

Raport de analiză a tehnologiilor inteligente de recunoaștere vizuală, dezvoltate în scopul evaluării creșterii biomasei sturionice și a celei de busuioc, în timp real, precum și pentru identificarea deficiențelor nutriționale (realizare parțială)

Pentru identificarea peștilor și a plantelor au fost folosite două abordări și anume: tehnici de Computer Vision și Deep Learning. Din categoria Computer Vision au fost explorate spațiile de culori pentru crearea de măști obiectelor. În primul rând, au fost identificate o serie de spații de culori, cele mai cunoscute în zona procesării de imagini, mai precis RGB, HSV, LAB, CMYK, YCrCb, XYZ. A fost selectată câte o imagine din fiecare set de date (pești și plante) și analizate canalele specifice fiecărui spațiu de culori. La final au fost păstrate doar prelucrările care ne ajutau la extragerea măștii. În final, ne-am oprit la două spații de culori. HSV, la care se extrag toți pixelii din imagine care se afla într-un interval de valori, și LAB, de la care au fost extrase dimensiunea L la pești și dimensiunea A la plante.




Fig. 28. Spațiile de culori HSV și LAB identificate la nivelul pozelor de biomasă sturionicolă și vegetală (busuioc) obținute în urma folosirii sistemului de observație imagistică

După cum se poate aprecia în imaginile de mai sus, metoda spațiului de culori ne ajută să extragem o mască cu toate obiectele din imagine, similară cu metodele de segmentare semantică (semantic segmentation) (fig. 28). Principalul neajuns al metodei este posibilitatea de apariție a zgomotului în imagine datorată mai multor factori (luminozitate, reflexie, obiecte de culoare asemănătoare, etc.).

Deep Learning - Învățarea profundă (cunoscută și sub numele de învățare profundă structurată sau învățare ierarhică) este parte dintr-o familie de metode de învățare automată bazată pe rețele neuronale artificiale. Învățarea poate fi supravegheată, semi-supravegheată sau nesupravegheată. Arhitecturile de învățare profundă au fost aplicate în diverse domenii, precum recunoașterea imaginilor, recunoașterea vocală, prelucrarea limbajului natural,

recunoașterea audio, filtrarea în rețele sociale, traducerea automată, bioinformatica, proiectarea de medicamente, analiza de imagini medicale, inspecția materialelor și divertisment, unde au obținut rezultate comparabile cu și, în unele cazuri, superioare experților umani.

Rețelele neuronale sunt sisteme flexibile și complexe care extrag modele din datele de intrare, cu scopul de a recunoaște mai târziu obiectele respective. Conceptul de rețea neuronală este asemănător creierului uman, acest tip de rețele fiind proiectate pe aceeași structură ca acesta. Rețeaua poate fi privită ca un ansamblu de neuroni legați între ei, similar unei structuri de tip graf orientat. *Transfer learning* este o tehnică de învățare profundă prin care o rețea neuronală dezvoltată anterior este antrenată pentru o nouă sarcină. De exemplu, dorim să instruiem o rețea neuronală care să recunoască caii, însă nu există algoritmi disponibili pentru așa ceva. Tot ce avem de făcut este să luăm o rețea neuronală antrenată pentru recunoașterea altor animale și să o punem la antrenat pentru a recunoaște caii. Modul de funcționare este foarte ușor. Se elimină ultimul strat numit "loss output" care este stratul final ce face prezicerea. Acest strat va fi înlocuit de un nou strat de ieșire ce va identifica noua clasă. Tot ceea ce mai avem de făcut este să punem setul de date adnotat și să pornim recalibrarea rețelei astfel încât să identifice clasa noastră. Această tehnică nu este destinată doar pentru recunoașterea imaginilor, ci și pentru recunoașterea vorbirii sau alte rețele de tip recurente (RNN - Recurrent Neural Network).




