

**Diagnoza automată și asistată de calculator a tumorilor abdominale, prin metode avansate de analiză și recunoaștere, pe baza imaginilor medicale (ACADTUM)**

**RAPORT ȘTIINȚIFIC FINAL**

**Perioada raportării: 15.05.2022 – 10.05.2024**

**I. Obiective prevăzute/realizate**

În contextul proiectului ACADTUM, s-au dezvoltat și experimentat metode avansate pentru diagnoza automată și asistată de calculator a tumorilor abdominale pe baza imaginilor medicale de diferite tipuri: ultrasonografice (US), computer tomografice (CT), respectiv imagini de rezonanță magnetică (IRM), urmărindu-se atât recunoașterea, cât și segmentarea formațiunilor tumorale. În acest scop, au fost implicate atât tehnici de învățare profundă, cât și tehnici convenționale, realizându-se compararea și combinarea acestora, cele mai performante metode fiind integrate în aplicația software ACADTUM, destinată diagnozei automate, respectiv asistate de calculator, a tumorilor abdominale. Astfel, conform propunerii de proiect, obiectivul principal al proiectului ACADTUM a fost acela de „dezvoltare a unui sistem software pentru diagnoza automată și asistată de calculator a tumorilor abdominale, bazat pe imagini medicale de diferite tipuri, implicând atât tehnici convenționale, cât și de învățare profundă”, obiectivele secundare fiind următoarele:

O1. Dezvoltarea unor metode avansate de analiză a imaginilor și clasificare, în scopul de a obține o performanță maximă în ceea ce privește recunoașterea tumorilor abdominale din imagini medicale de diferite tipuri

O2. Compararea performanțelor metodelor convenționale, respectiv a celor de învățare profundă, în situații multiple, în cazul unor tipuri variate de imagini medicale

O3. Detecția stărilor preneoplazice, respectiv a tumorilor aflate în stadiu de dezvoltare incipient, prin metode computerizate.

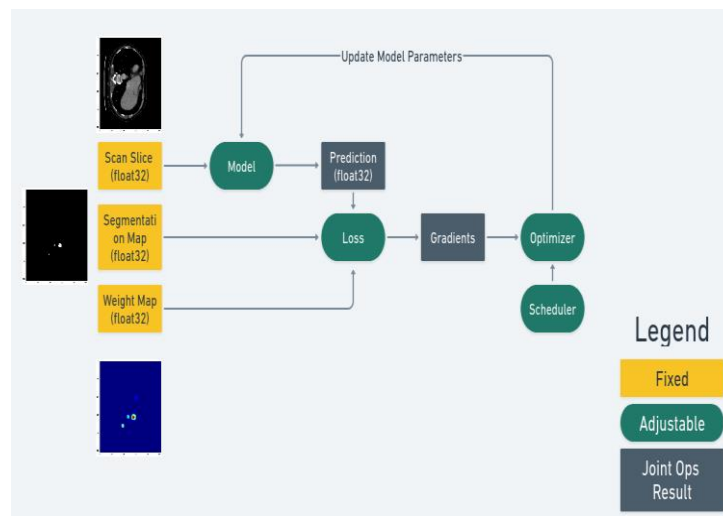
O4. Sustinerea activităților de cercetare pentru tinerii cercetători.

**1. Demersuri realizate în vederea obiectivului O1, “Dezvoltarea unor metode avansate de analiză a imaginilor și clasificare, în scopul de a obține o performanță maximă în ceea ce privește recunoașterea tumorilor abdominale din imagini medicale de diferite tipuri”**

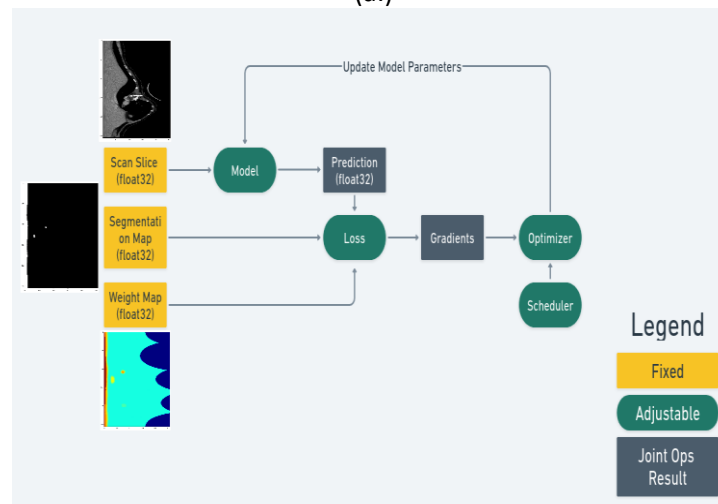
În vederea realizării obiectivului O1, au fost luate în considerare, în primul rând, metode de învățare profundă bazate pe tehnica rețelelor neuronale convoluționale (Convolutional Neural Networks – CNN) [1], analizate în vederea segmentării și recunoașterii tumorilor maligne specifice cancerului hepatic, pancreatic și renal, pe baza imaginilor medicale de diferite tipuri. Astfel, s-a urmărit atât segmentarea formațiunilor tumorale, implicând detecția, localizarea și delimitarea lor, cât și recunoașterea propriu-zisă a acestora, implicând selectarea unei regiuni de interes rectangulare în interiorul unei formațiuni suspecte, respectiv determinarea clasei de apartenență a acesteia (tumoră/non-tumoră). Aceste metode sunt detaliate în cele ce urmează.

### 1.1. Metode pentru segmentarea automată a formațiunilor tumorale

În scopul *segmentarii tumorilor hepatice din imagini CT*, în contextul celei de-a doua etape a proiectului, s-au experimentat și comparat metode de ultimă generație, bazate pe rețele neuronale convoluționale (Convolutional Neural Networks – CNN), precum UNet, UNet++ și DeepLabV3+. UNet reprezintă o rețea implementată frecvent în scopul segmentării imaginilor medicale, propusă inițial în 2015 [2]. UNet++ [3] reprezintă o variantă îmbunătățită a UNet, presupunând modificarea conexiunilor transversale (skip connections), prin înlocuirea operațiilor de cuplare și concatenare cu o serie de operații care au ca scop echilibrarea la nivel semantic a reprezentării datelor de intrare în stadiile intermediare corespunzătoare codificatorului și decodificatorului. DeepLab, precum și variantele sale îmbunătățite V2, V3, V3+ [4],[5] reprezintă o altă arhitectură CNN implementată cu succes pentru segmentarea imaginilor medicale.



(a.)



(b.)

**Figura 1.** Descrierea strategiei de antrenare: (a.) prin luarea în considerare a imaginilor de intrare/ieșire în reprezentare carteziană; (b.) prin luarea în considerare a imaginilor de intrare/ieșire în reprezentare polară

Această rețea implementează convoluții dilatate pentru a lărgi câmpul vizual, fără a reduce dimensiunile imaginii. Concomitent, arhitecturile DeepLab introduc convoluțiile și procesările multiscalare, integrând module de tipul Atrous Spatial Pyramid Pooling (ASPP), care permit aplicarea paralelă a convoluțiilor dilatate la diferite niveluri și rezoluții. Aceste rețele au fost experimentate în conjuncție cu arhitectura ResNet, aceasta constituind baza (backbone-ul) pentru codificator (encoder). În timpul antrenării acestor rețele s-a adoptat o funcție de cost (loss) hibridă, constituind o combinație între funcția de cost bazată pe entropia încrucișată [6], respectiv cea bazată pe costul DICE [6], așa cum rezultă din formula (1).


$$L_i(A_i, B_i) = \frac{LCE_i(A_i, B_i)W_i(A_i, B_i)}{L_{Dice}(A_i, B_i)} \quad (1)$$

În formula (1),  $L_i(A_i, B_i)$  reprezintă funcția de cost asociată șablonului  $i$ , iar  $LCE_i(A_i, B_i)$  reprezintă costul bazat pe entropia încrucișată, iar  $W_i(A_i, B_i)$  constituie o hartă de ponderi (weight map) ce pune în evidență zonele marginale ale regiunii de interes. De asemenea, simbolul  $A_i$  reprezintă predicția CNN, în timp ce  $B_i$  este rezultatul așteptat, indicat prin marcajul manual al medicului radiolog. Rețelele CNN prezentate mai sus au fost antrenate conform unei strategii ce presupus furnizarea imaginilor de intrare atât în reprezentare carteziană, cât și polară, conform ilustrărilor din Figura 1 [7]. Experimentele corespunzătoare acestei metodologii s-au realizat, pe de o parte, utilizând următoarele seturi de date standard: LiTS (The Liver Tumor Segmentation Benchmark) [8], ce a fost utilizat în fazele de antrenare și validare, în timp ce setul de date achiziționat în contextul proiectului ACADTUM, precum și setul de date standard 3DIRCADb-01 [9] au fost utilizate în faza de testare [10]. În ceea ce privește segmentarea tumorilor hepatice din imagini de rezonanță magnetică (IRM), s-au experimentat aceleași arhitecturi CNN, cea mai bună performanță rezultând în cazul rețelei Unet. Rezultatele obținute în urma aplicării acestor metode au fost comparate cu cele anterioare, corespunzătoare segmentării imaginilor ultrasonografice.

În vederea *segmentării tumorilor pancreatice din imagini CT îmbunătățite cu agent de contrast*, s-au experimentat următoarele arhitecturi CNN specifice, de ultimă generație: UNet[2], UNet++[3], DeepLabV3[4] și MANet [11] cu codificator de tip Resnet34[1]. Experimentele au fost realizate pe setul de imagini achiziționate în contextul proiectului ACADTUM, corespunzând unui număr de 26 de pacienți, incluzând imagini CT îmbunătățite cu agent de contrast, aferente fazei arteriale de propagare a substanței de contrast. S-a realizat augmentarea aleatoare a imaginilor prin introducerea de zgomot Gaussian, egalizare a histogramei, modificări de luminozitate și corecție Gamma, efecte de sharpen, blur sau motion blur. Toate imaginile s-au scalat la dimensiune de 512 x 512 pixeli. Setul de imagini a fost împărțit în felul următor: 75% dintre imagini au fost incluse în setul de antrenare, 20% dintre imagini au fost incluse în setul de validare, în timp ce 5% dintre imagini au fost incluse în setul de test. Modelele au fost antrenate cu următorii hiperparametri: număr de epoci 50; funcție de activare de tip softmax2D; funcție de cost, DiceLoss; optimizare Adam cu rata de învățare 0.0001.

