

AVTOMATIČNA DETEKCIJA ARTEFAKTOV NA MAMOGRAFSKIH SLIKAH

AUTOMATIC DETECTION OF ARTIFACTS ON MAMMOGRAPHIC IMAGES

Nejc Mekiš¹, Urban Zdešar², Anja Golja³, Aljaž Iskra³, Janez Žibert¹

¹ Univerza v Ljubljani, Zdravstvena fakulteta, Oddelek za radiološko tehnologijo, Zdravstvena pot 5, 1000 Ljubljana

² Zavod za varstvo pri delu, Center za fizikalne meritve, Chengdujska cesta 25, 1260 Ljubljana-Polje

³ Študent/ka študijskega programa Radiološka tehnologija 1. stopnja, Univerza v Ljubljani, Zdravstvena fakulteta, Zdravstvena pot 5, 1000 Ljubljana

Korespondenca/Correspondence: izr. prof. Janez Žibert, E-mail: janez.zibert@zf.uni-lj.si

Prejeto/Received: 16. 11. 2015

Sprejeto/Accepted: 1. 2. 2016

IZVLEČEK

Uvod: Tako kot na drugih diagnostikah se tudi na mamografski izvajajo dnevni testi kontrole kakovosti (KK), ki jih opravljajo radiološki inženirji z namenom, da bi ugotovili in preprečili popačenja in druge nepravilnosti na rentgenogramih.

Namen: Namen raziskave je bil oblikovati/razviti popolno avtomatizacijo procesov obdelave in analize homogenih rentgenskih slik za samodejno, objektivno in sprotno preverjanje tehnične kakovosti mamografskih slikovnih sistemov.

Materiali in metode: V prvem delu smo določili enotne dnevne protokole zajema slik, potrebnih za KK na sedmih različnih mamografskih aparatih, ki so vključeni v presejalni program DORA. Za zajem slik smo uporabili fantome, ki so jih za dnevne teste KK določili proizvajalci. Slike smo pregledali z lastnim programom, ki je namenjen za iskanje in označevanje popačenj na slikah (nehomogenost, mrtvi slikovni elementi, linije, obrisi predhodnih slik – ghost in ostalo). Zbirka homogenih mamografskih slik z zgoraj naštetimi popačenji je bila osnova za izgradnjo sistema za samodejno detekcijo popačenj in drugih nepravilnosti na slikah. Modeliranje je bilo izvedeno na podlagi različnih teksturnih značilk s postopki strojnega učenja z metodo podpornih vektorjev. Ocena uspešnosti detekcije je bila narejena z ROC (Receiver Operating Characteristics – karakteristike delovanja sprejemnika) analizo, kjer smo rezultate uspešnosti merili z izračunom ploščine pod ROC krivuljo.

Rezultati in razprava: Skupno smo zajeli 548 mamografskih slik. Od tega sta bili 102 slike nehomogeni, 66 jih je imelo viden obris prejšnje slike, v 8 primerih smo našli mrtve slikovne elemente (piksle), v 56 pa je bilo vidno linijsko popačenje. S sistemom za samodejno detekcijo smo uspeli zelo dobro zaznati nepravilnosti ghost-a z uspešnostjo 90%, splošnih popačenj z uspešnostjo 95% in nehomogenega kontrasta z uspešnostjo 79%.

Zaključek: Učinkovitost delovanja prototipnega sistema za samodejno detekcijo tehnične kakovosti mamografskih slik omogoča avtomatizacijo celotnega procesa kontrole kakovosti mamografskih sistemov in tako olajša delo radioloških inženirjev.

Ključne besede: mamografija, avtomatizacija, kontrola kakovosti

ABSTRACT

Introduction: In mammography, just like in the other modalities, daily quality control (QC) tests are performed by radiographers to prevent artifacts and other irregularities on radiographic images.

Aim: To design/develop fully automated post-processing and analysis of homogeneous mammographic images for automatic, objective and regular technical quality control of mammography imaging systems.