Fig. 29. Exemple de măști create pentru biomasa sturionicolă și cea vegetală, folosind conținutul imagistic prelevat cu ajutorul modulului imagistic de observație

Un avantaj al transfer learning-ului, față de antrenarea unei rețele neuronale de la 0, este timpul de antrenare care se reduce considerabil. De asemenea, această tehnică este indicată și atunci când avem insuficiente date. *MMDetection* este un *toolbox* open source pentru cercetare academică și aplicații industriale bazată pe PyTorch. Este oferit de OpenMMLab care acoperă o gamă largă de subiecte de cercetare privind viziunea

computerizată, de exemplu, clasificarea, detectarea, segmentarea și super-rezoluția. Printre caracteristicile majore se numără suport pentru multiple arhitecturi de rețea (RCNN, Mask RCNN, RetinaNet etc.), eficiență ridicată pe GPU în sarcinile de detecție de tip bbox(chenare) și mask (viteza de antrenament este mai rapidă sau comparabilă cu alte baze de cod, inclusiv Detectron2, maskrcnn-benchmark și SimpleDet). Acest *toolbox* provine din baza de cod dezvoltată de echipa MMDet, care a câștigat COCO Detection Challenge în 2018, și continuă să o dezvolte. Din acest *toolbox* am selectat algoritmul YOLACT care realizează segmentarea instanțelor și returnează chenarul și masca obiectelor. YOLACT (fig.30): Bolya et al., 2020, vin cu un algoritm de instances segmentation. Autorii au împărțit sarcina complexă de segmentare a instanței în două sarcini mai simple, paralele, care pot fi asamblate pentru a forma măștile finale (fig.29). Rețeaua este alcătuită din următoarele componente: *Prototype Generation* - ramura de generare a prototipului (protonet) prezice un set de k măști prototip pentru întreaga imagine; *Mask Coefficients* - ramura de detectare a obiectelor, bazat pe ancore utilizată pentru prezicerea confidenței clasei și a 4 casete de regresie; *Mask Assembly* - pasul de asamblare al măștii; *Assembly Steps* – se combină prototipurile de măști și coeficienți rezultând o matrice; *Losses* – se folosesc 3 tipuri de funcții de pierdere: classification loss L_{cls} , box regression loss L_{box} și mask loss L_{mask} ; *Cropping Masks* – atât în timpul antrenării, cât și în timpul detecției masca este decupată/tăiată utilizând caseta de delimitare (bounding box). Rezultatele oficiale furnizate de autori nu sunt cele mai bune (fig.31), însă sunt promițătoare dacă se ia în considerare viteza de procesare crescută față de ceilalți algoritmi.




Fig. 30. Exemplu de arhitectură YOLACT

Method	Backbone	FPS	Time	AP	AP ₅₀	AP ₇₅	AP _S	AP _M	AP _L
PA-Net [29]	R-50-FPN	4.7	212.8	36.6	58.0	39.3	16.3	38.1	53.1
RetinaMask [14]	R-101-FPN	6.0	166.7	34.7	55.4	36.9	14.3	36.7	50.5
FCIS [24]	R-101-C5	6.6	151.5	29.5	51.5	30.2	8.0	31.0	49.7
Mask R-CNN [18]	R-101-FPN	8.6	116.3	35.7	58.0	37.8	15.5	38.1	52.4
MS R-CNN [20]	R-101-FPN	8.6	116.3	38.3	58.8	41.5	17.8	40.4	54.4
YOLACT-550	R-101-FPN	33.5	29.8	29.8	48.5	31.2	9.9	31.3	47.7
YOLACT-400	R-101-FPN	45.3	22.1	24.9	42.0	25.4	5.0	25.3	45.0
YOLACT-550	R-50-FPN	45.0	22.2	28.2	46.6	29.2	9.2	29.3	44.8
YOLACT-550	D-53-FPN	40.7	24.6	28.7	46.8	30.0	9.5	29.6	45.5
YOLACT-700	R-101-FPN	23.4	42.7	31.2	50.6	32.8	12.1	33.3	47.1