În scopul *segmentării tumorilor renale din imagini CT*, au fost experimentate rețelele Unet[2], Unet++ [3] și respectiv MANet [11], combinate cu diferite arhitecturi CNN de bază, de ultimă generație, precum ResNet, EfficientNet și respectiv ResNext, realizându-se o comparație sistematică a rezultatelor obținute [12]. Ulterior segmentării acestor formațiuni tumorale, s-a realizat determinarea automată a gradului tumoral, pipeline-ul corespunzător acestei proceduri, redat în

Figura 2, incluzând următoarele module: (1.) **Modulul de segmentare tumorală**, acesta primind la intrare imaginea CT, asupra căreia se aplică metode de învățare profundă, cu scopul de a delimita regiunea tumorală din care urmează să se extragă regiuni de interes mai mici (patch-uri). (2.) **Modulul de generare a patch-urilor**, acesta realizând generarea automată a unor regiuni de interes rectangulare având dimensiunea 24x24 pixeli în interiorul formațiunilor segmentate. Aceste regiuni de interes au fost considerate valide dacă cel puțin 60% din dreptunghiul generat s-a situat în interiorul zonei (măștii) tumorale, determinată prin procedeul de segmentare automată corespunzător modulului (1). (3.) **Determinarea trăsăturilor texturale**: în interiorul fiecărei regiuni de interes rectangulare, au fost determinate trăsături texturale derivate din Matricea de Coocurența a Nivelurilor de Gri (Grey Level Cooccurrence Matrix, GLCM), respectiv pe baza convoluției cu filtre Gabor, rezultând un vector de trăsături texturale. (4.) **Recunoașterea gradului de evoluție tumorală pe baza texturii**, implicând aplicarea unor clasificatori convenționali, precum Perceptronul Multinivel (Multilayer Perceptron – MLP), Random Forest (RF) și respectiv Support Vector Machines (SVM), aceștia primind la intrare trăsăturile texturale determinate în etapa anterioară, în final, gradul tumoral fiind determinat prin intermediul unei proceduri de votare majoritară. Setul de date experimental a fost cel achiziționat în cadrul proiectului, de către medicii specialiști de la Institutul Clinic de Urologie și Transplant Renal din Cluj-Napoca, incluzând imagini CT îmbunătățite cu agent de contrast aparținând unui număr de 22 de pacienți afectați de tumori renale maligne (cancer renal), corespunzând fazelor nativă (fără contrast), precum și arterială, respectiv venoasă de propagare a substanței de contrast. Aceste imagini au fost împărțite în set de antrenare, validare și respectiv testare după cum urmează: 65% dintre imagini au fost utilizate pentru antrenare, 15% pentru validare, respectiv 20% pentru testare, această împărțire fiind adoptată atât în cazul segmentării formațiunilor tumorale, cât și în cazul recunoașterii gradului tumoral [12].



**Figura 2.** Principalele module din cadrul pipeline-ului de procesare propus


## 1.2. Metode pentru recunoașterea automată a formațiunilor tumorale

În scopul recunoașterii automate a formațiunilor tumorale din imagini medicale s-au adoptat, în primul rând, metode bazate pe învățare profundă, incluzând tehnici bazate pe rețele neuronale convoluționale (Convolutional Neural Networks – CNN), dar și rețele neuronale adânci din categoria transformerilor, dotate cu mecanisme de atenție [13]. În ceea ce privește tehnicile bazate pe rețele CNN, s-au luat în considerare atât arhitecturi existente (clasice), de ultimă generație, cât și variante îmbunătățite ale acestora în manieră originală. Ca și arhitecturi clasice, au fost implementate și evaluate următoarele: ResNet101, InceptionV3, VGGNet, MobileNetV2, EfficientNet\_b0 și ResNext [1]. De asemenea, s-au luat în considerare două variante îmbunătățite în manieră originală ale rețelei EfficientNet\_b0, după cum urmează: (1.) în cazul primei variante, *EfficNet\_ASPP1*, a fost adăugat un modul de tip Atrous Spatial Pyramid Pooling (ASPP), constituit dintr-o unitate convoluțională de dimensiune 1x1, respectiv din două unități convoluționale de dimensiune 3x3, corespunzând unor convoluții dilatate cu ratele 2, respectiv 3 adăugate la sfârșitul părții convoluționale, înaintea

nivelurilor complet conectate; (2.) în cazul celei de-a doua versiuni, *EfficNet\_ASPP2*, a fost adoptată o nouă formă a modului ASPP, adăugat în aceeași locație, acest modul fiind constituit dintr-o unitate convoluțională de dimensiune 1x1, din două unități convoluționale de dimensiune 3x3, corespunzând unor convoluții dilatate cu ratele 2 și 3, respectiv dintr-o unitate convoluțională de dimensiune 5x5, corespunzând unei convoluții dilatate cu rata 2. Cele două module ASPP au fost adăugate în vederea îmbunătățirii capabilităților rețelei cu proprietăți multiscalare. În ambele cazuri, a fost adăugat atât un nivel de tip *global average pooling*, cât și un nivel *dropout* cu o probabilitate 0.5, la sfârșitul părții convoluționale, pentru a se evita fenomenul de overfitting [14], [15]. În vederea îmbunătățirii performanțelor de recunoaștere ale acestor rețele CNN, s-au realizat combinații ale acestora, atât la nivelul clasificatorului, cât și la nivel decizional. Aceste scheme de combinare sunt detaliate în cele ce urmează.

#### a. Combinarea rețelelor CNN la nivelul clasificatorului

*Combinarea rețelelor CNN la nivelul clasificatorului* a presupus derivarea unor trăsături convoluționale la ieșirea ultimului nivel convoluțional al fiecărei rețele CNN, respectiv combinarea acestora printr-o metodă de fuziune specifică și furnizarea rezultatului la intrarea unui clasificator convențional, așa cum rezultă din Figura 3. Pentru combinarea trăsăturilor convoluționale s-au luat în considerare următoarele scheme: (1.) Simpla concatenare a vectorilor de trăsături convoluționale (*Concat*); (2.) Concatenarea vectorilor de trăsături convoluționale urmată de selecția trăsăturilor (*Concat+FS*); (3.) Selecția trăsăturilor, urmată de concatenarea vectorilor de trăsături convoluționale relevante (*FS+Concat*); (4.) Concatenarea vectorilor de trăsături, urmată de aplicarea metodei Kernel Principal Component Analysis (*Concat+KPCA*); (5.) Aplicarea metodei KPCA asupra fiecărui vector de trăsături, urmată de concatenarea vectorilor rezultat (*KPCA+Concat*). În vederea selecției trăsăturilor, s-au aplicat tehnici specifice, precum Correlation based Feature Selection (CFS), respectiv Information Gain Attribute Evaluation (IGA), respectiv combinații ale acestora [14], [16], [17]. În ceea ce privește clasificatorii convenționali s-a realizat o comparație a următorilor clasificatori, recunoscuți pentru performanțele lor: Support Vector Machines (SVM), Random Forest (RF), Multilayer Perceptron (MLP), respectiv AdaBoost combinat cu arbori decizionali (C4.5).




**Figura 3.** Combinarea rețelelor CNN la nivelul clasificatorului

#### b. Combinarea rețelelor CNN la nivel decizional

În scopul combinării rețelelor CNN la nivel decizional, s-au implementat și experimentat cele trei tehnici specifice, ilustrate în Figura 4, anume: (1.) determinarea mediei aritmetice, respectiv a unei medii ponderate între valorile probabilităților obținute la ieșirile rețelelor CNN (soft voting); (2.) luarea

unei decizii ținând cont de clasa majoritară determinată pe baza ieșirilor clasificatorilor CNN (votare majoritară); (3.) furnizarea valorilor probabilităților obținute la ieșirile CNN la intrările unor clasificatori convenționali, precum SVM, MLP, RF, respectiv AdaBoost combinat cu arbori decizionali (C4.5) (votare adaptivă) [14], [15], [16].



**Figura 4.** Combinarea rețeleor CNN la nivel decizional

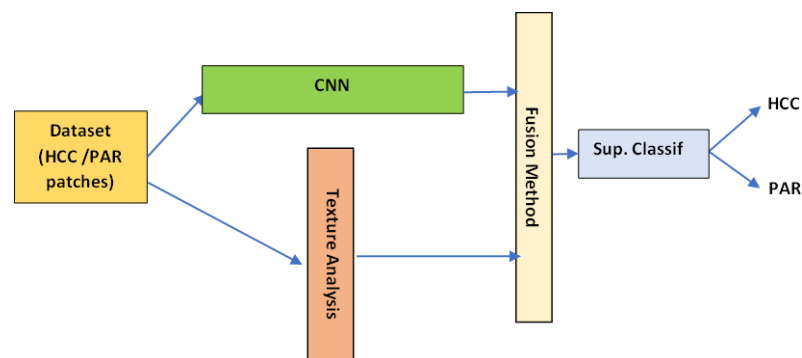
În ceea ce privește rețelele neuronale adânci din categoria *transformerilor*, s-au experimentat arhitecturi specifice, precum Vision Transformer (ViT), respectiv ConvNetxt\_base, cele mai bune rezultate fiind obținute în cazul rețelei ConvNext\_base [13]. În paralel, s-a realizat extinderea unor abordări anterioare, bazate pe *metode convenționale*, implicând aplicarea unor metode avansate de analiză a texturii în combinație cu clasificatorii tradiționali. Metodele destinate analizei texturii au fost extinse cu noi metode, bazate pe matrici de coocurență generalizate de ordin superior, precum matricea de coocurență a nivelurilor de gri de ordinul trei, trăsăturile Haralick corespunzătoare acesteia fiind determinate pentru diferite combinații de direcții ale vectorilor de deplasament. În manieră similară, a fost determinată o nouă formă a matricei de coocurență a microstructurilor texturale (Textural Microstructure Cooccurrence Matrix – TMCM), bazată pe aplicarea algoritmului k-means clustering cu valori ale parametrului k de 250, respectiv 500 de centre, urmată de determinarea matricei de coocurență a nivelurilor de gri pe imaginile rezultat. Astfel, elementele structurale de bază în noua abordare au fost centrii grupurilor (clusterilor) determinați prin intermediul algoritmului k-means. De asemenea, au fost luate în considerare noi trăsături multirezoluție, determinate prin intermediul transformatei Gabor. Concomitent, a fost experimentată o variantă proprie a metodei Local Binary Pattern (LBP), care a presupus determinarea unor histograme LBP pe regiunea de interes, ce au fost ulterior comprimate, pentru a conține un număr de 100 de acumuloare (bins). Vectorii de trăsături texturale, conținând atât trăsături clasice, cât și trăsăturile originale descrise anterior, au fost furnizați la intrările clasificatorilor convenționali (SVM, MLP, RF și respectiv adaboost combinat cu arbori decizionali). Aceste metode convenționale au fost experimentate atât individual, cât și în combinație cu metodele de învățare profundă, fuziunea fiind realizată atât la nivelul clasificatorului, cât și la nivel decizional [13].

## **2. Demersuri realizate în vederea atingerii obiectivului O2, „Compararea performanțelor metodelor convenționale, respectiv a celor de învățare profundă, în situații multiple, în cazul unor tipuri variate de imagini medicale”**

În vederea atingerii obiectivului O2, s-au realizat următoarele demersuri:

- compararea performanțelor metodelor de învățare profundă aplicate în vederea recunoașterii tumorilor hepatice din imagini ultrasonografice, CT și respectiv IRM
- compararea performanțelor metodelor de învățare profundă aplicate în vederea segmentării tumorilor hepatice din imagini ultrasonografice, CT și IRM; compararea rezultatelor obținute în urma aplicării metodelor de învățare profundă în vederea segmentării tumorilor hepatice, pancreatice și renale din imagini CT
- compararea metodelor convenționale cu cele de învățare profundă, în cazul recunoașterii tumorilor hepatice din imagini ultrasonografice, respectiv în cazul detecției gradelor tumorale în cazul cancerului renal, pe baza imaginilor CT.
- combinarea metodelor convenționale cu cele de învățare profundă, în vederea îmbunătățirii performanțelor metodelor de recunoaștere a tumorilor hepatice din imagini ultrasonografice; compararea performanțelor rezultate în urma aplicării acestor tehnici cu cele obținute în urma aplicării individuale a tehnicilor convenționale, respectiv a celor de învățare profundă.

