

1. Design tehnic al modulelor acvaponice, impus de exigențele necesare implementării tehnicii acvaponice cu substrat inovativ, sustenabil.

Integrarea modulelor acvaponice în cadrul sistemelor de producție acvicolă deja existente presupune o riguroasă proiectare astfel încât acestea să corespundă dezideratului tehnologic asumat. Astfel, proiectarea acestora este condiționată de exigențele de creștere a biomasei vegetale, calitatea apei tehnologice din cadrul sistemului de producție acvicolă, valoarea economică asumată a investiției, cât și de existența unui sistem automat de monitorizare și control la nivelul facilității piscicole. Drept urmare, se pot identifica modalități de proiectare a modulelor acvaponice în regim hidraulic continuu și intermitent, cu sau fără elemente de automatizare, confecționate din materiale accesibile financiar (lemn acoperit cu folie impermeabilă) sau din materiale mai rezistente în timp, în cadrul procesului de exploatare (inox), cu sistem de iluminat simplu, acționat manual, sau sistem de iluminat automatizat. Prezentul capitol este structurat în trei subcapitole ce comprimă toate variantele constructive descrise anterior.

1.1. Variante de design tehnic al unităților acvaponice fără integrarea elementelor de automatizare

Unitățile acvaponice construite în vederea aplicării tehnici acvaponice pe substrat de creștere au capacitatea ridicată de bioremediere, acestea fiind folosite și drept filtre biologice propriu-zise sau auxiliare. Drept urmare, substratul de creștere a plantelor este activat în vederea asigurării procesului de oxidare a amoniului, rezultat în urma procesului de creștere a biomasei piscicole, în nitriți, respectiv a nitriților în nitrați. Acest proces de oxidare necesită un anumit aport continuu de oxigen dizolvat, situație ce impune montarea unor linii de aerare la nivelul coloanei de substrat din cadrul unității acvaponice. Astfel, în condițiile în care exigențele de creștere a biomasei vegetale permit menținerea continuă în stare de imersie a întregii suprafețe radiculare a acesteia, de-a lungul întregului proces de creștere, și există disponibilitate financiară pentru integrarea liniilor de aerare anterior menționate, la nivelul substratului, o primă variantă constructivă a unităților acvaponice este cea prezentată în figura 1. Astfel, secțiunea longitudinală a unității de creștere (figura 1) indică prezența unei conducte de evacuare ce asigură un nivel al apei contant, în condițiile unui regim permanent de submersie a substratului de creștere. Partea interioară a conductei de evacuare este încadrată de o conductă din polipropilenă, prevăzută cu multiple orificii (2mm în diametru) în partea inferioară (figura 1). Aceasta are rolul de a separa partea superioară a conductei de evacuare de substratul de creștere folosit. De asemenea, un alt rol al conductei de separare este acela de a facilita evacuarea masei de apă din zona inferioară a unității acvaponice, în detrimentul celei prezente în zona superioară, fapt ce determină un anumit echilibru nutrițional la nivelul unității acvaponice. Alte variante constructive ce implică realizarea acestui tip de unitate acvaponică în regim hidraulic continuu sunt prezentate în cadrul Anexei 1, respectiv Anexa 2. Anexa 1 a prezentului raport descrie în mod detaliat soluția constructivă de realizare a unităților acvaponice din lemn, acestea urmând a fi acorite cu membrană HDPE. Astfel, în mod punctual, se pornește de la dezideratul asigurării unei suprafețe de creștere a biomasei vegetale de $2,4 \text{ m}^2/\text{unitatea de creștere}$, respectiv un volum de $0,36 \text{ m}^3$, un timp hidraulic de retenție de 15 minute, în condițiile asigurării unui debit de alimentare de $1,44 \text{ m}^3/\text{h}$, rată de încărcare hidraulică de $0,6 \text{ m}^3/\text{m}^2$. Anexa 2 a prezentului raport descrie în mod detaliat soluția constructivă de realizare a unităților acvaponice din inox alimentară. Astfel, în mod punctual, se pornește de la dezideratul asigurării unei suprafețe de creștere a biomasei vegetale de $2,5 \text{ m}^2/\text{unitatea de creștere}$, respectiv un volum de $0,375 \text{ m}^3$, un timp hidraulic de retenție de 15 minute, în condițiile asigurării unui debit de alimentare de $1,5 \text{ m}^3/\text{h}$, rată de încărcare hidraulică de $0,6 \text{ m}^3/\text{m}^2$.




Figura 1. Secțiune longitudinală unitate acvaponică cu regim hidraulic continuu




Figura 2. Secțiune longitudinală unitate acvaponică cu regim hidraulic intermitent (I, II – variante constructive ale dispozitivului tip sifon „siphon bell”)

A doua variantă constructivă (figura 2) răspunde la dezideratul ce presupune asigurarea unui regim hidraulic intermitent. Asigurarea acestui regim hidraulic este motivată de necesitățile tehnologice specifice speciei de biomasă vegetală (busuioc) vizată spre a fi cultivată. Astfel, asigurarea unui grad intermitent de submersie poate înlocui complet costurile generate de montarea liniilor de aerare la nivelul coloanei de substrat de creștere și utilizarea acestora de-a lungul întregului ciclu de producție. Astfel, aerarea substratului se realizează cu intermitență, prin intermediul oxigenului din atmosferă, în momentul scăderii nivelului apei din cadrul unității acvaponice. În vederea realizării regimului hidraulic intermitent, o lărgire de secțiune este aplicată asupra părții superioare a conductei, urmată de o îngustare a secțiunii aplicată părții inferioare a

conductei (figura 2). Această caracteristică constructivă determină accentuarea efectului de sorbție în timpul procesului de evacuare. Față de varianta cu regim hidraulic continuu, unitatea acvaponică cu regim intermitent dispune și de dispozitiv tip sifon „siphon bell”. Variantele constructive luate în considerare pentru realizarea acestui dispozitiv sunt prezentate în figura 2 (I și II). Astfel, prima varianta (figura 2, I) presupune confecționarea dispozitivului sub forma unui recipient cilindric, închis etanș în partea superioară, în timp ce în partea inferioară acesta este prevăzut cu fante pentru controlul nivelului minim al apei. A doua variantă constructivă (figura 2 II) presupune eliminarea fantelor menționate anterior și înlocuirea acestora cu un tub lateral, inserat în corpul cilindrului, ce oferă o posibilitate mai versatilă de control a nivelului minim din cadrul unității avaponice. În momentul scăderii nivelului apei tehnologice sub cel al fantelor/bazei tubului, aerul pătrunde în interiorul instalației și determină oprirea procesului de evacuare până în momentul în care nivelul apei din unitatea acvaponică depășește nivelul părții superioare a conductei de evacuare.

1.2. Variante de design tehnic al unităților acvaponice cu integrarea elementelor de automatizare

Automatizarea modulelor acvaponice în vederea controlului activ a nivelului apei din cadrul unităților de creștere a biomasei vegetale reprezintă o soluție modernă, menită să asigure în permanență nevoile tehnologice ce implică gradul de imersie a suprafeței radiculare. Astfel, comparativ cu soluțiile prezentate în cadrul subcapitolului 1.1., folosirea unui design pentru unitățile acvaponice, bazat pe control automatizat a nivelului apei, oferă avantajul posibilității de a optimiza tehnologia de creștere prin asigurarea gradului de imersie optim, aferent fiecărui stadiu de cultură a busuiocului. În acest fel, se generează premisa conform căreia optimizarea tehnologică anterior menționată poate spori performanța de creștere a busuiocului și, drept urmare, poate maximiza capacitatea de bioremediere a acestuia.

În figura 3 este prezentată o soluție de control automat a nivelului apei în cadrul unităților acvaponice prin intermediul variației debitului de alimentare al acestora. Această soluție automatizată constă în echipament hardware suplimentar, urmat de realizarea unei componente software. Echipamentul hardware propus este alcătuit din: 1. convertizor de frecvență, prin intermediul căruia se controlează turația pompei și implicit debitul de apă care ajunge din unitatea de creștere a peștilor în cea acvaponică; 2. senzori de nivel maxim și nivel minim, prin intermediul acestora se va monitoriza nivelul apei din unitatea acvaponică și totodată aceștia vor da comandă pentru creșterea sau descreșterea turației pompei rezultând astfel modificarea debitului de apă; 3. automat programabil, pe această componentă electronică se va implementa programul de control al debitului și nivelului apei din unitatea acvaponică. Componenta software, după cum am menționat mai sus, se va implementa pe automatul programabil. Acest program de control se va baza pe informațiile primite de la cei doi senzori de nivel maxim și minim. Atunci când nivelul apei se află la minim pompa va avea turație maximă, deci debit mare, iar pe măsură ce nivelul apei se apropie de cota maximă, turația pompei va fi din ce în ce mai mică, până va ajunge la minim, astfel încât să se asigure un minim de recirculare a apei ce urmează să contribuie la menținerea bunăstării materialului piscicol și, totodată, să se mențină nivel optim necesar creșterii biomasei vegetale aflată într-un anumit stadiu de dezvoltare.