Materials and methods: In the first part of the study the protocols for image acquisition for daily quality control tests were established. The image acquisition was performed on seven mammographic modalities that are operating in the DORA screening process. Phantoms that were used for image acquisition were selected for daily QC by the manufacturers. The images were then evaluated by a programme we developed which is used for marking the artifacts (non-uniformity, dead pixels, line artifacts, ghost image, etc.). This collection of marked mammographic images was then used to develop a system for automatic detection of artifacts on mammographic images. The modelling was performed on the basis of various texture features with the machine learning process by using the support vector method. The success rate was evaluated by the use of ROC (Receiver Operating Characteristics) analysis, where the results were measured by the calculation of the area under the curve (AUC).

Results and discussion: There were 548 mammographic images in total. We detected 102 images with non-uniformity artifacts, 66 images with ghost images, 8 images with dead pixels and 56 images with line artifacts. By using the automatic detection system, the detection rate of ghost images and of other artifacts was very high, i.e. 90% and 95%, respectively. However, the detection rate of non-uniformity was moderate (79%).

Conclusion: An effective prototype system for automatic detection of technical quality in mammographic images provides automation of the entire quality control process in mammography and therefore facilitates the radiographers' work.

Key words: mammography, automation, quality control

UVOD

Kontrola kakovosti (KK) v mamografski diagnostiki se deli na dnevne, tedenske, mesečne, polletne in letne teste (Perry et al., 2006). Radiološki inženirji izvajajo dnevne, tedenske, mesečne in nekatere polletne teste. Dnevni testi zajemajo pregled diagnostičnih monitorjev, pregled opreme mamografskega aparata in tiskalnika, dnevno sliko fantoma (pregled za popačenja in kontrolo brisanja plošč pri sistemih za računalniško radiografijo) (IAEA, 2011).

Tako kot pri ostalih rentgenskih slikanjih se tudi pri mamografskem rentgenskem slikanju pojavijo popačenja, ki so posledica različnih faktorjev. Najpogostejša popačenja, ki se pojavljajo na rentgenogramih so popačenja, povezana s pacienti, z napravo, s procesiranjem, s shranjevanjem in z detektorjem. Nekaj teh popačenj je bilo vidnih tudi v preteklosti na filmu, večina pa jih je značilnih le za digitalni sistem (Ayyala et al., 2008; Geiser et al., 2011). Popačenja poslabšajo kvaliteto mamogramov, ker lahko ponazarjajo ali prikrivajo patologijo in s tem povzročijo napako v interpretaciji slik. Zato je pomembno, da jih prepoznamo, pravočasno odstranimo in v prihodnje preprečimo (Geiser et al., 2011).

Četudi uporabljamo detektorje z enako strojno opremo, lahko razlika v kalibraciji ali procesiranju slike povzroči različne rezultate ali nevarnost za nastanek popačenj (Walz-Flannigan et al., 2012). Najpomembnejša za našo raziskavo pa so popačenja, povezana z detektorjem. Le-te razdelimo v manjše skupine:

- Ghosting (obris predhodnega objekta) – nastane, kadar se latentna slika iz predhodnega obsevanja detektorja superponira na novo pridobljeno sliko. Vzrok je v spremembi občutljivosti zaradi podaljšanega ali prekomernega obsevanja določenega dela detektorja (Ayyala et al., 2008; Walz-Flannigan et al., 2012).
- Gouging – se pojavi, kadar kompresijski lopar po nesreči pade na nezaščiten, mehak detektor. To je na sliki opazno kot okroglo popačenje (Ayyala et al., 2008).
- Horizontalne linije – te so značilne pri okvarjeni liniji slikovnih elementov ali pri nepravilnem branju podatkov. Lahko se pojavijo kot horizontalne linije ali pa kot robna bela proga (Ayyala et al., 2008).
- Posamezni mrtvi slikovni elementi ali skupine mrtvih slikovnih elementov – na sliki jih lahko zamenjamo za skupek mikrokalcifikacij (Geiser et al., 2011).
- Neuniformnost – do tega pride na tistih mestih, kjer so rentgenski fotoni izločeni pod koti, ki so vzporedni z anodo (Cowen et al., 1993).