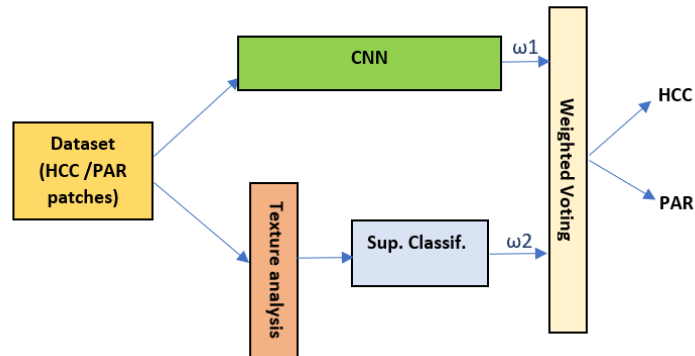
În scopul fuzionării tehnicilor convenționale cu cele de învățare profundă, s-au aplicat metode de combinare atât la nivelul clasificatorului, cât și la nivel decizional. Astfel, pentru a fuziona metodele convenționale cu cele de învățare profundă la nivelul clasificatorului (Figura 5), s-a realizat combinația dintre metodele convenționale, respectiv cele bazate pe CNN, în modul următor: trasaturile “deep learning”, extrase la capătul porțiunii convoluționale a rețelelor CNN, înainte de nivelurile complet conectate, au fost fuzionate cu vectorul de trăsături texturale, conform următoarelor scheme de combinare: (1.) s-a realizat simpla concatenare a vectorului de trăsături CNN cu vectorul de trăsături texturale (Concat); (2.) au fost determinate trăsăturile relevante considerând fiecare vector de trăsături, ca reprezentând intersecția rezultatelor aplicării metodelor Correlation based Feature Selection (CFS) și Information Gain Attribute Selection (IGA), apoi vectorii de trăsături relevante au fost concatenați (FS+concat); (3.) metoda KPCA a fost aplicată asupra fiecărui vector de trasaturi, apoi rezultatele obținute au fost concatenate (KPCA+concat); (4.) cei doi vectori de trăsături, corespunzători trăsăturilor “deep learning”, respectiv celor texturale, au fost concatenați, în final aplicându-se metodologia de selecție a trăsăturilor (concat+FS); (5.) cei doi vectori de trăsături, corespunzători trăsăturilor “deep learning”, respectiv celor texturale, au fost concatenați, în final aplicându-se metoda KPCA (concat+KPCA); (6.) cei doi vectori de trasaturi “deep learning”, respectiv de trasaturi texturale, au fost concatenați, în final aplicându-se metoda bazata pe algoritmul Particle Swarm Optimization (PSO) pentru selectia trasaturilor.



**Figura 5.** Combinarea tehnicilor convenționale și a celor de învățare profundă la nivelul clasificatorului

Rezultatul fuziunii a fost transmis la intrările unuia dintre următorii clasificatori supervizați convenționali: SVM, RF, respectiv AdaBoost în conjuncție cu algoritmul C4.5 [13].

Pentru a fuziona tehnicile convenționale cu cele de învățare profundă la nivel decizional, s-a realizat media aritmetică, respectiv media ponderată a valorilor probabilităților obținute la ieșirile clasificatorilor CNN, respective la ieșirile clasificatorilor convenționali, așa cum rezultă din Figura 6, unde  $w_1$ , respectiv  $w_2$  reprezintă ponderile asociate ieșirilor clasificatorilor, având valoarea 1 în cazul aplicării mediei aritmetice [14].



**Figura 6.** Combinarea tehnicilor convenționale și a celor de învățare profundă la nivel decizional

### 3. Demersuri realizate în vederea atingerii obiectivului "O3. Detecția stărilor preneoplazice, respectiv a tumorilor aflate în stadiu de dezvoltare incipient, prin metode computerizate"


În vederea atingerii obiectivului  $O_3$ , s-au realizat demersuri importante atât în scopul recunoașterii tumorilor hepatice aflate în stadiu incipient, cât și al recunoașterii stărilor preneoplazice ale cancerului hepatic, pe baza imaginilor CT. În ceea ce privește recunoașterea formațiunilor tumorale în stare incipientă, respectiv a stărilor preneoplazice, s-au constituit două clase: cea corespunzătoare formațiunilor tumorale inciente, precum și stărilor preneoplazice, incluzând tumori de tip carcinom hepatocelular (HCC) aflate în stadiul de evoluție incipient, respectiv noduli cirofici displazici (care pot evolua în tumori HCC); respectiv clasa corespunzătoare formațiunilor non-tumorale. În urma augmentării setului inițial de date, a rezultat un număr de 1000 instanțe/clasă. Acest set de date a fost furnizat la intrările unor rețele CNN, corespunzând unor arhitecturi precum SqueezeNet, GoogleNet, ResNet101, InceptionV3, EfficientNetb0, respectiv EfficientNetb0 îmbunătățită cu un modul ASPP (EfficientNet\_ASPP1). Seturile de date menționate au fost augmentate, de asemenea, în timpul antrenării, prin translație și scalare. Într-o altă abordare, conform metodologiei *domain adaptation learning* [18], rețelele CNN au fost întâi preantrenate în mediul Matlab (100 epoci) cu un set de date conținând atât stări preneoplazice (noduli displazici) cât și formațiuni tumorale hepatice aflate atât în stadii inciente, cât și evaluate. În cea de-a doua etapă, acestea au fost reantrenate (100 epoci) cu date specifice, corespunzătoare stărilor preneoplazice, respectiv formațiunilor tumorale aflate în stadiu incipient.

De asemenea, s-au dezvoltat tehnici adecvate în vederea recunoașterii gradelor tumorale din imagini CT în cazul cancerului renal, fiind incluse, în setul de date, formațiuni tumorale aflate în

stadiu de dezvoltare incipient, corespunzătoare gradului 1. Au fost comparate, din punctul de vedere al performanței de detecție, două metodologii:

- (1.) S-a realizat segmentarea formațiunilor tumorale renale prin metode bazate pe tehnica CNN, urmată de aplicarea unor metode convenționale, bazate pe analiză texturală, în scopul recunoașterii automate a gradului tumoral.
- (2.) S-au aplicat în mod direct metode de învățare profundă în scopul segmentării tumorilor renale în funcție de grad.

În ceea ce privește tehnicile bazate pe CNN, s-au luat în considerare arhitecturile specificate la punctul 1.1, anume UNet, UNet++, DeepLabV3+ și MANet, cu codificatoare (encodere) de tip ResNet, ResNext și EfficientNet\_b0. În ceea ce privește metodele convenționale, în scopul analizei texturale, s-au luat în considerare parametrii Haralick derivați din matricea GLCM, alături de trăsături multirezoluție, bazate pe transformata Gabor. S-a generat, astfel, un banc de filtre Gabor având diferite orientări, în intervalul  $[\frac{\pi}{8}, \pi]$ , pasul de incrementare fiind  $\frac{\pi}{8}$ , cu diferite frecvențe spațiale ale funcțiilor armonice, din mulțimea 0.05, 0.25, 0.5, parametrul sigma luând valori în intervalul [0..5], rezultând în acest mod un număr total de 45 de filtre. Vectorul de trăsături texturale, constituit din rezultatul convoluției cu partea reală a filtrului Gabor, respectiv din trăsăturile texturale rezultate din matricea GLCM, a fost furnizat la intrările clasificatorilor convenționali [12].



**Figura 7.** În timpul procedurii de inferență sunt generate patch-uri, gradul tumoral fiind prezis pentru fiecare patch. Gradul întregii formațiuni tumorale este decis printr-o procedură de votare majoritară.

În timpul experimentării acestui sistem, s-au generat în mod automat regiuni de interes rectangular (patch-uri) în interiorul fiecărei regiuni tumorale segmentate, așa cum rezultă din Figura 7. Pentru fiecare patch, este prezis un anumit grad tumoral (1, 2, 3 sau 4). Gradul de evoluție al întregii formațiuni tumorale este estimat printr-o procedură de votare majoritară, luându-se în considerare gradele prezise pentru regiunile de interes rectangular (patch-urile) componente, așa cum rezultă din Figura 7.

#### **4. Demersuri realizate în vederea îndeplinirii obiectivului “O4. Susținerea activităților de cercetare pentru tinerii cercetători.”**

În vederea atingerii obiectivelor proiectului ACADTUM, în procesul de dezvoltare și experimentare a metodelor corespunzătoare acestor obiective, respectiv în vederea dezvoltării aplicației software,

au fost implicați atât studenți masteranzi aflați în ultimul an de studiu, cât și tineri doctoranzi, membri în proiect. Astfel, studentul masterand (Vlad Timu), împreună cu unul dintre doctoranzi (Andrei-Vlad Florian), au fost implicați atât în dezvoltarea metodelor destinate segmentării tumorilor abdominale, cât și în demersurile realizate în vederea integrării modulelor componente în aplicația software ACADTUM. Cel de-al doilea doctorand membru în proiect, specializat în domeniul urologiei și al transplantului renal (Tudor Moisoiu), a fost implicat în achiziționarea și colectarea imaginilor conținând tumori reale, în adnotarea acestora, precum și în furnizarea datelor medicale, respectiv a informațiilor necesare echipei proiectului în acest domeniu. Toate aceste activități s-au dovedit a fi deosebit de utile pentru cei implicați, contribuind în mod considerabil la lărgirea orizonturilor profesionale, respectiv la completarea cunoștințelor și aptitudinilor acestora, generând conținut pentru o lucrare de disertație, creând oportunități de interacțiune și colaborare interdisciplinară.

**5. Demersuri realizate în vederea îndeplinirii obiectivului principal al proiectului, de „ dezvoltare a unui sistem software pentru diagnoza automată și asistată de calculator a tumorilor abdominale, bazat pe imagini medicale de diferite tipuri, implicând atât tehnici convenționale, cât și de învățare profundă”**

Cele mai performante metode dezvoltate în cadrul proiectului ACADTUM, în vederea segmentării, respectiv în vederea recunoașterii tumorilor abdominale din imagini de tipuri diferite, au fost integrate în sistemul software ACADTUM, destinat realizării diagnozei automate, respectiv asistate de calculator, a tumorilor abdominale, pe baza imaginilor medicale. Acest sistem software a fost dezvoltat utilizând tehnologie Python, implicând implementarea funcțiilor unor biblioteci specifice precum TorchVision, ScikitLearn, OpenCV, Numpy, PyQt. S-a urmărit obținerea unui sistem software eficient, care să furnizeze rezultatul așteptat în timp cât mai scurt, cu o interfață utilizator grafică prietenoasă, adecvată nevoilor exprimate de către medicii specialiști. Aplicația în format executabil se găsește la adresa:

[https://users.utcluj.ro/~dmitrea/Pagina\\_persDM/ACADTUM/ACADTUM\\_Sw\\_20204.zip](https://users.utcluj.ro/~dmitrea/Pagina_persDM/ACADTUM/ACADTUM_Sw_20204.zip) .

## **II. Rezultate obținute**

### **1. Rezultate privind segmentarea automată a formațiunilor tumorale**

#### **1.1. Segmentarea tumorilor hepatice**

##### **a. Evaluarea performanțelor obținute pentru segmentarea tumorilor hepatice în cazul utilizării modelului cartezian**

În **Tabelul 1** sunt ilustrate valorile parametrilor de performanță obținute pe setul de test (3DIRCADB) în cazul în care s-au furnizat la intrare date în reprezentarea carteziană, valorile optime fiind marcate cu bold. Rețelele au fost antrenate utilizând slice-uri pentru fiecare volum, apoi a fost determinată media aritmetică în cazul fiecărei metrici. Așa cum rezultă din Tabelul 1, valorile maxime ale majorității metricilor: *DICE*, *IoU*, *precizie* și *recall* au rezultat în cazul arhitecturii DeepLabV3+, în timp ce valorile maxime pentru acuratețe și AuC au fost obținute în cazul UNet.