1.3. Sistemul de iluminat din cadrul modulului acvaponic

În vederea asigurării unei dezvoltări optime a biomasei vegetale și, drept urmare, pentru asigurarea eficienței fitoremedierii, se impune o soluție automatizată de control în timp real, de-a lungul întregului ciclu de producție, a fotoperiodicității, respectiv a intensității luminoase. Sistemul automatizat are drept punct de plecare informațiile furnizate de modulul de analiză imagistică, descris în cadrul următoarelor secțiuni ale prezentului raport științific. Pe baza acestor informații, cât și prin utilizarea unui microcontroler, se va comanda un variator de tensiune (V.T), ce are ca rol de a modifica tensiunea de alimentare a lămpilor și implicit intensitatea luminii (figura 4). Reglarea activă a fotoperiodicității se va realiza pe baza informațiilor primite de la modulul de analiza imagistică al plantelor. Pe baza acestor informații și a unui microcontroler se va comanda în mod ON/OFF starea lămpilor pe o anumită durată de timp. Comanda de la microcontroler la lămpi se va realiza prin intermediul unui releu cu două stări, închis/deschis (ON/OFF).




Figura 3. Arhitectura propusă pentru controlul automat al debitului și nivelului apei dintr-o unitate acvaponică




Figura 4. Sistem de control automat al luminii pentru unitățile acvaponice

2. Design sistem multi-trofic de productie, prin integrarea modulelor acvaponice

În ceea ce privește modul de amplasare a unităților acvaponice în cadrul unui sistem recirculante de producție acvacolă, deja existent, se identifică două posibile variante de design (figura 5, figura 6).

Astfel, poziționarea modulelor acvaponice în plan superior unităților de creștere a biomasei piscicole și construcția, în această manieră, a unei noi bucle de recirculare, pe lângă cea existentă în cadrul sistemului recirculant de acvacultură (RAS), reprezintă prima variantă de design propusă (figura 5). Această variantă de sistem integrat decuplat are drept avantaj versatilitate și ușurința integrării în cadrul unui RAS deja existent. De asemenea, posibilitatea de a condiționa apa tehnologică înainte ca aceasta să părăsească unitatea de creștere reprezintă un alt avantaj adus către RAS. Posibilitatea menținerii în stare de funcțiune a sistemului de producție, de-a lungul unor perioade mici de timp, în condițiile apariției unor disfuncționalități în cadrul RAS sau pentru mentenanța anumitor unități componente ale acestuia, reprezintă un alt avantaj atribuit design-ului prezentat în figura 5. Principalele dezavantaje sunt legate de colmatarea substratului de creștere întrucât apa tehnologică nu este supusă unui proces anterior de filtrare mecanică, aceasta fiind preluată prin intermediul unei pompe submerse, poziționată la nivelul inferior al unității de creștere a biomasei piscicole. Drept urmare, posibile probleme legate de mentenanța frecventă a unui sistem integrat, bazat pe design-ul prezentat în figura 5, pot apărea ca urmare a scăderii ratei de bioremediere la nivelul substratului de creștere a plantelor, încetinirii ratei de creștere a biomasei vegetale, posibila apariție a unor afecțiuni manifestate la nivelul radicular al biomasei vegetale, posibila funcționare defectuoasă a pompei submerse ca urmare a aspirației unei cantități semnificative de reziduuri metabolice și hrană neconsumată, precum și îngreunarea capacității de eliminare a solidelor, în timp cât mai scurt, din cadrul unității de creștere în contextul apariției unui curent turbionar provocat de evacuarea masei de apă, pe cale gravitațională, din cadrul unităților acvaponice, direct în unitatea de creștere.

A doua variantă de design propusă (figura 6) constă în cuplarea unităților acvaponice, împreună cu cele de creștere a biomasei piscicole, în cadrul aceleiași bucle de recirculare. Această variantă asigură o disponibilitate mai mare a nitratilor la nivelul biomasei vegetale, împiedică pătrunderea solidelor la nivelul substratului de creștere, asigură o sedimentare a apei evacuate din cadrul unităților acvaponice, împiedicând pătrunderea eventualelor resturi provenite din rizosfera plantelor să ajungă în unitatea de creștere, asigură o mai bună mineralizare la nivelul unităților de sedimentare anterior menționate, împiedică eventualele disfuncționalități ale debitului de alimentare, provocate de încărcarea pompelor cu reziduuri metabolice și, de asemenea, oferă o perioadă mai lungă de funcționalitate, fără mentenanță generală, precum în cazul variantei de design anterior menționate. Drept dezavantaj, varianta de design prezentată în figura 6 asigură o integrare mai dificilă în cadrul unui RAS deja existent, fiind direct dependentă de funcționalitatea recirculării din cadrul sistemului de producție a biomasei piscicole.

Cele două variante prezentate anterior sunt integrate în design-ul existent al sistemului de producție piscicolă a beneficiarului prezentului proiect. Astfel, Anexa 3 a prezentului raport detaliază planul și schema situației existente în prezent la ferma SC SILURUS MARKET SRL. Astfel, se observă faptul că, la nivelul halei se disting cele două sisteme recirculante de producție pentru creșterea puietului (compus din 12 bazine PVC cu volum total de 24 m³, respectiv pentru creșterea materialului piscicol în stadiile ulterioare de creștere (compus din 16 bazine de beton cu un volum total de 640 m³). În cadrul planului de situație prezentat în Anexa 3 s-au elaborat cinci posibile variante de design, fiecare având particularități constructive diferite în ceea ce privește modul de integrare a modulului acvaponic și tipul/mărimea unităților acvaponice folosite (Anexa 4, Anexa 5, Anexa 6, Anexa 7, Anexa 8).





Figura 5. Design sistem multi-trofic de productie cu două bucle de recirculare (sistem decuplat)

Drept urmare, Anexa 4 prezintă planul și schema funcțională pentru varianta de integrare a modului acvaponic la sistemul recirculant de creștere a puietului deja existent, folosind varianta constructivă de unități acvaponice confecționate din lemn, acoperite cu membrana HDPE. Integrarea modului acvaponic se face după sistemul biologic de filtrare a apei, respectând pe cât posibil dezideratul ce presupune evacuarea gravitațională a apei tehnologice din cadrul acestuia, în unitățile de creștere a puietului. Anexa 5 prezintă același mod de amplasare a modului acvaponic descris și în cadrul Anexei 4, folosind principiul de design al sistemului multi-trofic de producție cu o buclă de recirculare (sistem cuplat), expus în cadrul figurii 6. Anexa 6 prezintă secțiunea transversală a variantei constructive prezentate în cadrul Anexei 5, punctând diferențele de nivel dintre poziționarea modului acvaponic și cea a unității biologice de condiționare a apei, respectiv a unității de creștere a puietului.

Anexa 7 și anexa 8 prezintă amplasarea modului acvaponic, folosind varianta de design expusă în figura 6, în cadrul sistemului de creștere a materialului piscicol trecut de primele stadii de dezvoltare. Soluția prevede colectarea apei tehnologice de la nivelul unității biologice de condiționare, pe cale gravitațională și evacuarea acesteia, de la nivelul modului acvaponic, folosind o pompa de recirculare.

Soluția de design prezentată în cadrul figurii 5 este transpusă la nivelul sistemului recirculant de creștere a biomasei piscicole trecute de primele stadii de dezvoltare (Anexa 9) și, astfel, modulele acvaponice sunt poziționate la nivel superior, deasupra unităților de creștere, folosind o pompă submersă pentru preluarea apei tehnologice. Conform soluției prezentate în Anexa 9, modulul acvaponic alcătuit din unități confecționate din lemn cu membrană HDPE, este poziționat direct deasupra unităților de creștere, fiind susținut de o podină confecționată din grătare zincate tip staco. Anexa 10 prezintă secțiunea transversală a variantei constructive prezentate în cadrul Anexei 9, punctând diferențele de nivel dintre modulul acvaponic și unitatea de creștere a biomasei piscicole trecute de primele stadii de dezvoltare.