Fig. 31. Rezultate YOLACT – documentația oficială

Algoritmul pentru determinarea creșterii sturionilor: Pentru a calcula indicele de creștere în suprafață al peștilor s-a pornit de la ideea de identificare a fiecărui exemplar de sturion care apare în regiunea de interes din bazin (peretele bazinului și plexiglas). Formula de calcul a indicelui de creștere se bazează pe suprafața în pixeli a fiecărui exemplar de sturion corelată cu distanța medie până la pește, distanța fiind identificată cu camera Intel RealSense. Un prim pas pentru calcularea indicelui de suprafață al peștilor îl reprezintă identificarea fiecărui

sturion din imagine: pentru a identifica fiecare pește care apare în imagine a fost antrenată o rețea neuronală folosind algoritmul YOLACT pus la dispoziție de MMDetection. Rețeaua a fost antrenată pe 600 epoci folosind arhitectura ResNet101. Pentru a obține rezultate mai rapide, am folosit transfer learning utilizând o rețea pre-antrenată oferită public de PyTorch. În urma antrenării, se poate aprecia faptul că rețeaua oferă chenare și măști cu o precizie încurajatoare. În fig. 32 se poate observa că rezultatele nu sunt foarte exacte, fapt ce indică necesitatea suplimentării exemplelor adnotate din setul de date. După creșterea setului de date și adnotarea imaginilor vom continua antrenarea rețelei pentru a obține rezultate mult mai precise. Rezultatele complete ale antrenării se regăsesc în Anexa 5.1.



Fig. 32. Chenare și măști la nivelul biomasei sturionice, folosind metoda transfer learning



Fig. 33. Utilizarea măștilor folosind spațiul de culori - dimensiunea L din LAB

Al doilea pas necesar a fi parcurs pentru calcularea indicelui de suprafață al peștilor îl reprezintă crearea unei măști pentru fiecare pește în parte. Astfel, pentru calcularea suprafeței peștelui este necesară masca fiecărui exemplar din imagine. Deoarece masca oferită de rețea nu a dat rezultatele cele mai bune, am ales utilizarea unei măști folosind spațiul de culori, mai precis dimensiunea L din LAB (fig. 33). În imaginea cu mască se observă că, pe lângă măștile exacte cu pești, apar și elemente de zgomot. Pentru a le înlătura, a fost selectată din fiecare imagine doar regiunea unde se află peștele, regiune selectată cu ajutorul coordonatelor oferite de rețeaua neuronală.

Formula de calcul pe care am utilizat-o este una relativ simplă. Pentru fiecare exemplar detectat am extras masca, după care am numărat câți pixeli apar în acea mască. Utilizând informațiile de adâncime oferite de camera Intel RealSense și masca, am rulat o operație de tip Bitwise AND și am extras distanța medie până la pește utilizând doar

informațiile de adâncime din interiorul măștii. Rezultatul acestei operații este un indice de suprafață pentru fiecare pește (tab.1).

Tab.1. Indicele de suprafață a materialului sturionicol - LAB reprezintă calculul efectuat cu masca de la spațiul de culori, NN reprezintă calculele efectuate cu masca de la rețeaua neuronală (Neural Network)

Data	B3			
	LAB		NN	
	Exemplare	AVG	Exemplare	AVG
06-11-2021	4552	5695.32	4552	4799.96
17-11-2021	3218	4066.09	3220	4570.89
24-11-2021	3700	4425.39	3699	5129.96
30-11-2021	3144	4712.21	3144	5465.89

Validarea rezultatelor: Biomasa sturionicolă aferentă unității de creștere la nivelul căreia a fost calculat indicele de suprafață cu ajutorul tehnicilor LAB și NN a înregistrat următoarea dinamică a creșterii, identificată prin cântăriri *in situ*: 599g în 06.11.2021; 874g în 17.11.2021; 1043 g în 24.11.2021; 1134g în 30.11.2021. Astfel, se identifică următoarele procente de creștere: 45,90%; 19,34%; 8,72%. Se observă faptul că indicele calculat prin LAB, respectiv NN înregistrează o evoluție negativă în prima parte a perioadei experimentale (06 – 17.11.2021). Acest lucru indică necesitatea calibrării sistemului imagistic, cât și cerința acomodării materialului sturionicol cu noile condiții din cadrul unității de creștere, survenite ca urmare a poziționării peretelui septat. Astfel, exemplarele de sturioni trebuiesc obișnuite cu prezența peretelui separator și cu modalitatea de tranzitare a acestuia, fapt posibil prin administrarea furajului pe toată lungimea suprafeței delimitate. Considerând perioada 17-24.11.2021, respectiv 24-30.11.2021, putem afirma faptul că indicele de suprafață a materialului sturionicol a înregistrat o creștere cu 8,83%, respectiv 6,48%, folosind metoda LAB și 12,23%, respectiv 6,54% folosind metoda NN. Astfel, metoda NN este cea mai precisă în acest context, modelul liniar pentru determinare a sporului de biomasă pentru perioada 17-24.11.2021 fiind $y = x + 7,11$, unde y este indicele de suprafață corectat și x este indicele de suprafață real, în timp ce pentru perioada 24-30.11.2021 avem $y = x + 2,18$. Modelele liniare de corecție în cazul folosirii LAB devin $y = x + 10,51$ pentru perioada 17-24.11.2021, respectiv $y = x + 2,26$.