**Tabelul 1.** Evaluarea Performanței pe Setul de Test 3DIRCADB-01 atunci când a fost implementat Modelul Cartezian

Model	DICE (%)	IoU (%)	Acc. (%)	Prec. (%)	Recall (%)	AuC (%)
UNet	78.67	67.74	<b>99.82</b>	81.79	77.78	<b>70.16</b>
UNet++	75.48	64.1	99.75	77.68	76.65	57.13
DeepLabV3+	<b>80.92</b>	<b>69.55</b>	99.81	<b>82.75</b>	<b>80.19</b>	37.63

**b. Evaluarea performanțelor pentru segmentarea tumorilor hepatice în cazul utilizării modelului polar**

**Tabelul 2** ilustrează valorile parametrilor de performanță atunci când la intrare a fost furnizat modelul polar, valorile maxime fiind marcate cu bold. În acest caz, valorile maxime pentru acuratețe, recall și AuC au fost obținute în cazul arhitecturii UNet, valorile maxime pentru coeficientul DICE și pentru IoU au rezultat în cazul UNet++, în timp ce valoarea maximă a preciziei a rezultat pentru DeepLabV3+.

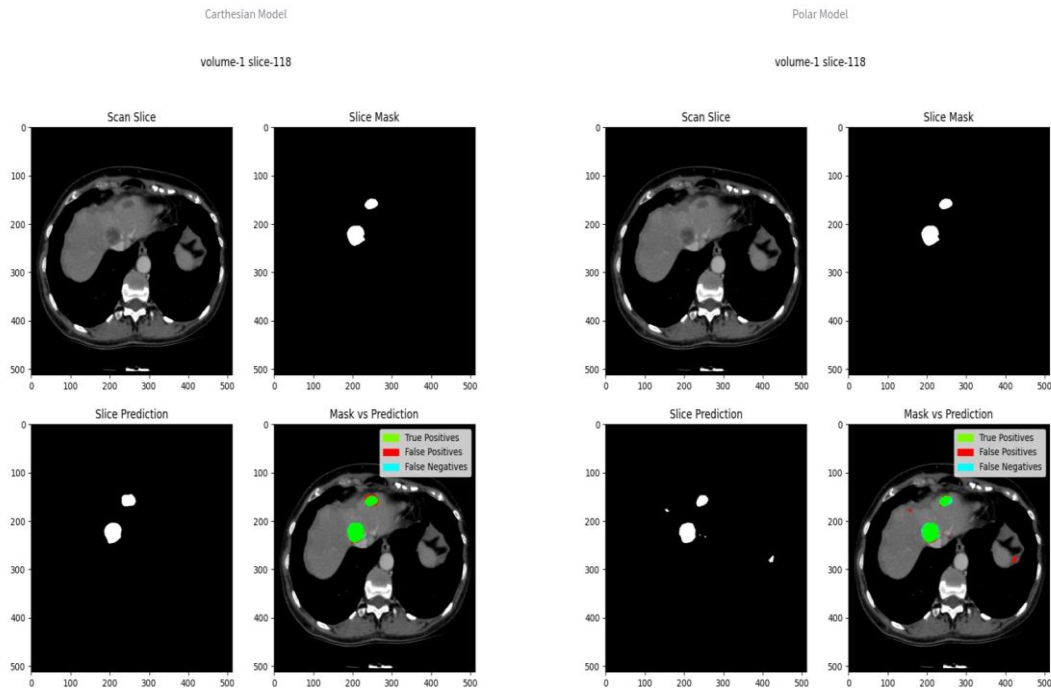
**Tabelul 2.** Evaluarea Performanței pe Setul de Test 3DIRCADB-01 la Implementarea Modelului Polar

Model	DICE (%)	IoU (%)	Acc. (%)	Prec. (%)	Recall (%)	AuC (%)
UNet	64.12	50.07	<b>99.64</b>	56.69	<b>75.71</b>	<b>50</b>
UNet++	<b>67.26</b>	<b>54.08</b>	99.63	66.87	70.26	47.35
DeepLabV3+	52.22	37.70	98.98	<b>72.42</b>	45.25	48.13

În Figura 8 se pot vizualiza rezultatele procesului de segmentare atunci când a fost implementată arhitectura DeepLabV3+, atât în cazul în care s-a utilizat modelul cartezian, cât și în cazul utilizării modelului polar. Pentru fiecare astfel de model, regiunile detectate ca și pozitive (True Positives) sunt marcate cu verde, regiunile detectate ca și fals pozitive sunt colorate cu roșu, respectiv fals negativele sunt colorate cu albastru. Se poate observa că atunci când a fost adoptat modelul polar au rezultat mai multe regiuni fals pozitive, decât în cazul adoptării modelului cartezian. De asemenea, potrivirile dintre masca de reper (ground truth) și cea corespunzătoare predicției au o mai mare acuratețe în cazul modelului cartezian. În cazul în care s-a utilizat ca set de testare *setul de date ACADTUM*, performanțele maxime au fost obținute în cazul rețelei DeepLabV3+, rezultând o valoare a indicelui DICE de 12.85%, o valoare a metricii IoU de 8.78%, o acuratețe de 99.38%, o precizie de 10.01%, o sensibilitate de 22.96%, o specificitate de 99.5%, respectiv o valoare AuC de 46.91%. În cazul modelului polar, pentru aceeași arhitectură CNN, pe același set de date, a rezultat o valoare a indicelui DICE de 11.07%, o valoare a metricii IoU de 7.16%, o valoare a acurateței de 99.29%, o precizie de 9.78%, o valoare a sensibilității de 16.49%, o valoare a specificității de 99.50%, respective o valoare AuC de 51.6%. Aceste rezultate au fost diseminate în lucrarea cu titlul "Liver tumor segmentation from Computed Tomography images through Convolutional Neural Networks", prezentată la conferința *The 2023 9th International Conference on Systems and Informatics (ICSAI 2023)*, 16-18 decembrie 2023, Changsha, China [10], publicată în volumul conferinței. De asemenea, în cazul segmentării tumorilor hepatice din imagini CT prin intermediul rețelei UNet, utilizând atât pentru setul de antrenare, cât și pentru cel de test, imagini achiziționate în contextul proiectului ACADTUM, a rezultat o valoare a metricii IoU de 63%, iar în cazul segmentării tumorilor hepatice din imagini IRM, utilizând setul de date ACADTUM, s-a obținut o valoare a metricii IoU de 71%.

## 1.2. Segmentarea tumorilor pancreatice

În cazul segmentării tumorilor pancreatice, cea mai bună valoare pentru metrica IoU a fost obținută cu o rețea de tip UNet++ pentru pixelii tumorali. Chiar dacă scorul IoU pentru tumoră a fost relativ mic, în majoritatea imaginilor au fost identificați cel puțin 50% din pixelii care aparțin regiunilor tumorale. Astfel, s-a remarcat faptul că în cazul segmentării tumorilor pancreatice s-a obținut o performanță mai redusă decât pentru celelalte tipuri de tumori abdominale, ceea ce s-a datorat, probabil, naturii difuze a acestor tumori în majoritatea cazurilor.




**Figura 8.** Ilustrarea procesului de segmentare a tumorilor hepatice prin intermediul arhitecturii DeepLabV3+, în cazul modelului cartezian (stânga), respectiv polar (dreapta)

## 1.3. Segmentarea tumorilor renale

Cele mai bune rezultate în ceea ce privește segmentarea tumorilor renale din imagini CT au fost obținute pe setul de imagini CT corespunzând fazei arteriale de propagare a agentului de contrast, rezultând, pentru setul de test, o valoare maximă de 73% pentru metrica IoU, în cazul implementării arhitecturii UNet având la baza codificatorul (encoder) arhitectura ResNet34, urmată de o valoare de 71% în cazul implementării arhitecturii UNet în conjuncție cu un codificator de tip ResNetx50, rezultând o acuratețe de 99.6% în cazul implementării arhitecturii UNet cu aceeași configurație.

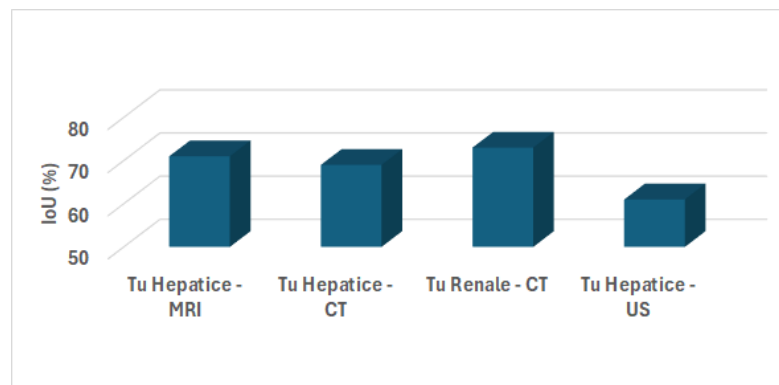
În Figura 9 este ilustrat un rezultat relevant privind segmentarea tumorilor renale din imagini CT corespunzătoare fazei arteriale. Aceste rezultate au fost disseminate în lucrarea R. Brehar, D. Mitrea, S. Nedevschi, T. Moisoiu, F.I. Elec, M. Socaciu, "Kidney Tumor Segmentation and Grade Identification in CT Images", 2023 IEEE 19th International Conference on Intelligent Computer Communication and Processing (ICCP), Cluj-Napoca, 26-28 octombrie 2023, publicată în volumul conferinței [12].



**Figura 9.** Segmentarea tumorilor renale din imagini CT corespunzătoare fazei arteriale (stanga: delimitarea manuală a medicului specialist - ground truth; dreapta: detecția propriu-zisă)

#### 1.4. Discuții

Luând în considerare rezultatele ilustrate mai sus, referitoare la segmentarea tumorilor abdominale pe baza imaginilor medicale, putem observa faptul că performanța optimă a rezultat în cazul segmentării tumorilor renale pe baza imaginilor CT, metrica IoU având, în acest caz, valoarea de 73%, în cazul implementării rețelei UNet cu codificator de tip ResNet34. Cea de-a doua valoare a performanței, metrica IoU având valoarea 71%, a rezultat în cazul segmentării tumorilor hepatice pe baza imaginilor IRM. Aceasta a fost urmată de cea corespunzătoare segmentării tumorilor hepatice pe baza imaginilor CT, metrica IoU având în acest caz valoarea de 69% în cazul antrenării rețelei DeepLabV3+ pe setul de date LiTS, testarea realizându-se pe setul de date 3DIRCADB. În cazul segmentării tumorilor hepatice din imagini ultrasonografice, a rezultat o valoare maximă a metricii IoU de 61%, în cazul implementării rețelei UNet. O prezentare sintetică a acestor rezultate se poate regăsi în Figura 10. Toate aceste demersuri au fost realizate în conformitate cu obiectivele  $O_1$  și  $O_2$  ale proiectului.