3. Design modul automat de observație a dinamicii biomasei sturionice și reconfigurarea tehnică a unităților de creștere, prin septarea parțială a acestora, în vederea facilitării achiziției de date imagistice

3.1. Design al diverselor variante constructive de reconfigurarea tehnică a unităților de creștere a biomasei sturionice în vederea colectării informațiilor necesare analizei imagistice

În vederea facilitării achiziției de date imagistice, a fost elaborată o arhitectură bazată pe o soluție duală. Astfel, se propune realizarea unei construcții mecanice mobile, în două variante, folosind un perete de sept, respectiv un tunel, amplasată în interiorul unității de creștere a materialului biologic, în scopul facilitării achiziției de date imagistice cât mai fidele pentru biomasa piscicolă. Această componentă mecanică este completată de sistemul automat de achiziție date, alcătuit din camere foto (CF) pentru achiziția de fotografii a biomasei piscicole și de sonare ultrasonice (SU) pentru determinarea prezenței peștilor în zona peretelui de sept și a tunelului. Aceste componente sunt reprezentate în figura 7 și au următoarea funcționalitate: în momentul prezenței exemplarului de sturioni în zonele de sept sau de tunel, SU detectează acest lucru și transmite informația către microcontrolerul Raspberry-Pi ce comandă camerele foto pentru achiziția de imagini (figura 8). Aceste imagini, prin intermediul microcontrolerului Raspberry-Pi, vor fi transmise către modulele de prelucrare și analiză a biomasei piscicole, în vederea determinării unui indice de creștere aferent acesteia. Camerele foto și senzorii ultrasonici au mobilitatea necesară, odată cu sistemul mecanic, pentru obținerea celei mai bune achiziții de date. Totodată, trebuie menționat, că achiziția de date se va face atât în mod subacvatic, a se vedea CF montate pe tunelul 1 și camera foto de pe trepiedul 2, din figura 7, cât și de la suprafața apei, camerele foto montate deasupra unității de creștere a peștilor, între peretele acesteia și peretele de sept. Scopul acestei arhitecturi este acela de a achiziționa cele mai bune date privind biomasa piscicolă din care să rezulte un indice de creștere cu o eroare cât mai mică față de valoarea reală.




Figura 7. Arhitectura sistemului de achiziție de date imagistice pentru determinarea dinamicii biomasei

Figura 6. Design sistem multi-trofic de productie cu o buclă de recirculare (sistem cuplat)




Figura 8. Schema sistemului de achiziție de date imagistice pentru determinarea dinamicii biomasei sturionice

sturionicole

Arhitectura sistemului de achiziție de date pentru determinarea dinamicii biomasei sturionicole este conectată la un sistem de achiziție de date legate de parametri fizico-chimici ai apei tehnologice (temperatura, pH, oxigenul dizolvat, NH_4 , NO_3) și, de asemenea, la un sistem de hrănire automată a biomasei sturionicole (figura 9). Astfel, determinarea optimă a cantității de hrană se va face pe baza a două informații (intrări în sistemul automat de hrănire a biomasei piscicole) și anume cele legate de calitatea apei tehnologice (oferite de către sistemul de achiziție date pentru calitatea apei), respectiv cele legate de indicele de creștere al biomasei piscicole (determinate pe baza modulului de achiziție de date imagistice). Microcontrolerul, care va sta la baza sistemului automat de hrănire a biomasei piscicole, va da comandă de deschidere a hrănitului pentru o anumită perioadă de timp, determinată baza celor două informații menționate anterior, după care o nouă comandă, cea de închidere, va fi transmisă controlerului. Perioada de funcționare a hrănitului este asociată unei valori exacte în ceea ce privește cantitatea de hrană distribuită. Informațiile provenite din cadrul sistemului de achiziție de date legate de calitatea apei tehnologice pot limita perioada de funcționare astfel încât, chiar dacă hrănitul primește comandă de funcționare din partea sistemului imagistic, această comandă poate fi anulată de către sistemul de achiziție date legate de parametri fizico-chimici ai apei tehnologice dacă se constată o calitate a apei precară, posibil datorată creșterii intensității de furajare.




Figura 9. Schema sistemului de distribuție automată a hranei către materialul sturionicol

3.2. Tehnici și metode pentru procesarea imaginilor

Tehnici Computer Vision

Object Detection este o problemă de găsim și de clasificare a obiectelor dintr-o imagine în una din categoriile de interes. În urma detectării, poate rezulta un număr variabil de obiecte identificate, număr care poate să fie diferit de la o imagine la alta.

Un **obiect** este o entitate caracterizată de un set de parametri (de exemplu, nivelul de gri al pixelului).

Edge detection

Metoda Edge Detection a fost studiată și implementată de cercetători în multe utilizând mulți algoritmi. Bansal și colab. [1] fac o trecere prin abordările de detectare a marginilor. Alegerea algoritmului depinde de obiectivul pe care îl avem și situațiile în care acesta va fi folosit. Textura materialului, obiectele din imagine și tipul de margine care se dorește ca răspuns sunt factori care influențează abordarea aleasă. Ne vom opri la una dintre abordările cele mai utilizate. Detectorul de margini Canny [2] este probabil cea mai eficientă metodă deoarece este o metodă de detectare a muchiilor complexă (figura 10).



Figura 10 Rezultatul algoritmului Canny asupra unei poze cu un pește și o plantă[3]

Acest tip de tehnică este bazată pe gradienti și histogramme. **Gradientii** reprezintă vectori orientați în direcția celor mai semnificative schimbări de culoare. Inițial, tehnica a fost concepută pentru detectarea pietonilor. Autorii lucrării (Dalal și Triggs) [4] [5] utilizează setul de date cu pietoni MIT. La pasul 1 se calculează magnitudinea fiecărui pixel, la pasul 2 se calculează gradientul orientat pentru fiecare pixel, iar la pasul 3 se calculează histograma gradientilor orientați (figura 11).




Figura 11 Extragere a caracteristicilor și de detectare a obiectelor [4]

Alte metode tradiționale de detectare a obiectelor detectorul Viola Jones, Histogram of Oriented Gradients (HOG), Deformable Part-based Model (DPM).

Tehnici Deep Learning

Object Detection

Problemele și provocările legate de detectarea obiectelor, au cunoscut progrese importante în ultima perioadă. Acestea au fost legate de **numărul variabil de obiecte** aflate într-o imagine și **dimensiunile diferite** ale obiectelor identificate. O altă preocupare a fost combinarea celor două cerințe pentru detectarea de obiecte (**localizare** și **clasificare**) într-un singur model.

Atunci când analizăm o imagine ne așteptăm să identificăm obiecte care acoperă cea mai mare parte din imagine. În schimb, unele obiecte ar putea fi de dimensiuni variabil mai mici, suprapuse sau chiar mai multe ca număr. Din acest motiv, este necesar ca înainte să facem o procesare a imaginilor, ceea ce duce la creșterea complexității.

Problema detecției numărului variabil de obiecte din imagini a fost abordarea folosind fereastra glisantă (**sliding window**). Practic, se trece peste o imagine o fereastră de dimensiuni fixe și se generează caracteristici pentru toate pozițiile acesteia. Unele rezultate obținute sunt eliminate, iar altele sunt combinate pentru a obține rezultatul final. La final se desenează un chenar în jurul obiectului identificat.

Mai târziu, metodele în două etape (**two-stage**) sau cele cu propunere de regiune (**region-proposal**) au început să domine. În cazul metodelor în două etape, **prima etapă** prezice un set de locații ale tuturor obiectelor de interes în care cea mai mare parte a fundalului este filtrată. În **a doua etapă**, un **convnet** clasifică obiectele din aceste locații ca fiind fundal sau una dintre categorii căutate.

Metodele de **propunere a regiunii** produc rezultate mult mai bune, dar sunt prea costisitoare din punct de vedere al calculului pentru detectarea obiectelor în timp real, în special pe sistemele încorporate.

YOLO (Redmon și colab. 2015) [6] și **SSD** (Liu și colab. 2015) [7] sunt arhitecturi care urmăresc rezolvarea acestei probleme prin prezicerea coordonatelor și a probabilităților chenarelor care delimitează obiectele într-o singură trecere prin rețea a imaginii. În schimb, acestea sunt optimizate pentru viteză cu prețul preciziei. Problema preciziei a fost rezolvată de **Lin și colab.**[8] prin redimensionarea funcției de pierdere (**focal loss**). Astfel, datorită acestei îmbunătățiri (**RetinaNet** - arhitectura propusă), pe lângă faptul că sunt mai rapide, metodele **one-stage** devin la fel de precise precum metodele în două etape, permițând detectare a obiectelor în timp real.