Algoritmul pentru determinarea creșterii plantelor (înălțime și suprafață): În problema de monitorizare a creșterii plantelor au fost urmărite creșterea în înălțime și în suprafața a busuiocului. Aceste două probleme au avut același parcurs de procesare,

exceptând formula de calcul de la final. Primul pas de calcul este reprezentat de identificarea plantelor. La fel ca în problema detectării peștilor, am ales utilizarea algoritmului YOLACT. Rețeaua a fost antrenată pe 1000 de epoci, utilizând o rețea pre-antrenată pe arhitectura ResNet101. Rezultatul antrenării este o rețea care identifică plantele cu o acuratețe destul de bună (fig. 34). Și în acest caz setul de date joacă un rol important în precizia cu care rețeaua detectează plantele și le construiește măștile. Pentru a avea rezultate mai bune, setul de date va fi îmbogățit cu alte imagini care vor fi adnotate. Rezultatele complete ale antrenării se regăsesc în Anexa 5.2.



Fig. 34. Identificarea plantelor folosind algoritmul YOLACT



Fig. 35. Crearea măștilor pentru biomasa de busuioc

Al doilea pas este reprezentat de crearea măștilor. Astfel, pentru calcularea suprafeței și a înălțimii trebuie identificată masca, mai precis zona unde se află fiecare plantă. În fig. 35 observăm că măștile sunt destul de cuprinzătoare la plante, însă nu sunt exacte. În timpul experimentelor preliminare realizate, am constatat că masca poate urmări conturul cu o precizie bună, însă nu elimină și golurile din interiorul plantei. Acest lucru poate afecta calculele noastre, așadar am luat în considerare realizarea unei măști utilizând spațiul de culori LAB. Prin combinarea celor două măști, se poate realiza o mască mult mai exactă care elimină golurile din interior (cu ajutorul măștii generate cu spațiul de culori LAB) și în același timp înlătură elementele de zgomot care pot apare (utilizând segmentarea realizată de rețeaua neuronală).

Al treilea pas este reprezentat de procesul de stabilire a formulelor de calcul. Formulele de calcul (cea pentru suprafață și cea pentru înălțime) se bazează pe ideea de

combinare a măștii cu informațiile de adâncime (depth). Deoarece există posibilitatea ca suprafața plantei să se mărească în timp ce numărul de pixeli scade, a fost luat în calcul crearea a două formule, una bazându-se doar pe numărul de pixeli verzi din imagine (calculați cu ajutorul măștii), iar a doua luând în considerare și distanța medie până la plantă. Se ia în considerare faptul că modulul imagistic a detectat o distanță de 0,88 m până la substratul de creștere a plantelor. Rezultatul acestei operații este un indice de suprafață pentru fiecare unitate acvaponică testată (A, respectiv B) (tab.2).

Tab.2. Indicele de suprafață și înălțimea biomasei de busuioc

Data	B3									
	A					B				
	inaltime		suprafata			inaltime		suprafata		
		0.88	nr. pixeli	avg	(0.88-avg)*nr. pixeli		0.88	nr. pixeli	avg	(0.88-avg)*nr. pixeli
05-11-2021	0.79	0.09	34733	0.84	1409.43	0.79	0.09	42219	0.84	1559.24
15-11-2021	0.78	0.10	54959	0.85	1726.99	0.77	0.11	69975	0.84	3061.67
18-11-2021	0.76	0.12	96025	0.86	1835.15	0.75	0.13	113372	0.84	4251.25
22-11-2021	0.75	0.13	93989	0.83	5044.22	0.73	0.15	116866	0.83	6336.60
25-11-2021	0.73	0.15	125571	0.83	5793.79	0.71	0.17	154669	0.83	8183.23
30-11-2021	0.73	0.15	137870	0.82	7896.56	0.70	0.18	162002	0.82	9850.01