Pomembno je, da čim prej odkrijemo popačenja, ki bi lahko pokvarila sliko in jo naredila diagnostično neuporabno. Dnevni testi nam omogočajo odkritje in opazovanje različnih neželenih popačenj.

V evropskih smernicah za izvajanje dnevnega testa je zapisano, da je testni objekt potrebno postaviti na podporo za dojko, ga centrirati lateralno in ga nekoliko potegniti čez rob digitalnega slikovnega sprejemnika, ki simulira prsno steno. Kompresijsko ploščo spustimo do objekta in ga stisnemo s silo, ki jo tudi sicer uporabljamo v klinični praksi (npr. 80 N). Temu sledi zajem slike testnega objekta s standardnimi kliničnimi nastavitvami.

Za ta test se uporabi DICOM verzija predstavitve slike. Slika je potrebno pregledati na delovni postaji. Uporabiti je potrebno določeno širino in raven okna, ki ju določi medicinski fizik. Pri ocenjevanju slike morajo biti pogoji vedno enaki, torej enaka širina in raven okna ($\pm 10\%$). Ustrezna širina okna pripomore k najdbi popačenj. Pri širini okna moramo biti pozorni na to, da je primerna ali tipična za slike z dojkami oz. za fantome z značilnostmi dojke. Z uporabo enake širine in ravni okna, kot je opisano zgoraj, je potrebno pregledati splošni izgled slike in prisotnost popačenj. Na celotni sliki je potrebno preveriti prisotnost grobih (neuniformnost, lise in proge) in podrobnih popačenj (črni ali beli slikovni elementi, skupek slikovnih elementov, linije in madeži). Groba popačenja najdemo, če gledamo sliko kot celoto, ne po posameznih delih. Podrobna popačenja pa najdemo pri najboljši prostorski ločljivosti ali celo pri povečavi. Najdena popačenja je potrebno spremljati in zapisovati v poseben, za to namenjen, dokument (IAEA, 2011).

Za preventivni program DORA (v katerem smo izvajali raziskavo) v Sloveniji je značilno, da radiološki inženir preprečuje nastanek popačenj s primernim izvajanjem KK testov, t.j. v skladu s protokoli. Podatke meritev vpiše v aplikacijo MaTKA, s pomočjo katere merimo kakovost mamografskih aparatov. Z njeno pomočjo ugotovimo, če posamezni parametri odstopajo od normalnih vrednosti. V tem primeru moramo prenehati s slikanjem in o tem obvestiti ZVD (Krajc in sod., 2011).

NAMEN

Namen raziskave je bil razviti sistem za avtomatizacijo procesa kontrole kakovosti, kjer bomo s pomočjo postopkov obdelave slik in strojnega učenja zgradili sistem za avtomatsko detekcijo popačenj v mamografiji. Tako bi lahko nadgradili aplikacijo MaTKA, ki se že uporablja v okviru programa zagotavljanja tehnične kakovosti presejalnega programa DORA.


V ta namen je potrebno:

- določiti protokole za zajem mamografskih slik in nato pridobiti bazo neobdelanih mamografskih slik z ustrezno označenimi popačenji (če so le-ta prisotna);
- razviti postopke obdelave slik za določanje popačenj in drugih nepravilnosti na slikah;
- s pomočjo postopkov strojnega učenja izgraditi sistem za avtomatično detekcijo popačenj v mamografiji.

METODE IN MATERIALI

Postopek sistema za avtomatično detekcijo popačenj v mamografiji, ki smo ga razvili v okviru raziskave, je prikazan na sliki 1.

