozatom vizsgálati keretein belül – az intenzitásértékek figyelembe vétele nélkül ugyan viszonylag hatékony, de sok fals pozitív találatot eredményez, és a klasszifikációra használt neurális hálózat kimenete nem alkalmas a valószínűség becslésére.

Ebben a fejezetben céлом megmutatni az általam definiált mérőszámok önálló viselkedését és azok hatékonyságát. Ehhez ún. boxplot ábrázolást fogok használni, mely adott halmaz statisztikus viselkedését jellemzi könnyen áttekinthetően.

A boxplot generálásakor első lépésként a halmaz elemeit sorba rendezzük. A boxplot befoglaló téglalapját ennek a rendezett halmaznak a 25 illetve 75 százalékánál elhelyezkedő értékek határozzák meg, vízszintes vonallal a mediánt is bejelöljük. A téglalap karjai a 0–25 és a 75–100 százalékok közötti halmazelemek eloszlását jellemzik, a halmazból rendkívül kiugró értékeket pedig külön jelöljük.

A vizsgálatok során minden mérőszámra elkészítettem a boxplot ábrázolást, külön-külön kezelve az igazi és a hamis jelölteket. Ezeket mutatja be a 42. ábra.



42. ábra, a paraméterek boxplot segítségével ábrázolva, fals jelöltekre és aneurizmákra csoportosítva

A gradiens alapú mérőszámok jól láthatóan hatékonyan elkülönítik egymástól az igazi és a hamis jelölteket, emiatt alkalmasak a klasszifikációra, vagy annak segítésére.

5.3 AZ EREDMÉNYEK ÖSSZEFOGLALÁSA

Az előző fejezetekben összevettem az algoritmusom által szolgáltatott eredményeket másokéval, és megmutattam, hogy a mérőszámok egyenként is jellegzetesen segítenek elkülöníteni egymástól az igazi és hamis jelölteket. Az értékelés során tett megállapításokat érdemes összefoglalni, és általánosan jellemezni a módszerem eredményességét.

A 4.1 fejezetben megfogalmazott várakozás – miszerint az intenzitásértékek kihagyása a klasszifikációból megnöveli a fals pozitív jelöltek számát – beigazolódott: a módszerem önállóan nem ért el olyan jó eredményeket, mint a ROC versenyben résztvevők.

Ugyanakkor úgy vélem, a kutatásom során sikerült számos olyan részeredményt elérni, melyek alkalmazásával a jelenlegi módszerek hatékonysága tovább javítható:

- **Simított bázisú JPEG rekonstrukció:** ennek alkalmazásával sikerült a JPEG tömörítés okozta blokkosodás hatását elnyomni, és lecsökkenteni a képen megjelenő zajt. Méréseim alapján ez a módszer hatékonyabb, mint a Gauss-simítás.
- **Gradiens alapú objektum szegmentáció:** mivel ez nem alkalmaz intenzitásértékeket, ellenben a gradiensvektorok változását figyeli, így hatékonyabban és eredményesebben szegmentálja az objektumokat, mint az irodalomban leggyakrabban alkalmazott régió-növelő algoritmus.
- **Gradiens alapú mérőszámok:** az alkalmazott gradiens alapú mérőszámok megfelelően segítenek elhatárolni egymástól a hamis és igazi jelölteket. Ezen mérőszámok ráadásul a kép intenzitásviszonyaitól közel függetlenek. Önálló alkalmazásukkal 41.5%-os találati arányt sikerült elérni átlagosan képenkénti 25 fals pozitív találat mellett: ez önmagában kedvező eredmény. Úgy gondolom, hogy ezen mérőszámok a más, intenzitáson alapuló mérőszámokkal együtt való alkalmazása az algoritmusok hatékonyságát növelni lesz képes. Ugyanis mint az [Antal10] munkájából kiderül, a módszerek – s ezzel együtt a mérőszámok – kombinálásával hatékonyabb működés érhető el, mintha az egyes elemeket önállóan alkalmaznánk. Ennek ékes bizonyítéka, hogy Antalék módszere, mely az eddigi algoritmusok kombinálásán alapul, a ROC verseny első helyén áll.

Kutatásomat tehát eredményesnek tekintem, s a jövőben tovább szeretném fejleszteni algoritmusomat.