3.3. Etape pentru procesarea imaginilor

Pentru atingerea obiectivului propus sunt necesari o serie de pași care pornesc de la alegerea tipului de rețea neuronală, colectarea imaginilor pentru antrenare în formatul necesar rețelei, urmat de prelucrarea acestora și antrenarea algoritmului de inteligență artificială. În final, se va stabili formula de calculare a biomasei piscicole și cantitatea de hrană furajeră.

Alegerea algoritmul de identificare obiect în imagine

Sarcina rețelei neuronale va fi de a detecta peștii sau plantele în imagini, returnând un chenar dreptunghic cu poziția peștelui. Din acest dreptunghi se poate determina dimensiunile peștelui.

Instance segmentation

Segmentarea obiectelor a apărut ca o metoda de ușurare a procesului de segmentare a imaginilor.

Segmentarea imaginilor presupune construirea unei „măști” din pixeli pentru fiecare obiect din imagine, inclusiv fundalul. Acest proces returnează multe instanțe și obiecte care nu ne sunt de interes întotdeauna.

Instance segmentation se concentrează doar pe anumite obiecte din imagine. Algoritmul identifică doar obiecte de interes din imagine și creează masca aferentă fiecărui obiect.

Există mai multe abordări ale acestei sarcini, abordări care au fost sintetizate de Hafiz și Bhat în lucrarea „A Survey on Instance Segmentation: State of the art” [9].

Rezultate din literatură

Tabel1. Rezultate ale algoritmilor pe setul de date MS COCO [10]

Algoritm	AP	An
Hybrid Task Cascade (With Extra Training Data) [11]	43.9%	2019
PANet [12]	42.0%	2018
SOLOv2 [13]	41.7%	2020
GCNet [14]	41.5%	2019
BlendMask [15]	41.3%	2020
SOLO [16]	40.4%	2019
Non-local Neural Networks [17]	40.3%	2017
Mask Scoring R-CNN [18]	39.6%	2019
CenterMask [19]	38.3%	2019
MaskLab+ [20]	38.1%	2017
TensorMask [21]	37.3%	2019
Mask R-CNN [22]	37.1%	2017
PolarMask [23]	32.9%	2019
YOLACT [24]	29.8%	2019
MultiPath Network [25]	25.0%	2016

Construirea setului de date și antrenarea rețelei

Această etapă este influențată de arhitectura sistemului de captare a imaginilor cu peștii și tipului de rețea neuronală ales. În funcție de abordare, informațiile conținute de imagini și adnotările vor fi diferite.

Procesul de preluare al imaginilor pentru antrenare, reprezentat în figura 12, se va efectua cu ajutorul sistemului stabilit. Numărul de imagini colectate va influența precizia algoritmului de inteligență artificială. Din aceste motive se va dori realizarea unui număr cât mai mare de imagini.

După ce imaginile sunt colectate, acestea vor trece printr-un proces manual de adnotare. Pentru fiecare imagine va indica locația unde se află peștii (printr-un chenar sau o mască) utilizând un software specializat.

În final, vom avea o listă cu imagini cu pești și adnotări pentru fiecare în parte.

Scopul acestui set de date este antrenarea algoritmului de inteligență artificială destinat detectării dimensiunilor peștilor din cadrul unității de creștere.




Figura 12 Procesul de construire al setului de date și instruirea rețelelor

Stabilirea algoritmului de calculare a biomasei

Ultimul pas este procesarea informațiilor obținute de la rețeaua neuronală. Calcularea exactă a dimensiunilor unui pește este un proces dificil. Calitatea imaginilor preluate de camera este afectată de claritatea apei, de reflexia și refracția luminii, de gradul de iluminare al bazinului. Însă, mai există un factor tehnic care afectează detectarea distanței până la obiect și acesta este eroarea dispozitivului. Din aceste considerente, se ia în calcul determinarea unui indice de dezvoltare a peștilor, denumit **media de dezvoltare a biomasei peștilor**.

Sistemul va capta imagini cu peștele din bazin, îi va detecta și va stoca în baza de date. Însă, numărul imaginilor realizate nu va fi același ca numărul peștilor din bazin, deoarece nu este posibilă marcarea acestora. În consecință, este posibil să avem un număr de fotografii mult mai mare decât numărul peștilor din bazin. De asemenea, este posibil ca unii pești să nu apară deloc în imagini.

Informațiile din baza de date vor fi extrase la o anumită perioadă de timp stabilită. Se va calcula indicele de dezvoltare al biomasei ca fiind media tuturor peștilor detectați în imaginile colectate anterior. Rezultatul final va fi comparat cu media anterioară, pentru a se afla gradul de dezvoltare al peștilor. Pe baza acestor rezultate se poate trasa un grafic cu parcursul dezvoltării peștilor.

3.4. Arhitectura sistemului

Așa cum se poate observa în figura 13, arhitectura sistemului este complexă și va fi abordată în două direcții: hardware și software.

Sistemul hardware

În acest subcapitol sunt prezentate liste de componente hardware care vor alcătui sistemul și poziționarea camerelor fotografice (tabel 2).

Componente hardware

Tabel 2. Componente hardware identificare ca fiind potrivite spre utilizare

Denumire	Descriere
Microcontroler	
Raspberry Pi 4 Model B/8GB [26]	Capacitate de procesare bună la un preț accesibil, acest tip de microcontroler este ideal pentru nevoile proiectului.

Denumire	Descriere
	Procesorul Quad core, memoria LPDDR4 de 8GB, USB 3.0 și conexiune WIFI sunt caracteristici necesare sarcinilor propuse.
Camere	
Camera Module V2 [27]	Modulul de cameră v2 are un senzor Sony IMX219 de 8 megapixeli. Poate fi accesat prin intermediul API-urilor MMAL, V4L și biblioteca Picamera Python.
Camera Pi NoIR V2 pentru Raspberry Pi [28]	Modulul de cameră cu infraroșu v2 Pi NoIR are un senzor Sony IMX219 de 8 megapixeli. Pi NoIR vă oferă tot ceea ce oferă modulul camerei obișnuit, cu o singură diferență: nu folosește un filtru infraroșu (NoIR = No Infrared) Este destinat pentru a monitoriza starea de sănătate a plantelor verzi sau ce fac animalele nocturne în grădina fără a le deranja.
Raspberry Pi High Quality Camera [29]	Senzor Sony IMX477 de 12,3 megapixeli este concepută pentru a accepta lentile cu montare CS și, împreună cu adaptorul furnizat, lentile cu montare C.
Intel® RealSense™ Depth Camera SR305 [30]	Coded light proiectează un model cunoscut pe o scenă și evaluează modul în care acest model se deformează pe suprafețe în 3D. Camera are un senzor RGB de 2MP pentru a permite puncte de adâncime complet texturate și colorate. Fiind un periferic plug and play cu cost redus, camera poate oferi rezoluție de 640x480 adâncime la 60 de cadre pe secundă. Intel RealSense SR305 este o cameră cu adâncime de rază mai mică, optimizată pentru cea mai bună adâncime la 0,2-1,5m și funcționează cel mai bine în interior sau într-o situație de iluminare controlată. Camera utilizează Intel RealSense SDK 2.0 (care este compatibil cu orice camera Real Sense). Aplicațiile pentru SR305 includ: analiza și urmărirea feței, scanarea și maparea, segmentarea scenei, urmărirea mâinilor și a degetelor și realitatea augmentată.
Intel® RealSense™ Depth Camera D415 [31]	Când acuratețea este cel mai important factor, D415 este alegerea perfectă. Disponând de un senzor RGB integrat, D415 este perfect pentru autentificare facială, scanare 3D sau captare volumetrică. D415 are un câmp vizual standard și folosește senzori <i>rolling shutter</i> . Acest câmp vizual are ca rezultat o rezoluție mai mare a adâncimii pentru obiecte mai mici sau atunci când sunt necesare măsurători mai precise.
Intel® RealSense™ Depth Camera D455 [32] [33].	D455 extinde distanța dintre senzorii de adâncime la 95 mm, ceea ce îmbunătățește eroarea de adâncime la mai puțin de 2% la 4 m. Pentru a îmbunătăți imaginea RGB și corespondența dintre imaginile de adâncime și RGB, senzorul RGB include un <i>global shutter</i> și este asortat cu FOV de adâncime, ambele având un câmp vizual de 86 °. Camera integrează un IMU care permite adaptarea adâncimii atunci când camera se mișcă. Acest lucru permite o mai bună conștientizare a mediului pentru robotică și drone.
Intel® RealSense™ LiDAR Camera L515 [34], [35]	L515 este o cameră LiDAR care utilizează o tehnologie proprietară de scanare a oglinzilor MEMS, care permite o eficiență mai bună a puterii laserului în comparație cu alte tehnologii. Cu un consum de energie mai mic de 3,5 W pentru streaming în profunzime, camera LiDAR Intel RealSense L515 este cea mai eficientă cameră LiDAR de înaltă rezoluție din lume. Concepută cu SDK-ul de măsurare volumetrică Intel și bazată pe camera RealDense LiDAR L515, este utilizată ca soluție DWS (<i>Dimensional Weight Software</i>) pentru transformarea măsurătorilor dimensionale în întreaga industrie logistică.
Sonar	
Senzor ultrasonic rezistent la apă	Este compatibil cu modelele de microncontrolere menționate în cadrul prezentului tabel. Are un curent de lucru de 30mA, frecvența emisiei acustice de 40KHz și oferă informații despre obiecte aflate la distanțe de 250 mm până la 4500 mm;
Modul Senzor Ultrasonic Rezistent la Apă JSN-SR04T cu Sondă pt. Măsurare la Distanță	
Senzor de tip sonar - MB7066-XL-MaxSonar-WRL1	
	Are rezoluție de 1 cm; 10Hz rata citire; 42kHz Sensor Ultrasonic ce masoara distanta la obiecte; datele se pot citi de la 3 iesiri ale senzorului: tensiune analogica, pe serial, modulat in latime a semnalului; opereaza de la 3.0-5.5V; temperatura de operare -40°C la +70°C (-40°F to +160°F); calibrare in timp real (voltaj umiditate, noise ambiental); filtru pentru reducerea zgomotului; rezistenta IP67; potrivit pentru tevi PVC 3/4-inch; zona ingusta de detectare;
Accesorii	
Alimentator oficial Raspberry Pi 4 Model B [36], [37]	Acumulatorul oficial Raspberry Pi USB-C a fost conceput special pentru plăcile Raspberry Pi 4 Model B. Având un cablu tip USB-C incorporat, alimentatorul este disponibil în patru versiuni diferite care satisfac cerințele prizelor de alimentare internaționale.