Sistem za avtomatično detekcijo popačenj avtomatično odloči, ali je na mamografski sliki prisotno popačenje ali ne. V postopku detekcije obdelujemo homogeno mamografsko sliko, iz katere s postopki obdelave slik najprej določimo ustrezne parametre – značilke, ki merijo prisotnost določenega popačenja na sliki, nato pa s postopki strojnega učenja odločimo ali je popačenje na sliki prisotno ali ne. Vhodna slika v takem sistemu mora biti neobdelana homogena slika, ki je pridobljena po vnaprej določenem protokolu zajemanja mamografskih slik. Pri izračunu značilk uporabljamo postopke obdelave medicinskih slik, s



Slika 1: Sistem za avtomatično detekcijo popačenj v mamografiji

katerimi določimo tiste mere kakovosti slik, ki merijo prisotnost določenega popačenja na sliki. Pri izgradnji statističnega modela za detekcijo popačenj na slikah pa moramo s postopki strojnega učenja zgraditi model, ki bo z določeno mero zanesljivosti odločal o prisotnosti popačenj na sliki. Pri tem moramo pridobiti ustrezno zbirko označenih slik, na podlagi katere naučimo model pravilnega odločanja. V nadaljevanju bodo predstavljeni vsi ključni deli izvedbe takega sistema.


Zbirka mamografskih slik

Zbirka mamografskih slik je potrebna za izgradnjo in evalvacijo statističnega modela in je zato ključno, da v njej zberemo takšne slike in na takšen način, kot jih bomo uporabljali pri uporabi sistema. Zato smo se pri pridobivanju zbirke ukvarjali s protokolom pridobivanja nehomogenih mamografskih slik in označevanjem popačenj na takih slikah.

Protokol zajemanja slik je bil določen za sedem različnih DR mamografskih enot, proizvajalcev Siemens in Hologic, ki so v uporabi v DORI. Pet od teh enot je bilo stacionarnih in dve sta bili mobilni. Protokol zajemanja slik je bil določen vnaprej, zajemanje slik pa je potekalo na Onkološkem inštitutu Ljubljana in v Zdravstvenem domu Ljubljana in sicer vsak dan približno 2 meseca, z izjemo vikendov in praznikov. Slike so bile zajete z uporabo enakih ekspozicijskih pogojev, kot se uporabljajo pri vsakodnevni testih KK v mamografiji, z avtomatskim nadzorom ekspozicije (z izbrano anodno napetostjo 28 kV). Uporabljali smo standardni fantom za dnevne teste KK, ki je bil za posamezen aparat priskrbljen s strani proizvajalca. Sestavljen je iz pleksi stekla, njegova debelina meri 4 cm. Slike so bile potem prenesene iz mamografskih enot na skupni strežnik, kjer so se zbirali vsi podatki. Slike smo shranjevali po posebnem vrstnem redu (ime zdravstvenega zavoda_ime mamografske enote_datum zajete slike_slika_vrstni red slike.dcm), zato da je bila baza pregledna in urejena.

Ustvarjeno bazo zajetih slik smo potem pregledali z orodjem, ki smo ga razvili oz. s programom za določitev prisotnosti ali odsotnosti popačenj na sliki, ki je prikazan na sliki 2.

S programskim orodjem za označevanje slik je bilo možno označiti naslednje vrste popačenj: nehomogenost, mrtve slikovne elemente, linije, ghost-e in ostala popačenja (tista, ki ne sodijo v nobeno od omenjenih kategorij). Program je omogočal označevanje tudi več popačenj hkrati in prilagoditve kontrasta s tehniko normalizacije histograma, kar je omogočalo boljše zaznavanje popačenj. Označbe slik so se shranjevale v posebno datoteko, ki smo jo potem uporabili za postopke učenja statističnih modelov v nadaljevanju.