Validarea rezultatelor: Biomasa vegetală din cadrul A a înregistrat următoarele valori ale lungimii totale maxime a părții aeriene: 9,97 cm (05.11); 16 cm (15.11); 18cm (18.11); 19,5 cm (22.11); 19 cm (25.11); 20 cm (30.11). S-au identificat următoarele variații procentuale: 60,48% (perioada 5-15.11), 12,5% (15-18.11), 8,33% (18-22.11), -2,56% (22-25.11), 5,26%(25-30.11). Variațiile procentuale reliefate de datele prezentate în cadrul tab.2 sunt următoarele 11,11% (perioada 5-15.11), 20% (15-18.11), 8,33% (18-22.11), 15,38% (22-25.11), 0%(25-30.11). Se identifică următoarele modele liniare de corecție: $y = x + 49,37$ (perioada 5-15.11); $y = x - 7,5$ (15-18.11), $y = x$ (18-22.11), $y = x - 17,94$ (22-25.11), $y = x + 5,26$ (25-30.11). Biomasa vegetală din cadrul A a înregistrat următoarele valori ale suprafeței foliare: 690,28 cm² (05.11); 1084,5 cm² (15.11); 1540,5 cm² (18.11); 1933,5 cm² (22.11); 2158 cm² (25.11); 2775,54 cm² (30.11). S-au identificat următoarele variații procentuale: 57,11% (perioada 5-15.11), 42,4% (15-18.11), 25,51% (18-22.11), 11,61% (22-25.11), 28,61%(25-30.11). Variațiile procentuale reliefate de datele prezentate în cadrul tab.2 sunt următoarele 22,53% (perioada 5-15.11), 6,26% (15-18.11), 174,87% (18-22.11), 14,86% (22-25.11), 36,29% (25-30.11). Se identifică următoarele modele liniare de corecție: $y = x + 34,57$ (perioada 5-15.11); $y = x + 35,78$ (15-18.11), $y = x - 149,35$ (18-22.11), $y = x - 3,24$ (22-25.11), $y = x - 7,67$ (25-30.11).

Biomasa vegetală din cadrul B a înregistrat următoarele valori ale lungimii totale maxime a părții aeriene: 11,39 cm (05.11); 16,5 cm (15.11); 18cm (18.11); 20 cm (22.11); 20

cm (25.11); 30 cm (30.11). S-au identificat următoarele variații procentuale: 44,86% (perioada 5-15.11), 9,09% (15-18.11), 11,11% (18-22.11), 0% (22-25.11), 50%(25-30.11). Variațiile procentuale reliefate de datele prezentate în cadrul tab.2 sunt următoarele 22,22% (perioada 5-15.11), 18,18% (15-18.11), 15,38% (18-22.11), 13,33% (22-25.11), 5,88% (25-30.11). Se identifică următoarele modele liniare de corecție: $y = x + 22,64$ (perioada 5-15.11); $y = x - 9,09$ (15-18.11), $y = x - 4,27$ (18-22.11), $y = x - 13,33$ (22-25.11), $y = x + 44,12$ (25-30.11). Biomasa vegetală din cadrul B a înregistrat următoarele valori ale suprafeței foliare: 718,32 cm² (05.11); 1088,54 cm² (15.11); 1532,24 cm² (18.11); 1812 cm² (22.11); 2530,58 cm² (25.11); 3028,72 cm² (30.11). S-au identificat următoarele variații procentuale: 51,53% (perioada 5-15.11), 40,76% (15-18.11), 18,25% (18-22.11), 39,65% (22-25.11), 19,68% (25-30.11). Variațiile procentuale reliefate de datele prezentate în cadrul tab.2 sunt următoarele 96,35% (perioada 5-15.11), 38,85% (15-18.11), 49,05% (18-22.11), 29,14% (22-25.11), 20,37% (25-30.11). Se identifică următoarele modele liniare de corecție: $y = x - 44,82$ (perioada 5-15.11); $y = x + 1,91$ (15-18.11), $y = x - 30,79$ (18-22.11), $y = x + 10,51$ (22-25.11), $y = x - 7,670,68$ (25-30.11).