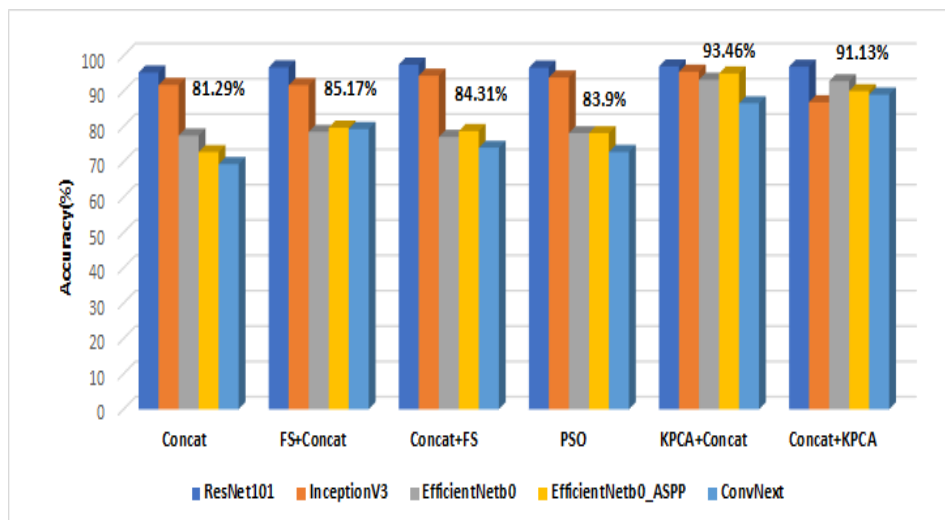
**Figura 10.** Compararea performanțelor corespunzătoare segmentării automate a tumorilor abdominale din imagini medicale de diferite tipuri

## 2. Rezultate privind recunoașterea automată a formațiunilor tumorale

### 2.1. Rezultate privind recunoașterea tumorilor abdominale din imagini ultrasonografice.

Compararea metodelor bazate pe învățare profundă cu cele convenționale

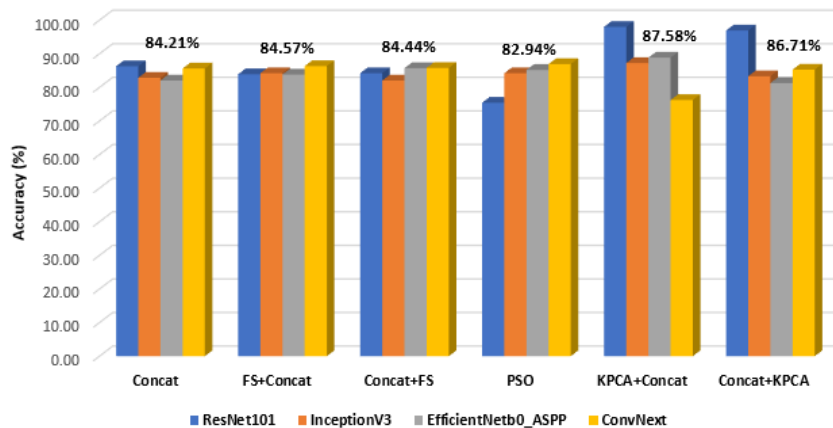
În scopul experimentării metodelor avansate destinate recunoașterii tumorilor hepatice din imagini ultrasonografice, bazate pe combinarea arhitecturilor CNN, respectiv pe fuziunea dintre metodele convenționale și metodele de învățare profundă, s-au realizat experimente pe două seturi de date: un set de date achiziționat prin intermediul unui aparat ultrasono-grafic Logiq 7 (GE7), corespunzător unui număr de 200 de pacienți bolnavi de HCC, respectiv un set de date achiziționat mai recent, prin intermediul unui aparat ultrasonografic de tip Logiq 9 (GE9), corespunzător unui număr de 96 pacienți bolnavi de HCC. Experimentele s-au desfășurat conform descrierilor din [13], [14]. În ceea ce privește *combinarea metodelor convenționale cu metodele de învățare profundă la nivelul clasicatorului*, au fost evaluate, respectiv comparate mai multe scheme de fuziune, conform descrierilor din capitolul anterior, respectiv celor din [13]. Astfel, pentru fiecare schemă de fuziune, a fost determinată media aritmetică a valorilor parametrilor de performanță obținuți pentru clasicatorii convenționali individuali. Comparăția dintre performanțele de clasificare datorate celor două scheme de fuziune, în cazul celor două seturi de date, GE7 și respectiv GE9, este ilustrată în Figura 11, respectiv în Figura 12. În Figura 11, deasupra fiecărui grup corespunzător unei anumite scheme de combinare, este reprezentată media aritmetică a valorilor de acuratețe pentru acel grup. Așa cum se poate observa, toate schemele de combinare ce au implementat selecția trăsăturilor și KPCA, au condus la o performanță mai bună decât cea obținută prin simpla concatenare a trăsăturilor CNN cu cele texturale. Cea mai mare valoare a acurateței medii pentru schemele de fuziune a fost obținută în cazul schemei de combinare KPCA+Concat (93.46%), urmată de cea rezultată în cazul Concat+KPCA (91.13%).



**Figura 11.** Comparația dintre valorile medii de acuratețe rezultate pentru fiecare schemă de fuziune, pentru fiecare arhitectură CNN, în cazul setului de date GE7

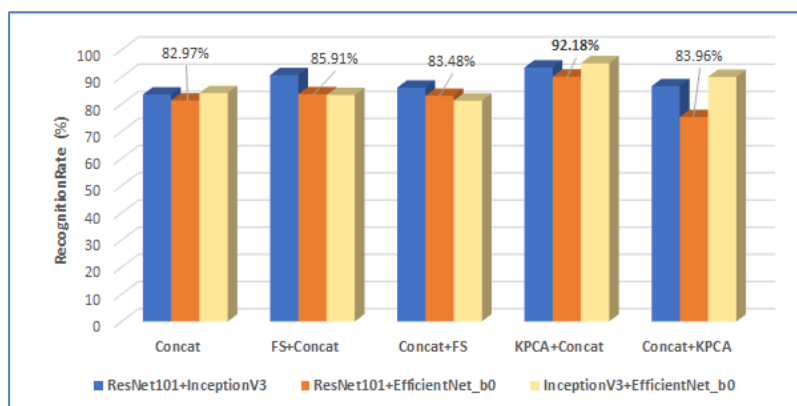
În Figura 12 este ilustrată comparația dintre mediile aritmetice ale valorilor de acuratețe pentru fiecare schemă de fuziune, aceste valori fiind evidențiate în partea superioară a figurii. Astfel, cea mai mare valoare a acurateței medii, de 87.58%, a fost obținută în cazul KPCA + Concat, urmată de valoarea 86.71%, rezultată în cazul Concat+KPCA. Informația furnizată prin intermediul Figurii 11 o confirmă pe cea furnizată prin intermediul Figurii 10, clasificarea schemelor de fuziune, din punctul de vedere al performanței de clasificare, fiind foarte similară în cele două figuri. În ceea ce privește tehnicile de învățare profundă, trebuie să remarcăm faptul că ResNet101, precum și ConvNext\_base, au furnizat rezultate foarte bune, în majoritatea situațiilor. Aceste rezultate au fost diseminate în lucrarea științifică cu titlul "Hepatocellular Carcinoma Recognition from Ultrasound Images Using

Combinations of Conventional and Deep Learning Techniques”, publicată în revista *Sensors*, Vol. 23, No. 5, 2023 [13].




**Figura 12.** Comparația dintre valorile medii de acuratețe rezultate pentru fiecare schemă de fuziune, pentru fiecare arhitectură CNN, în cazul setului de date GE9

În ceea ce privește *combinațiile dintre rețelele CNN la nivelul clasificatorului*, în cazul setului de date GE9, performanța de clasificare optimă a rezultat în cazul schemelor de combinare *CFS+Concat*, respectiv *KPCA+Concat*, atunci când au fost implementați metaclasificatorii Random Forest (RF), respectiv AdaBoost în conjuncție cu arbori decizionali. Pentru a oferi o viziune sintetică asupra rezultatelor, în Figura 13 este redat un grafic comparativ al valorilor parametrului acuratețe pentru fiecare schemă de fuziune, pentru fiecare combinație de arhitecturi CNN. Media aritmetică a valorilor de acuratețe, pentru fiecare schemă de fuziune, este de asemenea ilustrată. Astfel, performanța optimă a fost furnizată de schema de combinare *KPCA+Concat*, cu o acuratețe medie de 92.18%, urmată de *FS+Concat*, cu o acuratețe medie de 85.91%. Performanța optimă a fost furnizată de *Resnet101+InceptionV3*, urmată de *InceptionV3+EfficientNet\_b0*, respectiv de *ResNet101+EfficientNet\_b0*. Aceste rezultate au fost diseminate în lucrarea cu titlul “Hepatocellular Carcinoma recognition from ultrasound images through Convolutional Neural Networks and their combinations”, prezentată la International Conference on Advancements of Medicine and Health Care through Technology (MediTech), Cluj-Napoca, 20-22 octombrie 2022, publicată în volumul conferinței, editat la editura Springer [16].



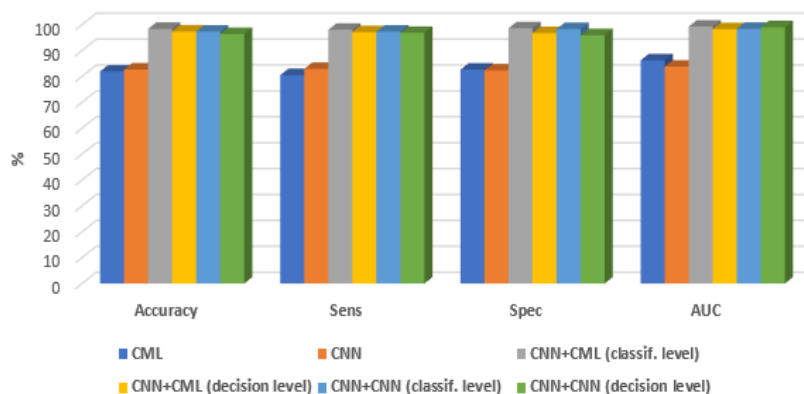
**Figura 13.** Comparația dintre valorile medii ale acurateței pentru fiecare schema de combinare, în cazul fiecărei combinații de arhitecturi CNN la nivelul clasificatorului

Referitor la *combinarea rețelelor CNN la nivel decizional*, pe setul de date GE9, o comparație a diferitelor scheme de combinare implementate se regăsește în Figura 14. Așa cum rezultă din această figură, cea mai mare performanță a rezultat în cazul schemei de combinare bazată pe votarea adaptivă (adaptive voting), rezultând o acuratețe medie de 96.85%, o senzitivitate medie de 97.43%, o specificitate medie de 96.30%, respectiv o valoare medie a parametrului AuC de 98.45%. Observăm de asemenea faptul că performanțele de clasificare datorate acestei scheme de combinare au fost apropiate de cele datorate combinării rețelelor CNN la nivelul clasificatorului. Aceste rezultate au fost diseminate în lucrarea științifică cu titlul “Hepatocellular carcinoma recognition from ultrasound images by fusing convolutional neural networks at decision level”, prezentată la The 46<sup>th</sup> International Conference on Telecommunications and Signal Processing (TSP 2023), 12-14 iulie 2023, publicată în volumul conferinței [15].