Slika 2: Program za določitev prisotnosti popačenj na sliki

Ključno pri taki zbirki so pravilno označene slike. Zato smo posebno pozornost posvetili postopku označevanja popačenj. Označevanje slik je potekalo v dveh fazah. V prvi fazi smo zbirko slik razdelili na dve skupini slik. Vsako skupino sta ločeno označevala dva označevalca, radiološka inženirja z ustreznim ekspertnim znanjem. Merili smo strinjanje med označevalci. Problem neujemanja označevalcev smo rešili z uvedbo tretjega označevalca, ki je dodatno ocenil slike, o katerih se predhodno označevalca nista strinjala. Po tretji oceni smo končno oznako napake izbrali po večinski odločitvi, npr. če je prvi ocenjevalec sliko označil z linijami, drugi z ghost-om in tretji z linijami, je bil končni rezultat slika z linijami. V zelo redkih primerih so vsi trije označevalci označili sliko različno, v tem primeru je bil končni rezultat slika brez prisotnega popačenja, saj brez večinskega strinjanja označevalcev ni bilo možno določiti drugačnega končnega rezultata. S takim sistemom smo pridobili bazo enotno označenih mamografskih slik.

Določitev značilk za detekcijo popačenj iz mamografskih slik

Naslednji korak pri izgradnji sistema za avtomatično detekcijo je bil pridobitev ustreznih mer kakovosti slik, na podlagi katerih se sistem lahko samodejno odloči ali so popačenja na sliki prisotna ali ne. V ta namen smo razvili postopek obdelave mamografskih slik za pridobivanje značilk, prikazan na sliki 3.



Slika 3: Postopek obdelave mamografske slike za pridobivanje značilk


V postopku pridobivanja značilk najprej izrežemo rob homogene mamografske slike, ki predstavlja 5% širine in višine slike. Na ta način za nadaljnjo obdelavo izberemo samo središčno območje slike. Nato izvedemo prilagoditev kontrasta s postopkom normalizacije histograma, da prestavimo območje sivin slike na področje, kjer bomo izvajali obdelavo. Naslednji korak predstavlja izračun razmerja signal-šum (SNR, Signal Noise Ratio) na podslikah osnovne slike. Podslike dimenzije 256×256 slikovnih elementov tvorimo tako, da začnemo v zgornjem levem kotu na osnovni sliki in premikamo izračun podslike za 128 slikovnih elementov v desno oziroma navzdol. Tako s podslikami pokrijemo celotno območje na osnovni sliki. Na vsaki podsliki izračunamo SNR. Vrednosti teh izračunov zapišemo v matriko glede na položaj slike v osnovni sliki. Tako dobimo manjšo sliko, sestavljeno iz vrednosti SNR. Če bi bila slika homogena, bi morale biti vrednosti SNR na vseh podslikah enake, če pa so na njej nepravilnosti, pa ni tako. To je bila tudi naša osnovna ideja, ko smo se odločili za tvorjenje podslik. V zadnjem koraku sliko, sestavljeno iz vrednosti SNR še dodatno normaliziramo. To izvedemo tako, da izračunamo povprečno sliko, sestavljeno iz vrednosti SNR iz vseh slik v naši zbirki, ki so narejene na enem mamografskem sistemu, in to povprečno sliko odštejemo od slike, ki jo obdelujemo. Ta korak smo naredili zato, da smo zmanjšali vpliv nehomogenega kontrasta, ki je značilen za mamografske sisteme zaradi postavitve vira rentgenskega sevanja in senzorja. Na ta način z odštevanjem povprečne slike kontrastno homogeniziramo sliko.

Vsi postopki na sliki 3 se izvajajo avtomatsko, kar je bila osnovna zahteva pri izgradnji sistema za detekcijo popačenj.

Na tako pridobljeni sliki SNR smo nato izračunali značilke za detekcijo popačenj. Odločili smo se za teksturne značilke, ki se pridobijo po metodi GLCM (The MathWorks, 2015). Te značilke so namenjene razlikovanju med področji z različnimi teksturami. Ker smo pričakovali, da se popačenja na slikah SNR obnašajo kot različne texture, smo v ta namen izpeljali iz matrike GLCM značilke, ki merijo energijo, kontrast in homogenost v vertikalni in horizontalni smeri (The MathWorks, 2015). Tako smo pridobili 6 značilk.