Denumire	Descriere
Carcasa aluminiu cu doua ventilatoare pentru Raspberry Pi 4 model B [38]	Carcasa este din aluminiu și conține două ventilatoare. Oferă protecție, îl protejează de temperaturi înalte, este ușoară și ușor de instalat. Este conceput astfel ca nu afectează semnalul WiFi.
Card microSDHC 32GB Kingston Canvas Select + Adaptor [39]	Suport de memorie pentru microcontrolerul Raspberry Pi
Obiectiv 6mm WIDE pentru cameră Raspberry Pi HQ [40]	Lentilă <i>wide</i> de 6 mm 3MP, care este potrivită pentru utilizarea camerei Raspberry Pi.
Obiectiv 16mm TELEPHOTO pentru cameră Raspberry Pi HQ [41]	Acesta este un teleobiectiv de 16 mm 10MP, care este potrivit pentru a fi utilizat cu aparatul foto Raspberry Pi. Are un nivel ridicat de zoom și poate fi folosit pentru a viza subiecți specifici aflați departe.




Figura 13 Arhitectura sistemului

Propuneri pentru poziționare camerei

Unul dintre cei mai importanți pași este poziționarea camerelor pentru captarea pozelor. Acest pas influențează calitatea imaginilor și acuratețea rețelei neuronale.

Pentru a fi mai ușor de urmărit și fotografiat, s-a ales utilizarea unei tub/conducta transparente prin care vor trece pești.

În diagrama de mai sus sunt reprezentate 3 posibile poziționări ale camerei, care vor fi detaliate mai jos (figura 14).

1. Camera în bazinului (fără tunel pentru pește)

Camera va fi poziționată într-o carcasă transparentă, amplasată în interiorul bazinului. Această camera va fotografia peștii care trec prin fața obiectivului și va poza peștii.

Alături de camera se leagă un senzor de tip sonar care va detecta apropierea unui pește de obiectiv și va porni fotografierea acestuia.

Camera se va activa pe baza unui sonar care se afla în același loc. În acest fel, când sonarul detectează peștele în apropierea camerei, activează camera și realizează fotografiile.

Avantaje:

- Camera poate fi poziționată oriunde în bazin, deoarece ea este încapsulată într-o carcasă.

Dezavantaje:

- Peștele poate veni din orice direcție, în orice poziție, ceea ce va îngreuna detectarea acestuia în imagine.
- Camera nefiind poziționată în lateralul peștelui, va complica detectarea distanței până la pește și dimensiunea acestuia.
- Menținerea (curățarea de sedimente depuse) carcasei în care se află camera




Figura 14 Poziționarea camerelor

2. Camera deasupra bazinului (deasupra apei)

Camera poate fi poziționată deasupra bazinului, tot în dreptul conductei. De asemenea, vor fi amplasate 2 sonare la fiecare capăt al tubului, care vor detecta momentul de intrare și ieșire al peștelui din tunel.

Avantaje:

- Camera se afla în exterior, ceea ce permite o operare ușoară.
- Peștele fiind fotografiat de deasupra, permite o identificare mai ușoară a lungimi acestuia
- Distanța de la camera la tub este cunoscută
- Peștele se poate afla doar într-o singură poziție

Dezavantaje:

- Pozele fiind făcute de deasupra peștelui, detectarea acestora va fi mai dificilă (cantitatea de informație oferită de imagine fiind mai mică)
- Suprafața apei poate influența calitatea imaginii prin reflexia luminii și a mișcării suprafeței apei datorată pompelor de oxigen
- Menținerea (curățarea de sedimente depuse) tubului în care se deplasează peștii

3. Camera în bazin, în lateralul tubului

Această abordare presupune crearea unui carcase impermeabile pentru camera și dispozitivul Raspberry Pi. Cele două dispozitive vor fi amplasate în apă, la același nivel cu conducta transparentă. Două sonare vor fi plasate la fiecare capăt al tubului pentru a detecta momentul de intrare și ieșire al peștelui din tunel.

Pentru această abordare, este necesară cunoașterea distanței minime de focalizare a camerei.

Avantaje:

- Camera va fi relativ aproape de conducta transparentă și de pești, ceea ce va oferi o calitate mai bună a imaginilor
- Distanța de la camera la tub este cunoscută
- Peștele se poate afla doar într-o singură poziție

Dezavantaje:

- Este necesară construirea unei carcase care să încapsuleze camera și modulul Raspberry, care să nu permită strecurarea apei
- Alimentarea celor 2 module va fi mai dificilă
- Menținerea (curățarea de sedimente depuse) tubului în care se deplasează peștii și a carcasei în care se află camera

Sistemul de achiziție de date

Microcontrolerul colectează datele de la camera și senzori, după care le trimite către server. Procesul are loc astfel:

- Sonarele amplasate la capetele tubului sau lângă cameră detectează apropierea peștelui și trimit informația către Raspberry Pi.
- Când peștele este în zona de interes, se microcontrolerul activează camera și începe să facă poze la pește.
- După ce peștele a plecat din zona de interes, camera nu mai face poze.
- Se citește senzorii de apă pentru a se colecta informații.
- Imaginile împreună cu informațiile de la senzori sunt trimise către server

Sistemul de hrănire automată a peștilor

Dispozitivul IoT bazat pe Raspberry Pi va fi conectat la un hrănitor automat pentru pești. Acest hrănitor va furniza peștilor cantitatea de mâncare optimă dezvoltării acestora, ținându-se cont și de parametrii de calitate a apei.

Sistemul software

Sistemul software este alcătuit din mai multe componente care comunică între ele.

Sistemul de achiziție și trimitere de imagini

Pentru a conecta camera, sonarul și plăcuța Raspberry Pi împreună într-un sistem IoT, este necesar un program care să ruleze continuu pe microcontroler. Programul va capta informațiile de la sonar și va activa camera foto atunci când peștele se afla în proximitatea obiectivului.

De asemenea, în apă din bazin vor fi o serie de senzori care vor măsura calitatea apei. Aceste rezultate vor fi citite de către modulul Raspberry Pi.

După ce se realizează fotografia, se va folosi un program client care va consuma servicii web aflate pe server. Aceste servicii vor permite încărcarea unei fotografii și trimiterea informațiilor citite de la senzori.