**Figura 14.** Comparația dintre valorile medii ale acurateței pentru fiecare schemă de combinare, în cazul fuziunii rețelelor CNN la nivel decizional

Figura 15 ilustrează comparația dintre valorile maxime ale parametrilor de performanță pentru metodele și schemele de combinare implementate în scopul recunoașterii tumorilor HCC din imagini ultrasonografice, pe cel mai recent set de date, GE9 [14]. Pentru a îmbunătăți valoarea procedurilor de evaluare, cei mai performanți clasificatori, identificați în contextul experimentelor realizate anterior, au fost reevaluați prin procedura de validare încrucișată cu 5 iterații (cross-validation with 5 folds). Astfel, performanța maximă a rezultat în cazul fuziunii la nivelul clasificatorului, între tehnicile convenționale și cele de învățare profundă (“deep learning”), CML și CNN, media aritmetică a valorilor tuturor parametrilor de performanță având valoarea de 98.55%. Pe locul al doilea s-a situat combinația la nivel decizional dintre rețelele CNN, atunci când această combinație s-a realizat prin votare adaptivă, media aritmetică a valorilor parametrilor de performanță, obținută în acest caz, fiind 97.83%. A urmat fuziunea la nivel decizional dintre metodele de învățare profundă, respectiv metodele convenționale, media aritmetică a parametrilor de performanță, obținută în acest caz, fiind 97.36%, apoi fuziunea la nivelul clasificatorului a rețelelor CNN (valoarea medie a indicilor de performanță fiind 97.83%). Toate aceste scheme de fuziune au surclasat în ceea ce privește performanța de clasificare aplicarea individuală a rețelelor CNN, performanța medie fiind în acest caz de 82.91%, respectiv aplicarea individuală a metodelor CML (performanța medie de 82.81%). Aceste rezultate au fost descrise în capitolul de carte “Deep Learning Techniques for Liver Tumor Recognition in Ultrasound Images”, publicat în cartea cu titlul “Deep Learning - Recent Findings and Researches”, editată la editura internațională IntechOpen [14].

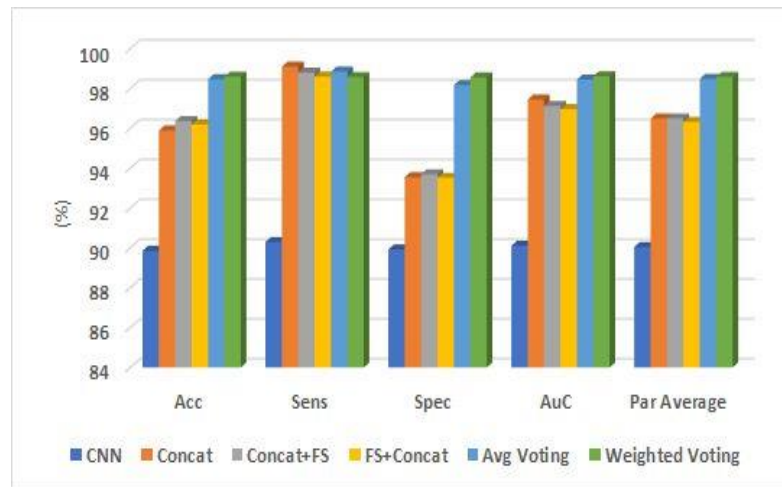


**Figura 15.** Comparația parametrilor de performanță pentru toate schemele de fuziune în cazul recunoașterii HCC din imagini ultrasonografice

## 2.2. Rezultate privind recunoașterea tumorilor hepatice și pancreatice din imagini CT, IRM

Experimentele s-au realizat în mediul MatlabR2021b, fiind utilizat, în cazul tumorilor hepatice, un set de date imagistic corespunzător unui număr de 50 pacienți, cuprinzând atât imagini CT, cât și IRM pentru aceiași pacienți. În cazul tumorilor pancreatice, s-a utilizat un set de imagini CT corespunzând unui număr de 26 pacienți. Astfel, în cazul diferențierii dintre clasele tumoră hepatică/non tumoră pe baza imaginilor CT, s-a obținut o acuratețe maximă de 99.4%, o sensibilitate maximă de 99.6% și o specificitate maximă de 99.1% în cazul arhitecturii GoogleNet. În cazul diferențierii dintre clasele tumoră hepatică/non tumoră pe baza imaginilor IRM, s-a obținut o acuratețe maximă de 99.7%, o sensibilitate maximă de 100%, respectiv o specificitate maximă de 99.4% în cazul arhitecturii Squeezenet. În vederea recunoașterii tumorilor pancreatice din imagini CT, s-au comparat, într-o primă fază, arhitecturile CNN descrise în cadrul capitolului I. Cele mai performante arhitecturi CNN au fost fuzionate, de asemenea, atât la nivelul clasificatorului, cât și la nivel decizional, prin intermediul unei proceduri de votare bazată pe media aritmetică, respectiv pe cea ponderată, cele mai mari ponderi fiind atribuite clasificatorilor mai performanți. În ceea ce privește aplicarea individuală a clasificatorilor CNN, rezultatele optime au fost furnizate prin intermediul arhitecturii InceptionV3 (acuratețe de 98%, sensibilitate de 98.7%, specificitate de 97.2%, respectiv AuC de 97.95%). În ceea ce privește variantele îmbunătățite ale arhitecturii EfficientNet\_b0, varianta EfficNet\_ASPP1 a furnizat aceeași acuratețe ca și EfficientNet\_b0, dar o valoare îmbunătățită a sensibilității și AuC. Versiunea de rețea CNN EfficNet\_ASPP2 a condus la o valoare superioară a specificității, dar la valori inferioare pentru ceilalți parametri. Figura 16 ilustrează comparația dintre valorile medii ale parametrilor de performanță corespunzători aplicării individuale a rețelelor CNN, precum și diferitelor scheme de combinare ale rețelelor CNN la nivelul clasificatorului, respectiv la nivel decizional. Toate schemele de combinare considerate au depășit în performanță rețelele CNN individuale, în timp ce schemele de fuziune la nivel decizional au furnizat în general rezultate optime, urmate de fuziunea la nivelul clasificatorului. Astfel, cea mai mare medie a valorilor parametrilor de performanță, de 98.59%, a rezultat în cazul votării prin intermediul mediei ponderate, urmată de valoarea 98.49% obținută prin procedura de votare pe baza mediei aritmetice, urmată de valoarea medie 96.5%, obținută în cazul schemelor de fuziune la nivelul clasificatorului: concatenare (*Concat*), respectiv concatenare urmată de selecția trăsăturilor (*Concat+FS*). Aceste rezultate au fost diseminate în lucrarea cu titlul „Pancreatic Tumor Recognition from CT Images through Advanced


Deep Learning Techniques”, acceptată la conferința „IEEE International Conference on Automation, Quality and Testing, Robotics (AQTR 2024)” [17].



**Figura 16.** Comparația dintre valorile parametrilor de performanță corespunzătorii unor metode variate de recunoaștere a tumorilor pancreatice

### 2.3. Discuții

Se poate observa faptul că performanțele maxime în ceea ce privește recunoașterea tumorilor hepatice au fost cele obținute pe baza imaginilor IRM, urmate de cele obținute pe baza imaginilor CT, respectiv de cele obținute în cazul imaginilor ultrasonografice. Astfel, în cazul recunoașterii tumorilor abdominale pe baza imaginilor IRM, s-a obținut o acuratețe maximă de 99.7%, pentru arhitectura SqueezeNet. În cazul recunoașterii tumorilor abdominale pe baza imaginilor CT a rezultat o acuratețe maximă de 99.6%, pentru arhitectura GoogleNet. În cazul recunoașterii tumorilor abdominale pe baza imaginilor ultrasonografice a rezultat o acuratețe maximă de 98.01% în cazul fuziunii dintre trăsăturile ResNet101 și cele texturale prin intermediul schemei de combinare *KPCA + Concat*. În general, metodele bazate pe învățare profundă au depășit metodele convenționale din punctul de vedere al performanței de clasificare.



**Figura 17.** Comparația dintre valorile parametrilor de performanță în cazul recunoașterii tumorilor abdominale din imagini medicale de diferite tipuri

O ilustrare grafică elocventă în acest sens, ce ia în considerare toți parametrii de performanță, este redată în Figura 17. Aceste demersuri au fost realizate în conformitate cu obiectivele  $O_1$  și  $O_2$  ale proiectului.

### 3. Rezultate privind recunoașterea stadiilor incipiente și a stărilor preneoplazice

În cazul diferențierii stărilor preneoplazice hepatice de formațiunile non-tumorale din imagini CT, în conformitate cu obiectivul  $O_3$  al proiectului, în urma antrenării rețelelor CNN direct cu datele imagistice corespunzătoare formațiunilor incipiente și preneoplazice, luând în considerare clasele *formatiuni incipiente&preneoplazice, respectiv parenchim cirotc pe care acestea s-au dezvoltat*, s-a obținut o acuratețe maximă de 82.8%, o sensibilitate maximă de 77%, respectiv o specificitate maximă de 89.8% în cazul arhitecturii InceptionV3. Luând în considerare abordarea *domain adaptation learning* [18], rețelele CNN au fost antrenate, într-o primă fază, în vederea diferențierii dintre clasele: formațiuni incipiente&preneoplazice și tumori hepatice maligne (HCC), respectiv parenchim cirotic pe care acestea s-au dezvoltat (non-tumoră). În acest caz, a rezultat o acuratețe maximă de 77.5%, o sensibilitate maximă de 69.9%, o specificitate maximă de 90.6%, respectiv o valoare AuC maximă de 80.25%, tot pentru arhitectura InceptionV3. În cea ce-a doua etapă, antrenarea acelorși rețele a fost rafinată luându-se în considerare setul de date referitor la formațiunile incipiente și preneoplazice (conținând clasele *formatiuni incipiente&preneoplazice, respectiv parenchim cirotc pe care acestea s-au dezvoltat*). A rezultat o acuratețe maximă de 81.9%, o sensibilitate maximă de 88.8%, o specificitate maximă de 76.8%, respectiv o valoare maximă a AuC de 82.30%, în cazul arhitecturii InceptionV3.

În cazul detecției gradului tumoral pentru cancerul renal ( $O_3$ ), prin intermediul metodelor convenționale descrise în capitolul I, valorile maxime ale metricilor de performanță au rezultat tot în cazul imaginilor CT preluate în faza arterială. Trebuie menționat faptul că în cazul recunoașterii gradului 1 s-a obținut o performanță mai scăzută, datorită dimensiunilor mici ale tumorilor, motiv din care a rezultat un set de date de antrenare de dimensiune redusă, în timp ce în cazul recunoașterii gradelor mai evolute, performanța a crescut, valorile maxime ale metricilor rezultând în cazul recunoașterii gradului 4 tumoral. În ceea ce privește clasificatorii convenționali implicați, cele mai mari performanțe au rezultat în cazul clasificatorului Random Forest (RF), precizia fiind 99% în cazul recunoașterii gradului 4 tumoral, dar și în cazul clasificatorului Support Vector Machines (SVM), precizia fiind 99% în cazul recunoașterii gradului 4 tumoral, respectiv 93% în cazul recunoașterii gradului 2 tumoral [12].

**Tabelul 3.** Valorile metricilor de performanță în cazul recunoașterii gradului tumoral

Clasificator	Precizie	Recall	Scor F1
MLP	0.71	<b>0.73</b>	0.71
RF	<b>0.82</b>	0.71	<b>0.73</b>
SVM	0.69	0.67	0.57

Valorile medii ale metricilor de performanță obținute pentru fiecare clasificator convențional sunt ilustrate în Tabelul 3. Se observă faptul că cele mai bune performanțe au rezultat în cazul clasificatorului Random Forest (RF). În paralel, au fost aplicate direct metodele bazate pe clasificatori CNN, în scopul segmentării automate a formațiunilor tumorale renale, în funcție de grad. Rețelele CNN experimentate au fost de tipul UNet cu codificator de tip ResNet34, respectiv UNet++ cu același


tip de codificator. Cele mai bune performanțe au rezultat pentru imaginile achiziționate în timpul fazei arteriale. Valorile medii ale metricilor de performanță corespunzătoare fiecărei rețele CNN, pentru faza arterială, sunt ilustrate în Tabelul 4. Se observă, astfel, faptul că metoda bazată pe arhitectura UNet a furnizat rezultate mai bune decât cea bazată pe arhitectura UnetPlusPlus, pentru toți parametrii de performanță.