Dodatno značilko smo izpeljali za merjenje popačenj z nehomogenim kontrastom in ghost-a. V tem primeru smo pričakovali eno področje, ki se po vrednostih razlikuje od drugega na isti sliki. Zato smo to značilko izpeljali na

podlagi segmentacije slike, ki smo jo izvedli po postopku segmentacije aktivnih obrisov (Chan in Vese, 2001), kjer smo avtomatično detektirali dve interesni področji na sliki. Na vsakem interesnem področju smo nato izračunali povprečno vrednost SNR in obe primerjali med seboj. Večja kot je bila razlika v povprečjih, večja je bila verjetnost, da se področji razlikujeta, kar je posledica bodisi nehomogenega kontrasta ali pa ghost-a. Postopek pridobivanja 7. značilke je prikazan na sliki 4.




Slika 4: Postopek izračuna značilke za merjenje homogenosti kontrasta na sliki

Vsi postopki izračunov značilk so bili izvedeni s programskim paketom MATLAB (Mathworks Inc.).

Sistem za detekcijo popačenj na mamografskih slikah

Iz vsake mamografske slike smo tako pridobili 7 značilk, ki merijo prisotnost popačenj na sliki. Z njihovo pomočjo je bilo potrebno za vsako sliko določiti ali je na sliki prisotno popačenje ali ni. Odločili smo se modelirati naslednja popačenja: nehomogeni kontrast, ghost, linije in skupke mrtvih slikovnih elementov ter popačenj zaradi težav pri slikanju (ostala popačenja). Sistem za detekcijo popačenj smo zgradili po principu verifikacije. Tako smo zgradili modele za posamično odločanje o popačenjih na sliki, kar je pomenilo, da smo za vsak tip popačenja zgradili en model, pri detekciji pa smo se odločali ali je ta tip popačenja prisoten na sliki ali ne. Tako smo problem detekcije popačenj spremenili v več binarnih klasifikacijskih problemov, kjer je pozitiven razred predstavljal popačenje, negativen razred pa vse ostalo. Diagram sistema za detekcijo popačenj je prikazan na sliki 5.



Slika 5: Diagram sistema za detekcijo popačenj po principu verifikacije


Modeli za binarno klasifikacijo so bili izvedeni za vsako popačenje posebej, po metodi podpornih vektorjev (SVM)

z uporabo jeder RBF (Radial Basis Function) z optimizacijo odprtih parametrov (Christianini in Shawe-Taylor, 2000). Tako smo zgradili 5 SVM modelov za vsako popačenje posebej.

Modeli SVM so bili določeni iz primerov slik popačenj iz naše zbirke slik in sicer po principu navzkrižne validacije z izločanjem enega vzorca iz zbirke (leave one out cross validation, Moskowit in Pepe, 2004). Tako smo za vsako popačenje naučili toliko modelov SVM, kolikor je slik v zbirki, pri čemer smo v vsakem primeru izločili eno sliko iz učenja in nato na tej sliki testirali naš model. Na ta način smo za vsako sliko pridobili verjetnost, ali je določeno popačenje na sliki. V primeru visoke verjetnosti lahko sklepamo na prisotnost popačenja na sliki, v primeru nizke verjetnosti pa ne. Vrednotenje zanesljivosti detekcije naših modelov smo lahko izvedli z ROC krivuljami, kjer smo za končno mero zanesljivosti delovanja detekcije računali površino pod ROC krivuljo ali AUC (ang. area under curve, Moskowit in Pepe, 2004). To je običajna metoda za objektivno testiranje zanesljivosti binarnih klasifikacijskih problemov.

REZULTATI IN RAZPRAVA

Našo bazo je sestavljalo 548 surovih mamografskih slik. Označevalci so med temi slikami našli 102 primera nehomogenosti, 66 primerov ghost-ov, 56 primerov linij, 8 primerov mrtvih slikovnih elementov in 18 primerov ostalih popačenj. Ostala popačenja so se pojavila zaradi nenatančnosti pri upoštevanju protokola slikanja s strani radioloških inženirjev. To pa ni negativno vplivalo na našo zbirko slik, saj smo te slike uporabili kot dodatno kategorijo popačenj. Prikaz tipičnih primerov popačenj iz naše zbirke je na sliki 6.