Sistemul Server

API

Serverul va expune un API care permite:

1. **Salvarea unei imagini pe server** – serviciu care va fi consumat de plăcuța Raspberry Pi. Se creează o înregistrare în baza de date cu informații despre imagine (denumire, locație etc)
2. **Salvarea informațiilor de la senzori** – serviciul permite înregistrarea în baza de date a informațiilor legate de calitatea apei.
3. **Rularea rețelei neuronale** – după ce imaginea a fost stocată, aceasta este trimisă mai departe către rețeaua neuronală. Aceasta va executa și returna un rezultat care va fi procesat și înregistrat în baza de date.
4. **Vizualizarea informațiilor** – API-ul va permite vizualizarea informațiilor stocate în baza de date sub formă de rapoarte. Utilizatorii le vor folosi pentru a interpreta informațiile acumulate și a lua deciziile necesare.
5. **Configurarea informațiilor inițiale** – la început, este necesar setarea unor parametri (cum ar fi numărul de pești, perioada de timp pentru calcule) care vor fi necesar în funcționarea sistemului.
6. **Calcul hrană** – cantitatea de hrană necesară peștilor este calculată în funcție de dimensiunea peștilor și indici de calitate al apei.

Baza de date

Sistemul va comunica cu baza de date de tip relațional, ce va stoca:

- Informații despre imagini colectate de la camera (data, ora, locul de stocare)
- Datele de la senzorii de calitate a apei împreună cu data și ora prelevării
- Rezultatele algoritmilor de detectare a dimensiunii peștelui în imagine
- Informațiile inițiale configurate de utilizator (numărul de pești, dimensiunea inițială, rata de furajare etc)

Aplicație web

Aplicația web va fi alcătuită din 2 module de interes:

- Modulul de configurare inițială, unde se vor putea seta și modifica date
- Modulul de vizualizare al dezvoltare peștilor, unde se va putea urmări evoluția acestora

Utilizarea rețelelor neuronale

Rețelele neuronale vor rula cu ajutorul unor scripturi a căror sarcină este rularea și captarea informațiilor rezultate. Aceste informații vor fi trimise apoi către server unde se vor calcula dimensiunile peștilor detectați și vor fi stocate în baza de date.

Pentru a nu fi probleme de compatibilități, versiuni și librării, se vor crea containere pentru fiecare rețea neuronală în parte.

Modulul de hrănire automată a peștilor

Microcontrolerul Raspberry Pi va fi conectat la un hrănitor automat care va furniza peștilor o anumită cantitate de furaje.

Înainte de a seta cantitatea de hrană, se va apela un serviciu de pe server care va răspunde cu cantitatea de hrană care trebuie data peștilor. În acest fel se ține cont mereu de dimensiunea acestora și de parametrii de calitate a apei.

4. Design modulul automat de observație a dinamicii biomasei vegetale în vederea achiziției de date imagistice

4.1. Design al diverselor variante constructive de configurarea tehnică a unităților de creștere a biomasei vegetale în vederea colectării informațiilor necesare analizei imagistice

Arhitectura sistemului de achiziție de date pentru biomasa vegetală (figura 15) vizează determinarea dinamicii de creștere a biomasei de busuioc, de-a lungul ciclului de producție, precum și identificarea în timp util a unor posibile deficiențe manifestate la nivelul plantelor, în vederea remedierii acestora în timp util, fără a periclita întreaga producție.

Design-ul sistemului evidențiază următoarele elemente constructive: o componentă mecanică, mobilă, pe verticală, având capacitatea de a se înălța odată cu creșterea plantelor (reprezentată cu roșu în figura 15), pe care se vor amplasa camerele foto; o componentă de hardware reprezentată de camerele foto (în număr de trei pe unitate acvaponică), prin intermediul cărora se

vor achiziționa date (imagini), la intervale de timp prestabilite. Declanșarea achiziției de date pentru biomasa vegetală se va face prin intermediul unui microcontroller de tip Raspberry-Pi. Acest microcontroller are și rolul de a transmite datele către următorul nivel, cel de analiză imagistică a biomasei vegetale. Componenta hardware va fi însoțită și de o componentă software (figura 16) prin care se va stabili comunicația cu camerele foto, achiziția de imagini și transmiterea lor către modulul de analiză imagistică.




Figura 15. Arhitectura sistemului de achiziție de date imagistice pentru biomasa vegetală de busuioc




Figura 16. Schema sistemului de achiziție de date imagistice pentru biomasa vegetală de busuioc

4.2. Tehnici și metode folosite pentru evaluarea biomasei vegetale

Obiectivul acestei activități este acela de a urmări evoluția creșterii biomasei de busuioc și de a identifica posibile deficiențe manifestate de-a lungul ciclului de producție, folosind abordări bazate pe Computer Vision și Deep Learning.

Pentru a pune diagnosticul corect unei plante afectate, trebuie să cunoaștem aspectul normal, condițiile de creștere (lumină, apă și nutrienți) și potențialul de apariție a unor deficiențe.

Identificarea corectă a deficienței manifestate la nivelul unei plante este o problemă complexă. Diagnosticul se face cel mai bine urmărind evoluția plantei aflate în creștere. Deficiența este identificată atunci când întreaga plantă sau o parte din ea este afectată. De asemenea, prezența unei deficiențe poate fi identificată atunci când planta pare normală, dar frunzele, tulpina, rădăcina sau alte părți ale acesteia sunt deformate, decolorate sau chiar supra-dezvoltate. Examinarea frunzelor este punctul de plecare cel mai bun atunci când dorim să evaluăm starea de sănătate a plantei.

Tehnici și metode folosite pentru evoluție creștere plante

Metoda tradițională pentru urmărirea evoluției unei plante, respectiv identificare și determinare deficiențelor este cea de **examinare manuală** a plantei. Acest proces este consumator de timp, iar detectarea deficiențelor plantelor printr-o tehnică automată ar reduce considerabil activitatea de monitorizare. În ultima perioadă cercetătorii au fost preocupați să dezvolte metode folosind **Computer Vision** și **Deep Learning** care să detecteze și să clasifice deficiențelor culturilor vegetale cu scopul de a rezolva și depăși problemele legate de metodele manuale folosite în mod normal.

Utilizarea acestor metode presupune achiziția de imagini, extragerea diferitelor caracteristici, alegerea metodelor de procesare și analiza rezultatelor.

Tabel 3. Studiu detectare și clasificare plante

Cultură	Caracteristici	Tehnică	Accuracy	Lucrare
Frunze citrice	Intensitate și textură	Discriminant	94 - 72%	Pydipati et al. [42]
Frunze orhidee	Textură și culoare	ANN	89,6%	Huang et al. [43]
Frunze orez	Textură	SVM	97,2%	Yao et al. [44]
Frunze citrice	Textură și culoare	AdaBoost	88%	Zhang et al. [45]
Frunze grâu și viță de vie	Textură, formă și culoare	GRNN, PNN	94,29%	Wang et al. [46]
Frunze trandafiri, mămâi, fasole și bananier	Textură și culoare	SVM	94%	Arivazhagan et a [47]
Frunze trestie de zahăr	Textură	SVM	80%	Ratnasari et al. [48]
Frunze tufe roșii	Formă	SVM	78% -98% - 88%	Mokhtar et al. [49]
Frunze lucernă	Textură, formă și culoare	SVM	80%	Qin et al. [50]
Frunze plante verzi	Textură, formă și culoare	2 tehnici SVM	87,80%	Youssef Essaady et al. [51]
Frunze citrice	Textură și culoare	Bagged tree	99,9%	Ali et al. [52]
Frunze busuioc și pătrunjel	Textură, formă și culoare	Rețele neurale	80% - 100%	AL-Otaibi et al. [53]

Frunze mix plante	Textură, formă și culoare în funcție de regiune cultivare	Radial Basis, Function Neural, Network	86,21%	Chouhan et al. [54]
Frunze măr și tufe castraveți	Culoare	Super pixel clustering, kmeans clustering	90.43% - 92.15%	Zhang et al. [55]
Frunze grâu	Culoare	Deep convolution neural networks	> 96%	Picon et al. [56]
Frunze palmier	Culoare	Naïve Bayes	80%	Nababan et al. [57]
Frunze tufe roșii	Culoare	Deep convolution neural networks	96%	Fuentes et al. [58]

Sistem de colectare și instruire rețele

Plantele vor fi cultivate în condiții de **mediu controlat** într-un recipient cu substraturi consacrate (hidroton – bile din argilă tratate termic, respectiv rocă vulcanică) și aport nutritiv care provine de la un bazin cu pești hrăniți cu un tratament special. Acest proces contribuie la dezvoltarea biomasei vegetale de busuioac și ajută la evaluarea performanței de creștere și a bunăstării plantei (formă, culoare și alte eventuale semne specifice care pot să apară la nivelul frunzelor). În timpul experimentului se vor colecta o serie de poze cu biomasa vegetală pe baza cărora se va construi o bază de date, care ulterior va fi folosită în cadrul celui de-al doilea experiment.