**Tabelul 4.** Valorile metricilor de performanță corespunzătoare segmentării tumorilor în funcție de grad prin intermediul CNN

CNN	Dice Loss	IoU Score	F1 Score
UNet+ResNet34	<b>0.0209</b>	<b>0.989</b>	<b>0.994</b>
UnetPlusPlus + ResNet34	0.021	0.983	0.991


Luând în considerare rezultatele prezentate în Tabelul 3, respectiv în Tabelul 4, putem compara metodele convenționale cu cele de învățare profundă în funcție de metrica *F1 Score*, în conformitate cu obiectivul  $O_2$  al proiectului. Astfel, în ceea ce privește metodele convenționale, a rezultat o valoare medie de 0.67 a acestei metrici, în timp ce în cazul metodelor bazate pe învățare profundă, valoarea medie a metricii *F1 Score* a fost 0.992, deci metodele bazate pe învățare profundă au depășit în performanță metodele de clasificare.

Ilustrări elocvente, prin intermediul hărților de confidență, ale rezultatelor obținute în cazul recunoașterii gradului întâi tumoral prin intermediul metodelor convenționale, respectiv prin intermediul metodelor bazate pe învățare profundă, sunt redată în Figura 18, respectiv în Figura 19.



**Figura 18.** Detecția automată a tumorilor renale de grad 1 prin metode convenționale

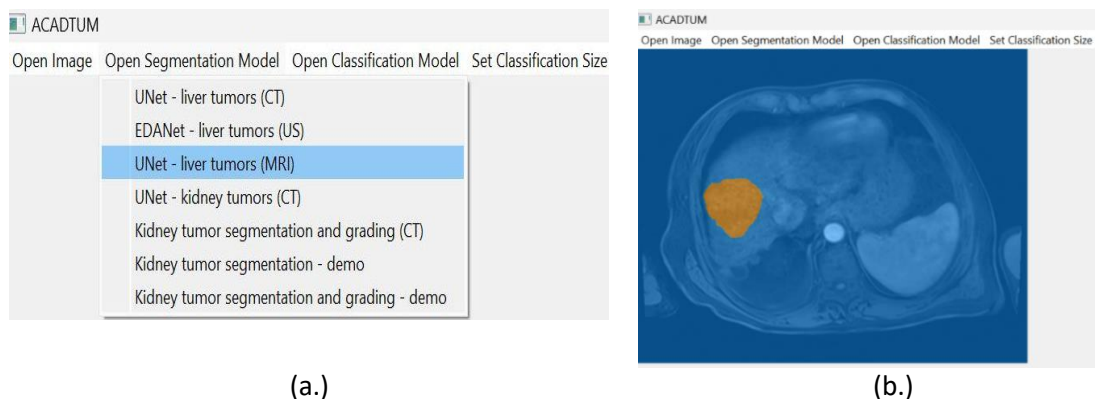
În Figura 18, detecția obținută în mod automat, prin intermediul metodelor convenționale, este suprapusă cu indicația manuală a medicului specialist radiolog („Ground Truth”), în timp ce în Figura 19, cele două imagini (cea corespunzătoare indicației medicului specialist, respectiv cea corespunzătoare detecției automate) sunt ilustrate separat. Se poate observa faptul că, și în acest caz, acuratețea procesului de detecție automată este mai mare în cazul aplicării metodelor bazate pe învățare profundă, decât în cazul aplicării metodelor convenționale. Aceste rezultate sunt diseminate în lucrările științifice “Kidney Tumor Segmentation and Grade Identification in CT Images”, prezentată la conferința 2023 *IEEE 19th International Conference on Intelligent Computer Communication and Processing (ICCP)*, Cluj-Napoca, 26-28 octombrie 2023, publicată în volumul conferinței, respectiv în lucrarea „Kidney tumor stage identification in CT images”, aflată în pregătire pentru jurnalul *IEEE Transactions on Medical Imaging (ISI, Q1)*.



**Figura 19.** Detecția tumorilor renale de grad 1 în cazul aplicării metodelor bazate pe învățare profundă: (a.) indicația medicului specialist radiolog („Ground Truth”); (b.) detecția prin CNN

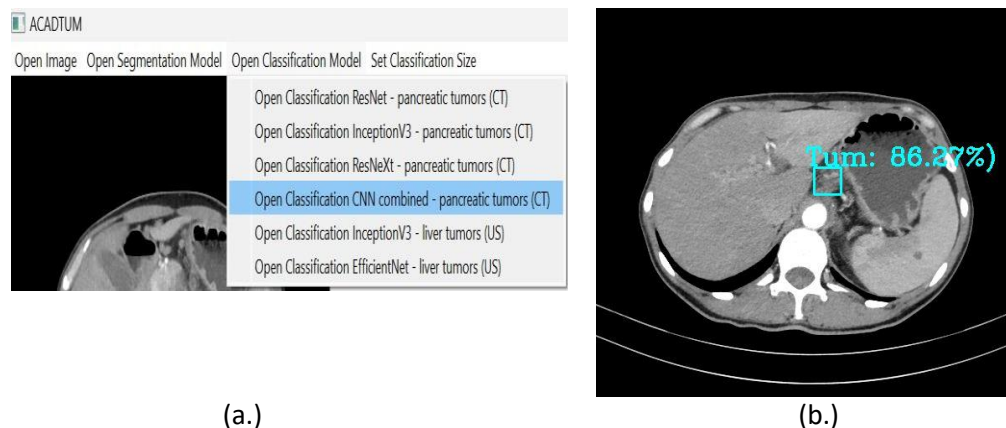
#### 4. Aplicația software ACADTUM

Aplicația software ACADTUM include două secțiuni principale: cea de segmentare, respectiv cea de recunoaștere a tumorilor abdominale. Partea de segmentare presupune integrarea celor mai performante rețele CNN, antrenate în vederea segmentării tumorilor abdominale, dar și în scopul detecției automate a stadiilor de evoluție pentru cancerul renal. Un exemplu relevant este ilustrat în Figura 20.



**Figura 20.** (a.) Meniul corespunzător funcțiilor de segmentare. (b.) Rezultatul segmentării conform funcției selectate (GradCAM)

Secțiunea corespunzătoare recunoașterii tumorilor abdominale pune la dispoziție cele mai performante metode destinate determinării automate a clasei de țesut: tumoră malignă, respectiv țesut de natură benignă, indicând prezența/absența cancerului abdominal. Utilizatorul trebuie să selecteze o regiune de interes rectangulară într-o zonă suspectă din imagine, să specifiche dimensiunile în pixeli ale acesteia, respectiv să activeze din meniu funcția dorită, care determină în mod automat clasa de țesut, conform ilustrării din Figura 21.



**Figura 21.** (a.) Meniul corespunzător funcțiilor de recunoaștere (clasificare). (b.) Rezultatul corespunzător funcției selectate

## 5. Diseminarea rezultatelor și indicatorii de rezultat obținuți

Rezultatele obținute în contextul proiectului ACADTUM, ilustrate succint în secțiunile precedente, au fost diseminate, conform planului de realizare, în lucrări prezentate la conferințe științifice internaționale de prestigiu și publicate în volumele aceluiași conferințe aflate în curs de indexare ISI Proceedings, în jurnale științifice de top (Q2), respectiv într-un capitol de carte, publicat la o editură internațională de prestigiu. De asemenea, s-a depus o propunere de brevet european la European Patent Office (EPO, <https://www.epo.org/en>). Acestea sunt detaliate în cele ce urmează:

- (1.) D. Mitrea, R. Brehar, S. Nedevschi, M. Platon-Lupsor, M. Socaciu, R. Badea, "Hepatocellular Carcinoma Recognition from Ultrasound Images Using Combinations of Conventional and Deep Learning Techniques", *Sensors*, Vol. 23, No. 5, 2023, <https://www.mdpi.com/1424-8220/23/5/2520>
- (2.) R. Brehar, D. Mitrea, S. Nedevschi, T. Moisoiu, F.I. Elec, M. Socaciu, "Kidney Tumor Segmentation and Grade Identification in CT Images", 2023 IEEE 19th International Conference on Intelligent Computer Communication and Processing (ICCP), Cluj-Napoca, 26-28 octombrie 2023, publicată în volumul conferinței (IEEE, Scopus, DBLP, în curs de indexare ISI)
- (3.) D. Mitrea, R. Brehar, C. Mocan, S. Nedevschi, M. Socaciu, R. Badea, "Hepatocellular carcinoma recognition from ultrasound images by fusing convolutional neural networks at decision level", The 46<sup>th</sup> International Conference on Telecommunications and Signal Processing (TSP 2023), 12-14 iulie 2023, Proceedings, (IEEE, Scopus, DBLP, în curs de indexare ISI)
- (4.) D. Mitrea, V. Timu, V. A. Florian, C. Mocan, S. Nedevschi, M. Socaciu, R. Badea, "Liver tumor segmentation from Computed Tomography images through Convolutional Neural Networks", The 2023 9th International Conference on Systems and Informatics (ICSAI 2023), 16-18 decembrie 2023, Changsha, China, Proceedings, [http://81.68.97.198/submission\\_icsai/ICSAI-2023-Proceeding.pdf](http://81.68.97.198/submission_icsai/ICSAI-2023-Proceeding.pdf) (IEEE, Scopus, DBLP, în curs de indexare ISI)
- (5.) D. Mitrea, R. Brehar, S. Nedevschi, M. Socaciu, R. Badea, "Hepatocellular Carcinoma recognition from ultrasound images through Convolutional Neural Networks and their combinations", International Conference on Advancements of Medicine and Health care through Technology (MediTech 2022) Cluj-Napoca, 20-22 octombrie 2022, IFMBE Proceedings, 2024, Volume 102, pp. 3-11, Springer, [https://link.springer.com/chapter/10.1007/978-3-031-51120-2\\_1](https://link.springer.com/chapter/10.1007/978-3-031-51120-2_1) (Scopus, în curs de indexare ISI)

- (6.) D. Mitrea, R. Brehar, R. Itu, S. Nedevschi, M. Socaciu, R. Badea, "Pancreatic Tumor Recognition from CT Images through Advanced Deep Learning Techniques", lucrare acceptata la conferința IEEE International Conference on Automation, Quality and Testing, Robotics (AQTR 2024), Cluj-Napoca, 16-18 mai 2024 (ISI Proceedings).
- (7.) D. Mitrea, R. Brehar, R. Itu, A.-V. Florian, M. Socaciu, T. Moisoiu, "Improving the Performance of Abdominal Tumors Diagnosis within Medical Images through the Combination of Conventional and Deep Learning Techniques", propunere de brevet depusă la European Patent Office (EPO), decembrie, 2023.
- (8.) D. Mitrea, S. Nedevschi, M. Socaciu, R. Badea, "Deep Learning Techniques for Liver Tumor Recognition in Ultrasound Images", capitol în cartea cu titlul "Deep Learning - Recent Findings and Researches", IntechOpen (<https://www.intechopen.com/online-first/deep-learning-techniques-for-liver-tumor-recognition-in-ultrasound-images>)
- (9.) R. Brehar, D. Mitrea, S. Nedevschi, T. Moisoiu, F.I. Elec, M. Socaciu, „Kidney tumor stage identification in CT images”, IEEE Transactions on Medical Imaging, în evaluare.

