



Școala doctorală de Științe Inginerești și
Matematică
Domeniul de doctorat: Calculatoare și Tehnologia
Informației

TEZĂ DE DOCTORAT

**Progrese în segmentarea automată a mai
multor organe**

Doctorand:
Ing. Valentin OGREAN

Conducător Doctorat:
Prof. Dr. Ing. Remus BRAD

Această lucrare de doctorat conține materiale de cercetare originale în domeniul segmentării automate a mai multor organe prezente în imagini medicale.

Interpretarea tomografiilor computerizate și a imagisticii prin rezonanță magnetică de către medici este o activitate complexă și consumatoare de timp. În plus, formele și dimensiunile organelor sunt diverse și există variații foarte mari între persoane, lucruri care fac ca instruirea experților să fie un proces de lungă durată și care are costuri ridicate. Prin urmare, capacitatea de a extrage automat informații din imagini medicale are un potențial major de a ajuta în radiologie și ar putea să atenueze problemele cu care se confruntă medicii în munca lor de zi cu zi.

Pentru a aduce îmbunătățiri în acest domeniu de cercetare, am proiectat și implementat arhitecturi care atenuează probleme cunoscute ale metodelor moderne și arhitecturi care prezintă algoritmi complet noi pentru execuția segmentării automate a organelor. În plus am setat misiunea ca soluțiile propuse să fie utilizate în configurații cu mai multe organe pentru a extinde atractivitatea și potențialul lor de utilizare în sisteme de producție.

Activitatea a început prin realizarea unui studiu cuprinzător care descrie soluțiile și algoritmi existenți. Modelele de Machine Learning (ML) – învățare automată – sunt cele mai folosite în segmentare automată pentru că ele produc cele mai bune rezultate la ora actuală. De aceea **primul capitol** se concentrează pe algoritmi de Deep Learning (DL) care au fost importanți în dezvoltarea domeniului de segmentare a mai multor organe. Acesta conține o listă vastă a soluțiilor bazate pe algoritmi Deep-learning supravegheați ca Rețele Neuronale Convoluționale (Convolutional Neural Networks – CNNs) și Fully Convolutional Neural Networks (FCNs). Descrie și arhitecturi hibride care folosesc Rețele Neuronale Recurente (Recurrent Neural Network – RNNs) ori Generative Adversarial Networks (GANs) sau abordări care nu pot fi categorisite în nici una dintre categoriile anterioare. Sunt detaliate și abordări bazate pe Deep Reinforcement Learning (DRL), din cauza interesului crescut pe care l-au primit în ultimii ani.

Capitolul 2 descrie o arhitectură originală folosită pentru segmentarea mai multor organe toracice. Obiectivul acesteia este de a demonstra că algoritmi cu un design bun pot obține rezultate relevante chiar și în situația în care sunt utilizați pe un hardware cu resurse limitate (disponibil pentru majoritatea cercetătorilor). Arhitectura DL este bazată pe un algoritm standard U-Net, dar folosește tehnici moderne de preprocesare, un mecanism inteligent de „batching” (loturi) și fuzionarea rezultatelor obținute de la diferite rețele specializate pe anumite organe. Sunt implementate 4 rețele neuronale axate pe un singur organ și o rețea care vizează mai multe organe iar rezultatele lor sunt combinate pentru a obține segmentarea finală. Memoria grafică maximă folosită este de 8 GB, și astfel această arhitectură poate fi replicată de majoritatea cercetătorilor și satisface constrângerile legate de folosirea unor resurse limitate. Arhitectura a fost testată pe dataset-ul furnizat de challenge-ul SegTHOR care are și un sistem automat de clasare a soluțiilor folosind date de test ne-segmentate. Metoda mea a obținut locul 8 în acest challenge internațional, demonstrând astfel că produce rezultate echivalente cu cele ale altor metode moderne.