Colectare/achiziție set de imagini

Captare imagini și adnotare

Captarea imaginilor se va face cu ajutorul unor camere conectate la dispozitive IoT Raspberry Pi. Ținând cont de obiectivele proiectului (măsurare înălțime plantă, masurare suprafață ocupată și clasificare frunze) au fost luate în considerare tipul camerelor și calitatea imaginii, acestea fiind aspecte importante în analiza imaginilor.

Pentru a simula mediile în aer liber și pentru a evita factori precum iluminarea și orientarea, se vor folosi becuri fluorescente cu filtre de lumină naturală și reflectoare, plasate la 1m de suprafața cu plante și un pentru a asigura o iluminare adecvată. Colectarea imaginilor se va face atât manual cât și automat în timpul creșterii unei plante.

Colectare imagini manual

Procesul de pregătire a setului de date va cuprinde mai multe etape de achiziție de imagini cu întreaga plantă, atât înainte de tăiere cât și după. Se vor face imagini cu planta întreagă în mediul original în care a crescut, imagini cu planta întreagă după tăiere și apoi la frunze.

De asemenea, se vor face imagini la frunze, în timpul dezvoltării plantei, fără să fie tăiate (se va pune o coală albă sub fiecare frunză și se va face câte o poză). Adnotarea imaginilor se va face manual utilizând un software dedicat pentru a marca zonele de interes.

Colectare imagini cu sistem de captare automat

Sistemul va capta automat mai multe imagini cu vedere de sus, laterală și în unghi de 45 de grade. Imaginile vor fi **capturate** în format RGB la un interval de timp (de exemplu 12 ore) folosind trei camere. O cameră va fi poziționată în plan vertical și va capta imagini de sus pentru a evalua **suprafața plantei** și pentru **deteția de frunze**. A doua cameră va fi în plan înclinat (unghi de 45 de grade) pentru **deteția de frunze**. Iar a treia cameră în plan orizontal va avea drept scop măsurarea **înălțimii plantei și deteția de frunze**.

Fiecare cameră va fi conectată la un o placă IoT Raspberry Pi, care la un anumit interval de timp (setat în aplicație) se va declanșa și va efectua o secvență de imagini. Figura de mai jos reprezintă partea constructivă a sistemului propus. Poziționarea camerelor va fi identic ca în sistemul de producție. Adnotarea imaginilor se va face manual utilizând un software dedicat pentru a marca zonele de interes.

Stocare imagini

După achiziția de imagini, acestea vor fi **stocate** sub formă de fișiere pe un server, iar diferite informații (oră, tip cameră, poziție cameră - orizontală/verticală/unghi, etc) necesare prelucrării vor fi salvate într-o bază de date (figura 17). Aceste date vor fi gestionate de sistemul de gestionare a datelor. Aceste imagini sunt utilizate pentru instruirea rețelelor.




Figura 17. Colectare imagini manual și automat

Această etapă presupune aplicarea unor **operații** (geometrice; de îmbunătățire imagine – modificare contrast, decupare imagine cu păstrare sau nu a fundalului, negativare imagine; de restaurare imagine; de segmentare imagine sau de compresie imagine – reducerea volumului de date pentru reprezentarea informației) și **extragerea de informații** (atribute – culoare; textură; formă cu metode bazate pe regiuni, contur; colțuri, etc.) relevante din imaginile captate (figura 18).

Prelucrarea unei imagini se va face în funcție de ora la care au fost făcute, tipul și unghiul camerei folosind metode de procesare pentru a obține trăsăturile sau caracteristicile din aceste imagini.




Figura 18 Diagramă colectare imagini și instruire rețele

Etapa de preprocesare

Calitatea imaginii poate influența rezultatele etapei de analiză. Scopul etapei de preprocesare este de a scoate în evidență anumite detalii ale frunzelor utilizând diferite metode de procesare pentru a îmbunătăți calitatea imaginilor.

Metode care pot fi aplicate:

- **dimensionare imagine** – reducere dimensiune date cu o pierdere cât mai mică de informații posibil
- **analiză culoare** - "color card" pentru corectarea culorii pentru fiecare imagine
- **ajustare intensitate** – scoatere în evidență a anumitor zone bolnave ale unei frunze
- **corectare contrast** între obiectul țintă (plantă) și fundal: adăugare material pentru a crește contrastul (albastru, de exemplu).
- trecere dintr-un **spațiu de culori** în altul
- **segmentare**

Etapa de analiză

Vor fi folosite câte două tehnici pentru fiecare problemă (măsurare suprafață plantă, măsurare înălțime plantă, clasificare plantă) și anume metode de **Computer Vision** și metode de **Deep Learning**.

În aceste sarcini vom folosi **propriul set de date** care va conține diferite imagini cu frunze etichetate ca fiind sănătoase sau etichetate cu un anumit tip de boală.

Măsurare suprafață plantă

Vor fi folosite în principal imaginile făcute de camera poziționată deasupra, dar și imagini de la camera laterală, respectiv camera în unghi, rezultând **trei valori** pentru suprafața ocupată. Se va calcula suprafața întregii plante. Pentru această etapă se definește un **indice de suprafață/creștere globală**, indice care ar trebui să crească mereu, ceea ce indică faptul că planta se dezvoltă. **Indicele de suprafață este o măsură care nu reprezintă suprafața reală a plantei**, ci va fi o mărime de genul % care se va evalua pe baza pixelilor din imagine.

Pentru măsurarea suprafeței unei plante vom folosi cele două abordări amintite și anume, tehnici de Computer Vision și tehnici de Deep Learning. Pe partea de **Computer Vision** vom folosi ca metodă **edge detection**, iar pe partea de **Deep Learning** **instance segmentation** (pentru frunze) și **image segmentation** (pentru întreaga suprafață ocupată de plantă).

Măsurare înălțime plantă

Pentru măsurarea înălțimii unei plante, pe partea de **Computer Vision** vom folosi o **cameră Intel** pentru primul experiment, iar pentru al doilea experiment vom folosi un **reper** (riglă gradată) și o **camera normală** orizontală. Pentru

segmentare vom folosi ca metode (pe partea de **Deep Learning**) **instance segmentation** și **image segmentation**, iar a doua tehnică folosită va fi **object detection**.

Camera Intel (S305, D415, D455, L515) ne dă informații despre distanță. Distanța va fi măsurată de la cameră până la cel mai apropiat punct. Identificarea plantei se va face cu Computer Vision sau Deep Learning.

Cameră normală (Pi V2) împreună cu o riglă gradată și tehnici de **Deep Learning** va cea de a doua metodă folosită pentru calcularea înălțimii plantei. Vom identifica obiectele din imagine și le vom încadra într-un chenar. Pentru calibrarea pixelilor cu lumea reală, se va identifica numărul de pixeli raportat la mm. De asemenea, vom calcula dimensiunea în pixeli a riglei. Planta va fi identificată folosind tehnici de Computer Vision sau Deep Learning.

Clasificare plantă

Pentru clasificarea plantelor vom folosi cele două abordări, pe partea de **Computer Vision** metoda **edge detection**, urmată de tehnici de **Machine Learning** pentru clasificarea frunzelor detectate, iar pe partea de **Deep Learning**, vom folosi **Object detection** la nivel de frunză și la nivel de plantă (care va fi un experiment), după care vom clasifica obiectele detectate (frunză, plantă). Etapa de segmentare este etapa în care vor fi localizate segmentele bolnave ale plante.

Arhitectură sistem

Descriere sistem

Sistemul este format din două module: modul achiziție date și modul procesare date.

Modul achiziție și instruire rețele

Modulul pentru achiziția datelor va conține o aplicație IoT utilizată de Raspberry Pi pentru colectarea imaginilor de la camerele fotografice și un **serviciu achiziții date**.

Pe baza imaginilor colectate se vor instrui rețelele neuronale. Rețelele candidate sunt descrise în capitolul anterior.

Modul procesare date

Acest modul va conține o aplicație web, rețelele instruite în etapa anterioară și serviciul de colectare imagini.

Imaginile colectate vor fi salvate în baza de date împreună cu diverse informații (de exemplu, informații despre camera care a făcut fotografia), după care vor fi procesate prin tehnici de Computer Vision și tehnici Deep Learning. Rezultatul rețelelor va fi stocat în baza de date.

Pe baza informațiilor colectate și a rezultatelor procesării se creează diverse rapoarte.

Aplicație web

Date introduse în aplicație


- Când este iluminare
- Câte poze se fac pe zi
- La câte zile se va calcula diferența (gradul de creștere)

Analiza datelor

- Zilnic procentul de suprafața,
- Zilnic evoluție înălțime
- Tabele
- Rezultatul clasificării frunzelor
- Încărcare imagine (alta decât una existentă în setul de date) pentru a face o analiză

Diagrama sistemului

Arhitectura software a sistemului este prezentată în cadrul figurii 19.