S-au obținut, astfel, următorii indicatori de rezultat:

- 1.) O lucrare științifică publicată în jurnalul Sensors (ISI, Q2)
- 2.) Patru lucrări științifice prezentate la conferințe internaționale de prestigiu, publicate în volumele acestor conferințe, fiind deja indexate în bazele de date IEEE, Scopus și DBLP, respectiv în curs de indexare în baza de date ISI Web of Science.
- 3.) O lucrare științifică acceptată la conferința internațională AQTR 2024, care va avea loc între 16-18 mai în Cluj-Napoca, România, aflată în curs de publicare în volumul conferinței, care va fi indexată în bazele de date IEEE, Scopus și ISI Web of Science.
- 4.) O propunere de brevet internațional (european) de tip European Patent Office (EPO)
- 5.) O lucrare științifică aflată în evaluare la un jurnal de top (ISI, Q1).

### **III. Impactul estimat al rezultatelor obținute, cu sublinierea celui mai semnificativ rezultat obținut.**

Metodele dezvoltate în contextul proiectului ACADTUM au condus la o îmbunătățire semnificativă a performanțelor de segmentare și recunoaștere a tumorilor abdominale pe baza imaginilor medicale de diferite tipuri, depășind realizările similare obținute în domeniu [19], [20], [21]. Conform obiectivului principal al proiectului (O), aceste metode au fost integrate în sistemul software ACADTUM, destinat diagnozei automate și asistate de calculator a tumorilor abdominale, acesta contribuind în mod semnificativ la procesul de diagnoză non-invazivă, automată și asistată de calculator, de maximă acuratețe și eficiență, a tumorilor abdominale. Rezultatele obținute indică faptul că performanțele de segmentare și recunoaștere datorate imaginilor de tip CT și IRM au fost în general superioare celor corespunzătoare imaginilor ultrasonografice, derivate în condiții echivalente. Acest fapt se datorează în principal clarității vizuale mai bune a imaginilor CT și IRM, care, în comparație cu imaginile ultrasonografice, sunt mai puțin afectate de zgomote specifice. Cu toate acestea, nu trebuie ignorat faptul că imaginile ultrasonografice conduc la o evaluare medicală non-invazivă, nepericuloasă (prin lipsa radiațiilor), de cost redus, a afecțiunilor abdominale, repetabilă în scopul unei monitorizări adecvate a evoluției afecțiunilor abdominale. Din acest motiv, s-a insistat asupra dezvoltării unor metode de maximă performanță privind recunoașterea tumorilor hepatice pe

baza imaginilor ultrasonografice, implicând combinarea metodelor convenționale cu cele bazate pe tehnica CNN, respectiv combinații ale rețelelor CNN la nivelul clasificatorului, precum și la nivel decizional, acesta constituind unul dintre cele mai importante rezultate ale acestui proiect. Comparația sistematică a acestor metode a fost ilustrată în capitolul II al acestui raport de cercetare, în cadrul secțiunii 2.1, fiind de asemenea diseminată în lucrările științifice [13], [14], [15], [16]. Astfel, a rezultat în final o acuratețe maximă de peste 98% privind recunoașterea tumorilor hepatice din imaginii ultrasonografice. Aceste demersuri s-au realizat în conformitate cu obiectivele  $O_1$  și  $O_2$  ale proiectului.

Un alt rezultat semnificativ a fost cel referitor la diagnoza automată și asistată de calculator a afecțiunilor preneoplazice, respectiv a formațiunilor tumorale aflate în stadiu incipient, implicând detecția nodulilor displazici dezvoltăți în cel mai avansat stadiu de ciroză, care pot evolua în tumori hepatice maligne de tip HCC, precum și a tumorilor HCC aflate în fază incipientă, respectiv a tumorilor renale de gradul 1. Metodele și rezultatele corespunzătoare au fost prezentate în cadrul Capitolului I, secțiunea 3, precum și în cadrul Capitolului II, secțiunea 3, respectiv diseminate în lucrarea științifică [12]. Aceste metode s-au dezvoltat în conformitate cu obiectivul  $O_3$  al proiectului. Acest subiect fiind de o importanță deosebită în scopul prevenției dezvoltării afecțiunilor canceroase, cercetările vor continua în această direcție, prin lărgirea seturilor de date imagistice, respectiv prin luarea în considerare și a altor afecțiuni, precum pancreatita cronică ce poate conduce la apariția cancerului pancreatic.

Întrucât atât bolile hepatice difuze, cât și pancreatita cronică, respectiv afecțiunile canceroase prezintă o importanță deosebită, afectând sănătatea umană în mod semnificativ, metodele dezvoltate în contextul acestui proiect vor fi consolidate și extinse prin integrarea unor tehnici specifice direcțiilor *domain adaptation learning*, implicând antrenarea clasificatorilor cu date aferente mai multor domenii adiacente [18], respectiv *continual learning*, implicând reantrenarea cu date actuale ale unor clasificatori antrenați anterior cu date din același domeniu [22]. În acest sens, au fost realizate propuneri de noi proiecte de cercetare implicând aplicarea tehnicilor de inteligență artificială în domeniul imagisticii medicale în contextul programelor *Hub Român de Inteligență Artificială (2023)*, respectiv *Centre de Excelență (CoEx 2024)*.

Realizările și rezultatele obținute în contextul proiectului ACADTUM sunt prezentate în manieră succintă pe web site-ul proiectului, la adresa <https://cv.utcluj.ro/acadtum/>.

### Referințe bibliografice:

- [1] H. S. Chatterjee, "Various Types of Convolutional Neural Networks", 2019. [Online]. Available: <https://towardsdatascience.com/mvarious-types-of-convolutional-neural-network-8b00c9a08a1b>.
- [2] O. Ronneberger, P. Fischer, T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation", International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, Vol. 9351, pp. 234-241, 2015.
- [3] Z. Zhou, M.M.R. Siddiquee, N. Tajbakhsh, J. Liang, "Unet++: A nested u-net architecture for medical image segmentation", In Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, Lecture Notes in Computer Science, Springer, Berlin/Heidelberg, Germany Volume 11045, pp. 3–11, 2018
- [4] L.C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, A. L. Yuille, "DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs", arXiv:1606.00915, 2016.
- [5] J. Wang, X. Liu, "Medical image recognition and segmentation of pathological slices of gastric cancer based on Deeplab v3+ neural network", *Computer Methods and Programs in Biomedicine* 2021, 207, 106210.

- [6] M. Bencevic, et al., "Training on polar image transformations improves biomedical image segmentation", *IEEE Access*, vol. 9, pp. 133 365–133 375, 2021.
- [7] S. Jadon, "A survey of loss functions for semantic segmentation", arXiv:2006.14822v4, 2020. [Online]. Available: <https://arxiv.org/pdf/2006.14822.pdf>
- [8] P. Bilic et al., "The liver tumor segmentation benchmark (LiTS)," *Medical Image Analysis*, vol. 84, p. 102680, Feb. 2023. [Online]. Available: <https://doi.org/10.1016%2Fj.media.2022.102680>.
- [9] L. Soler, et al., "3d image reconstruction for comparison of algorithm database: A patient specific anatomical and medical image database", 2010. Online. [Available]: <https://www-sop.inria.fr/geometrica/events/wam/abstract-ircad.pdf>
- [10] D. Mitrea, V. Timu, V. A. Florian, C. Mocan, S. Nedevschi, M. Socaciu, R. Badea, "Liver tumor segmentation from Computed Tomography images through Convolutional Neural Networks", The 2023 9th International Conference on Systems and Informatics (ICSAI 2023), 16-18 decembrie 2023, Changsha, China
- [11] Y. Xu, H. Lam, G. Jia, "MANet: A two-stage deep learning method for classification of COVID-19 from Chest X-ray images", *Neurocomputing*, Vol. 443, pp. 96-106, 2021
- [12] R. Brehar, D. Mitrea, S. Nedevschi, T. Moisoiu, F.I. Elec, M. Socaciu, "Kidney Tumor Segmentation and Grade Identification in CT Images", 2023 IEEE 19th International Conference on Intelligent Computer Communication and Processing (ICCP), Cluj-Napoca, 26-28 October, 2023
- [13] D. Mitrea, R. Brehar, S. Nedevschi, M. Lupsor-Platon, M. Socaciu, R. Badea, "Hepatocellular carcinoma recognition from ultrasound images using combinations of conventional and deep learning techniques", *Sensors*, Vol. 23, No. 5, pp. 1-29, 2023.
- [14] D. Mitrea, S. Nedevschi, M. Socaciu, R. Badea, "Deep Learning Techniques for Liver Tumor Recognition in Ultrasound Images", in book "Deep Learning - Recent Findings and Researches", IntechOpen (<https://www.intechopen.com/online-first/88353>)
- [15] D. Mitrea, R. Brehar, C. Mocan, S. Nedevschi, M. Socaciu, R. Badea, "Hepatocellular carcinoma recognition from ultrasound images by fusing convolutional neural networks at decision level", the 47<sup>th</sup> International Conference on Telecommunications and Signal Processing, 12-14 iulie 2023.
- [16] D. Mitrea, R. Brehar, S. Nedevschi, M. Socaciu, R. Badea, "Hepatocellular Carcinoma recognition from ultrasound images through Convolutional Neural Networks and their combinations", International Conference on Advancements of Medicine and Health care through Technology (MediTech 2022) Cluj-Napoca, 20-22 octombrie 2022, IFMBE Proceedings, 2024, Volume 102, pp. 3-11, Springer, [https://link.springer.com/chapter/10.1007/978-3-031-51120-2\\_1](https://link.springer.com/chapter/10.1007/978-3-031-51120-2_1)
- [17] D. Mitrea, R. Brehar, R. Itu, S. Nedevschi, M. Socaciu, R. Badea, "Pancreatic Tumor Recognition from CT Images through Advanced Deep Learning Techniques", lucrare acceptata la conferința IEEE International Conference on Automation, Quality and Testing, Robotics (AQTR 2024), Cluj-Napoca, 16-18 mai 2024
- [18] H. Guan, M. Liu, „Domain Adaptation for Medical Image Analysis: A Survey”, *IEEE Transactions on Biomedical Engineering*, Vol. 69, No. 3, pp. 1173–1185, 2022.
- [19] A. Aziz, et al. "An Ensemble of Optimal Deep Learning Features for Brain Tumor Classification". *Computers, Materials and Continua*, Vol. 69, No. 2, pp.2653 – 2670, 2021.
- [20] R. Paul, et al. "Predicting malignant nodules by fusing deep features with classical radiomics features", *Journal of Medical Imaging*, Vol. 5, No. 1, pp.011021-1 - 011021-11
- [21] Z. Zhang, S. Li, Z. Wang and Y. Lu, "A Novel and Efficient Tumor Detection Framework for Pancreatic Cancer via CT Images," The 42<sup>nd</sup> Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), 2020, pp. 1160-1164, doi: 10.1109/EMBC44109.2020.9176172.
- [22] P. Kumari, J. Chauhan, et al., "Continual learning in medical image analysis. A comprehensive review of recent advancements and future prospects", arXiv:2312.17004v2 [eess.IV] 22 Jan 2024

Director Proiect,

Conf. Dr. Ing. Delia-Alexandrina Mitrea