Slika 6: Tipični primeri popačenj iz naše zbirke: 1 – slika brez popačenj, 2 – ghosting, 3 – linija, 4 – nehomogenost, 5 – skupek mrtvih slikovnih elementov, 6 – popačenje zaradi napačnega slikanja.

Strinjanje med označevalci smo merili z ujemanjem oznak med slikami. Ujemanje med ocenjevalcema, ki sta ocenjevala prvo skupino slik je bilo 87%, ujemanje med ocenjevalcema, ki sta ocenjevala drugo skupino slik pa 72%. Največ nestrinjanj med označevalci se je pojavilo pri detekciji nehomogenosti in ghost-ov, medtem ko v kategorijah linij, mrtvih slikovnih

elementov in ostalih popačenj skoraj ni bilo nestrinjanj. To lahko pojasnimo z dejstvom, da se ocenjevalci bolj strinjajo pri ocenjevanju geometričnih popačenj (npr. linije) kot pa pri ocenjevanju negeometričnih popačenj (nehomogenost kontrasta). Slike smo nato enovito označili po ponovnem pregledu tretjega označevalca po metodi večinskega glasovanja.

Na podlagi zbirke slik smo lahko zgradili 4 sisteme za detekcijo posameznih popačenj iz mamografskih slik: sistem za detekcijo nehomogenega kontrasta, sistem za detekcijo ghost-a, sistem za detekcijo linij in sistem za detekcijo ostalih popačenj. Sistema za detekcijo skupkov mrtvih slikovnih elementov ni bilo mogoče zgraditi zaradi malega števila slik s tem popačenjem v zbirki.

Rezultati testiranja modelov so prikazani z ROC krivuljami in ocenami AUC na sliki 7.



Slika 7: Rezultati ROC analize za vsako popačenje

Iz rezultatov ROC analize lahko vidimo, da smo dosegli zelo dobro detekcijo popačenj ghost-a (AUC = 90%) in ostalih popačenj (AUC = 97%), malo manj uspešni pa smo bili pri detekciji nehomogenega kontrasta (AUC = 79%) in linij (AUC = 75%). Tako lahko sklepamo, da naši sistemi dobro detektirajo popačenja, kjer imamo nepravilnosti v homogenosti na sliki (ghost, nehomogenost kontrasta, ostala popačenja), malo manj zanesljiv pa je sistem pri detekciji lokalno pogojenih popačenj, ki so predstavljeni z linijami na sliki ali pa s skupinami mrtvih slikovnih elementov.

Kljub temu pa lahko zaključimo, da smo z razvitimi postopki avtomatične obdelave in modeliranja slik zgradili dokaj zanesljive sisteme za detekcijo izbranih popačenj na mamografskih slikah.

ZAKLJUČEK

Cilj te raziskave je bil razviti sistem za avtomatično detekcijo tipičnih popačenj na mamografskih slikah, kar bi omogočilo večjo avtomatizacijo procesov dnevne kontrole kakovosti tehnične ustreznosti mamografskih slik. Avtomatizacija celotnega procesa detekcije popačenj na mamografskih slikah je vključevala definiranje ustreznih protokolov za pridobivanje homogenih slik, razvoj postopkov za določanje objektivnih mer kakovosti iz teh slik ter izgradnjo sistema za samodejno detekcijo popačenj na teh slikah. Pri razvoju aplikacije smo predvideli avtomatično detekcijo kontrastne nehomogenosti, pojav ghost-a, prisotnost linijskih in drugih popačenj ter prisotnost skupkov mrtvih slikovnih elementov. Tako smo razvili prototipne aplikacije za detekcije posameznih elementov nepravilnosti na slikah. Pri tem smo z metodami strojnega učenja uspeli zelo dobro detektirati nepravilnosti ghost-a z uspešnostjo 90%, splošnih popačenj z uspešnostjo 95% in nehomogenega kontrasta z uspešnostjo 79%, merjeno z AUC.