În **Capitolul 3** o arhitectură complet nouă și originală este prezentată. Status-quo-ul în segmentarea automată este că algoritmi DL supervizați produc cele mai bune rezultate. Am contestat acest lucru prin dezvoltarea unei arhitecturi care folosește Deep Reinforcement Learning și care obține rezultate asemănătoare pentru aceleași tipuri de sarcini. Procesul de segmentare a fost transformat cu succes într-o problemă de tip Markov Decision Process (MDP), prin utilizarea unei porțiuni de CT ca mediu și antrenând un agent care învață să se

miște prin imaginea mediu și să segmenteze un organ uman (în cazul meu, inima). Folosind algoritmul Deep Q-Network (DQN) ca sursă de inspirație, am implementat un agent care navighează prin imaginea dintr-un CT și utilizând acțiuni discrete (mişcare dreapta, stânga, sus, jos și segmentare) să genereze segmentarea organului. Agentul este recompensat în funcție de acțiunile alese, și în acest mod va învăța tactica optimă prin care își va putea îndeplini sarcinile.

Datorită faptului ca segmentarea este un proces prea complex pentru a putea fi rezolvat de către un singur agent, arhitectura completă este sub forma unui „pipeline” care începe cu o etapă de preprocesare, continuă cu detecția prezentei organului în imaginea din CT, utilizează un agent DQN care detectează poziția inițială din care va începe procesul de segmentare și apoi folosind un alt agent DQN se va genera segmentarea organului. Recompensele sunt corelate cu acuratețea acțiunilor alese iar agentul este stimulat să genereze contururi închise (cum sunt majoritatea organelor umane). Rezultatele demonstrează ca soluțiile bazate pe DRL pot fi folosite și în sarcinile de segmentare automată și că acestea pot fi generalizate ca să obțină rezultate bune chiar și când sunt antrenate pe un set limitat de date (de exemplu 10 CT-uri umane).

Capitolul 4 extinde implementarea DRL prin utilizarea unui algoritm mai modern, Proximal Policy Optimization (PPO). Arhitectura este în continuare sub forma unui pipeline care conține etape de preprocesare, de detecție a prezentei organului în CT, care continuă cu un agent DQN care detectează poziția inițială pentru segmentare, dar pentru segmentarea propriu zisă s-a folosit un agent PPO care utilizează acțiuni continue pentru a desena conturul. Valorile produse de agent reprezintă direct marginea organului și în acest fel nu este nevoie să efectueze foarte multe acțiuni pentru a naviga prin imagine. În plus, există implementări diferite care folosesc doi agenți PPO (unul pentru a segmenta conturul stânga, unul pentru a segmenta conturul dreapta) dar și o variantă în care un singur agent PPO va produce valori ce reprezintă marginile complete ale organului. Rezultatele sunt comparabile cu cele obținute folosind agenți DQN dar procesul de învățare PPO este mult mai rapid (câteva ore) și astfel poate fi extins rapid și folosit și pentru alte organe.

Capitolul 5 prezintă implementarea arhitecturii PPO și pentru alte organe, demonstrând că poate fi folosită într-un context multi-organ. Am folosit un alt dataset și am selectat două organe diferite pentru a testa mai bine metodele din capitolele anterioare. Primul organ selectat a fost pancreasul care este un organ foarte mic. În mod opus, al doilea organ selectat a fost ficatul, care este mult mai mare și are o morfologie diversă în diferite părți ale CT-ului. Rezultatele au demonstrat că agenții DRL pot fi folosiți cu succes la o categorie diversă de organe umane.

Capitolul 6 conține îmbunătățiri adiționale aduse arhitecturilor DRL. Dezavantajul major al arhitecturilor inițiale este că „pipeline”-urile necesită includerea mai multor agenți pentru generarea rezultatelor. Pentru a atenua acest dezavantaj, cercetarea s-a concentrat pe dezvoltarea unor agenți care pot segmenta singuri organele, beneficiind de cât mai puțin ajutor din exterior. Astfel, am implementat agenți noi cu un design îmbunătățit, și am propus simplificări care au făcut ca agenții să învețe mai ușor și să fie mai ușor de utilizat. În plus, am creat și o arhitectura care reduce numărul de agenți dintr-un „pipeline” care astfel a fost simplificată și mai mult.

Capitolul 7 schițează concluziile finale și face un sumar al cercetării efectuate. În plus prezintă contribuțiile personale aduse în domeniul cercetat și descrie cum au fost diseminate rezultatele.