6. KITEKINTÉS

A jövőre tekintve, kutatás közben felmerült bennem néhány lehetséges fejlesztési irány, melyekkel az elért eredmények javíthatóak, illetve a gradiens alapú módszer a gyakorlatban is jobban szerepet kaphat:

- **Intenzitáson alapuló mérőszámok:** algoritmusomban való alkalmazásukkal számos fals jelölt kiszűrhetővé válik a klasszifikáció során.
- **Klasszifikáló rendszerek további tesztelése:** a tanító halmaz bővítésével, és további neurális hálózat-struktúrák vizsgálatával eredményesebb klasszifikációs eredményeket várok.
- **Jóságot hatékonyan becslő valószínűségi érték kidolgozása:** amint az kiderült, a ROC verseny értékelése szerint azért értem el gyenge eredményt, mivel a klasszifikáló neurális hálózat kimenete nem volt alkalmas a jelöltek jóságának becslésére. Ez az intenzitáson alapuló mérőszámok használatával változhat, de egy jóságot hatékonyan becslő mérőszám kidolgozása is érdekes feladat lehet.

További terveim a jövőre:

- **Részvétel a ROC versenyen:** a fenti pontok megvalósítása után tervezem a ROC versenyen való részvételt.
- **Másokkal való tapasztalatcsere és együttműködés:** hasznosnak tartanám a verseny egyes résztvevőivel felvenni a kapcsolatot tapasztalatcsere céljából, és a hatékonyabb algoritmusok kifejlesztése érdekében.

7. IRODALOMJEGYZÉK

- [Antal10] Antal B., Hajdu A., *Improving microaneurysm detection in color fundus images by using an optimal combination of preprocessing methods and candidate extractors*, 18th European Signal Processing Conference, 2010
- [Basu03] Basu A., *Is digital image compression acceptable within diabetic retinopathy screening?* Diabetic Medicine, Vol. 20, pp.766–771, 2003
- [Bonet06] Bonet J., *Deblocking JPEG images*, <http://www.debonet.com/research/deblocking>, 2006
- [Chaudhuri89] Chaudhuri S., *Detection of Blood Vessels in Retinal Images Using Two Dimensional Matched Filters*, IEEE Trans. on Medical Imaging Vol. 8, No. 3, 1989.
- [Cree06] Cree MJ., Olson JA., McHardy, KC., *Automated microaneurysm detection*, International Conference on Image Processing, Vol. 3, pp.699–702, 1996
- [Cree08] Cree MJ., *The Waikato Microaneurysm Detector*, Technical report, 2008
- [Cree08]JPEG] Cree MJ., Jelinek HF., *The effect of JPEG compression on automated detection of microaneurysms in retinal images*, IS&T/SPIE Electronic Imaging Symposium: Image Processing: Machine Vision Applications, volume 6813 of Proceedings of the SPIE, pp.68130M, 2008
- [Lazar11] Lazar I., Hajdu A., *Microaneurysm detection in retinal images using a rotating cross-section based model*, Technical report, 2011
- [Martins08] Martins CIO., Veras RMS., *Automatic Microaneurysm Detection and Characterization Through Digital Color Fundus Images*, Simpósio Brasileiro de Redes Neurais 2008 - WCI , Salvador-Ba. Proceedings of SBRN 2008, 2008
- [Mizutani09] A. Mizutani, C. Muramatsu, Y. Hatanaka, S. Suemori, T. Hara, and H. Fujita, *Automated microaneurysm detection method based on double ring filter in retinal fundus images* SPIE Medical Imaging 2009: Computer-Aided Diagnosis, Vol. 7260, pp.72601N, 2009
- [Niemeijer10] Niemeijer M., van Ginneken B., Cree MJ., Mizutani A., *Retinopathy online challenge: automatic detection of microaneurysms in digital color fundus photographs.*, IEEE Trans. on Medical Imaging, pp.185-95, 2010
- [Serrano04] Serrano C., Acha B., Revuelto S., *2D adaptive filtering and region growing algorithm for the detection of microaneurysms in retinal angiograms*, Proc. SPIE 5370, 1924, 2004
- [Sopharak11] Sopharak A., Uyyanonvara B., *Automatic Microaneurysm Detection from Non-dilated Diabetic Retinopathy Retinal Images Using Mathematical Morphology Methods*, IAENG International Journal of Computer Science, 2011
- [Spencer96] Spencer T., Olson JA., *An image-processing strategy for the segmentation and quantification of microaneurysms in fluorescein angiograms of the ocular fundus*, Computers and Biomedical Research, 1996
- [Streeter03] Streeter L., Cree MJ., *Microaneurysm Detection in Colour Fundus Images*, Image and Vision Computing NZ, 2003
- [Xu10] Xu L., Luo S., *A novel method for blood vessel detection from retinal images*, BioMedical Engineering OnLine, 2010