Z vključitvijo takega sistema za avtomatično detekcijo popačenj v delovni proces dnevne kontrole kvalitete tehnične ustreznosti mamografskih slik bi lahko izvajali bolj objektivno testiranje mamografskih sistemov in zmanjšali količino dela za radiološke inženirje, ki dnevno testirajo mamografske sisteme.

LITERATURA

Ayyala RS, Chorlton MA, Behrman RH, Kornguth PF, Slanetz PF (2008). Digital Mammographic Artefacts on Full-Field Systems: What Are They and How Do I Fix Them? *Radiographics* 28 (7): 1999–2008.

Chan TF, Vese LA (2001). Active contours without edges. *IEEE Trans. Image Process.* 10(2): 266–77.

Christianini N, Shawe-Taylor J (2000). *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. Cambridge: Cambridge University Press.

Cowen AR, Brett DS, Workman A (1993). Technical note: Compensation for field non-uniformity on a mammographic X-ray unit. *Brit J Radiol* 66 (782): 150–4.

Geiser WR, Haygood TM, Santiago L, Stephens T, Thames D, Whitman GJ (2011). Challenges in Mammography: part I, Artifacts in Digital Mammography. *AJR* 197 (6): 1023–30.

International Atomic Energy Agency (2011). Quality assurance programme for digital mammography. Vienna: IAEA 1482 (17): 43–4.

Krajc M, Šval C, Purić F in sod. (2011). Postopki in protokoli SOP presejalnega procesa. Ljubljana: Register in program DORA. http://www.onko-i.si/fileadmin/_migrated/content_uploads/Klinicna_pot_poteka_dela_v_presejalno-diagnosticnem_centru_programa_DORA-november_2011_01.pdf. <19. 2. 2016>

Moskowitz CS, Pepe M (2004). Quantifying and comparing the predictive accuracy of continuous prognostic factors for binary outcomes. *Biostatistics* 5 (1): 113–27.

Perry N, Broeders M, de Wolf C, Törnberg S, Holland R, von Karsa L eds. (2006). *European guidelines for quality assurance in breast cancer screening and diagnosis*. Luxembourg: Office for Official Publications of the European Communities, 10–48.

The MathWorks Inc. (2015). *Matlab GLCM, Gray-Level Co-Occurrence Matrix (GLCM)*. <http://www.mathworks.com/help/toolbox/images/ref/graycomatrix.html>. <18. 5. 2015>

Walz-Flannigan A, Magnuson D, Erickson D, Schueler B (2012). Artifacts in Digital Radiography. *AJR* 198 (1): 156–61.

ZAHVALA

Sistem za detekcijo artefaktov iz mamografskih slik je bil izveden v okviru projekta Po kreativni poti do praktičnega znanja, ki ga delno financira Evropska unija, in sicer iz Evropskega socialnega sklada. Projekt se je izvajal v okviru Operativnega programa razvoja človeških virov za obdobje 2007–2013, 1. razvojne prioritete »Spodbujanje podjetništva in prilagodljivosti« ter prednostne usmeritve 1.3: »Štipendijske sheme«, v okviru potrjene operacije »Po kreativni poti do praktičnega znanja«. Prav posebno bi se zahvalili študentom radiološke tehnologije Urški Štrekelj, Sabini Androjna, Ivani Kocevi, Anji Golja in Aljažu Iskra, ki so pod vodstvom delovnega mentorja mag. Janija Izlakarja iz Onkološkega inštituta iz Ljubljane sodelovali pri pridobivanju in označevanju mamografskih slik, študentom medicinske fizike Gregorju Bensi in Janu Šomnu za pomoč pri obdelavi slik za izračun značilk ter študentu računalništva in informatike Klemnu Lokarju za razvoj in testiranje modelov za detekcijo artefaktov.