5. Design sistem de stocare a datelor imagistice prelevate în vederea determinării biomasei sturionice și vegetale, utilizând tehnica IoT.


Bazele de date reprezintă ansambluri structurate de date, persistente, cu redundanță minimă, ce pot fi prelucrate eficient de mai mulți utilizatori într-un mod concurent. Un sistem de gestiune a bazelor de date (SGBD – Data Base Management System) reprezintă un produs software ce asigură interacțiunea cu o bază de date, permițând definirea, consultarea și actualizarea datelor din baza de date. Toate cererile de acces la baza de date sunt tratate și controlate de către SGBD. În prezent, Oracle, SQL Server, MySQL, MariaDB, Firebird și PostgreSQL reprezintă cele mai utilizate sisteme de gestiune a bazelor de date.

În cadrul prezentului proiect, dezvoltarea bazei de date relaționale a sistemului va fi realizată conform următoarei arhitecturi (figura 20), sistemul de gestiune a bazelor de date urmând a fi stabilit pe baza a trei variante (MySQL, MariaDB, PostgreSQL), acestea reprezentând cele mai cunoscute sgbd-uri open source, având în același timp performanțe remarcabile, inclusiv în scenarii de tip "big data".

Baza de date, a cărei arhitectură a fost prezentată în figura 20, își propune stocarea tuturor datelor definitorii pentru contextul piscicol și cel vegetal, oferind suport de stocare atât pentru datele operaționale (provenind de la diferiți senzori), cât și pentru informația/cunoașterea rezultată în urma analizei inteligente a datelor primare.

Prima iterație a arhitecturii bazei de date, din cadrul prezentului proiect, conține 17 tabele relaționale, oferind posibilitatea stocării datelor provenind atât din scenariile referitoare la analiza masei piscicole, cât și din scenariile referitoare la evoluția masei vegetale. Astfel, semantica tabelor din cadrul bazei de date este după cum urmează:

- **EnvironmentParameter:** tabelă utilizată pentru stocarea tuturor parametrilor ce urmează a fi măsurați, indiferent de context (vegetal sau piscicol). Practic, în momentul în care se stabilește necesitatea efectuării unor măsurători asupra unui parametru, detaliile acestuia vor fi stocate în această tabelă;
- **Sensor:** tabelă utilizată pentru stocarea tuturor senzorilor folosiți în cadrul platformei tehnologice aferente prezentului proiect, indiferent de context (vegetal sau piscicol)
- **Measurement:** structură utilizată pentru stocarea tuturor măsurătorilor efectuate (a datelor provenind de la senzori), indiferent de context (vegetal sau piscicol)
- **Pool:** tabelă utilizată pentru stocarea și identificarea tuturor bazinelor piscicole analizate din perspectiva biomasei piscicole;
- **SensorPool:** structură de date de legătură ce face asocierea între bazinele piscicole și senzorii utilizați în cadrul unui bazin de-a lungul unei perioade de timp;
- **PoolContext:** tabelă strategică a arhitecturii bazei de date deoarece oferă informații, păstrate istoric, provenind din algoritmi inteligenți de analiză. Aici se regăsește stocată dinamica variației biomasei piscicole la nivelul unui/fiecărei unități de creștere;
- **Fishfood:** tabelă utilizată pentru stocarea datelor referitoare la hrana folosită pentru hrănirea peștilor din cadrul unităților de creștere;
- **Feeding:** tabelă de legătură între bazinul piscicol și hrana piscicolă, datele stocate aici oferind informații istorice/temporale despre ce hrană a fost administrată pe fiecare bazin în parte;
- **Plants_Pool:** tabelă utilizată pentru stocarea datelor referitoare la unitățile de creștere a plantelor;
- **Plants_Pool_Sensor:** tabelă de legătură, utilizată pentru realizarea asocierii între senzori și unitățile cu plante. Astfel, va fi cunoscut pentru orice moment temporal, ce senzori au realizat măsurători pentru fiecare unitate în parte;
- **Plants_Pool_Context:** tabelă, de asemenea strategică, ce conține informație provenind din algoritmi inteligenți de analiză a plantelor – dinamica suprafeței foliare. O unitate de creștere a plantelor poate avea asociat orice număr de context, un context putând fi, spre exemplu, definit pentru un timp diferit sau pentru plante diferite, etc. Cele două tabele menționate a fi strategice sunt încadrate în această categorie inclusiv datorită potențialului comercial al datelor pe care acestea le conțin. Astfel, organizația poate vinde cunoașterea obținută în urma experimentelor realizate, către terțe părți interesate, putând oferi informații importante referitoare la simbioza dintre anumite plante și anumiți pești, în variate condiții de mediu;
- **Plant:** tabelă utilizată pentru stocarea datelor referitoare la plantele crescute în sistem;
- **Plants_Nutrients:** tabelă utilizată pentru stocarea detaliilor despre nutrienții folosiți pentru creșterea plantelor (daca este cazul)
- **Dosage:** tabelă ce descrie istoricul, dinamica hrănirii plantelor, cantitatea de nutrient folosită, intervalul de timp în care s-a efectuat hrănirea;
- **Plants_Growing:** reprezintă o tabelă ce oferă informații referitoare la ce plante au crescut într-un bazin, pe o anumită perioadă de timp. Astfel, a fost considerat inclusiv cazul în care într-un bazin pot crește mai multe plante, acestea fiind distribuite pe mai multe zone.
- **Disease:** tabelă utilizată pentru stocarea detaliilor despre deficiențele ce pot fi analizate în cadrul platformei inteligente.
- **Plants_Pool_Context_Disease:** tabelă de legătură, utilizată pentru realizarea asocierii între un context vegetal și deficiențele cunoscute. Astfel, pot fi formalizate atât pentru situații în care, pentru un singur context, sunt identificate mai multe deficiențe, cât și pentru situații în care o boală este asociată mai multor contexte;



- Figura 20. Arhitectura bazei de date aferentă soluției software din cadrul prezentului proiect

Rezultate sintetizate

1. Realizarea unor variante punctuale de design, cu și fără elemente de automatizare, a modulelor acvaponice din cadrul unui sistem integrat de producție și aplicarea acestora în cadrul sistemului de producție deținut de către beneficiarul prezentului proiect.
2. Realizarea unor variante punctuale de design în ceea ce privește posibilitatea integrării modulelor acvaponice în cadrul unui sistem recirculant sturionicol și aplicarea acestora, în diferite scenarii tehnice, în cadrul sistemului de producție deținut de către beneficiarul prezentului proiect.
3. Realizarea unor variante de design al modul automat de observație a dinamicii biomasei sturionicole, de reconfigurarea tehnică a unităților de creștere, prin septarea parțială a acestora sau prin amplasarea unor construcții tip tunel de trecere la nivelul acestora, în vederea facilitării achiziției de date imagistice
4. Stabilirea procedurilor, tehnicilor și metodelor folosite în cadrul procesului de evaluare imagistică a biomasei sturionicole.
5. Realizarea unor variante de design al modul automat de observație a biomasei vegetale, de reconfigurarea tehnică a unităților acvaponice, în vederea facilitării achiziției de date imagistice.
6. Stabilirea procedurilor, tehnicilor și metodelor folosite în cadrul procesului de evaluare imagistică a biomasei vegetale.
7. Realizarea design-ului sistemului de stocare a datelor imagistice prelevate în vederea determinării biomasei sturionicole și vegetale, utilizând tehnica IoT.
8. Diseminarea rezultatelor printr-un număr de 5 articole științifice ISI Proceedings acceptate spre publicare, 1 articol cotelat ISI publicat (IF 3,267), 1 articol aflat în evaluare, în vederea publicării în cadrul unui jurnal cotelat ISI (IF 3,682) și un număr de 5 lucrări științifice comunitate (prezentare orală virtuală) în cadrul conferințelor internaționale indexate ISI.

Anexe

Cele 10 anexe menționate drept referință în cadrul prezentului raport sunt încărcate în cadrul platformei EVOC. Acestea se intitulează astfel:

ANEXA 1 - UNITATE DE CREȘTERE BIOMASA VEGETALA CONFECTIONATA DIN LEMN CU MEMBRANA HDPE

ANEXA 2 - UNITATE DE CREȘTERE BIOMASA VEGETALA CONFECTIONATA DIN INOX ALIMENTAR

ANEXA 3 - PLAN SI SCHEMA FUNCTIONALA SITUATIE EXISTENTA LA FERMA SC SILURUS MARKET SRL

ANEXA 4 - PLAN SI SCHEMA FUNCTIONALA SISTEM ACVAPONIC CUPLAT LA MODUL CREȘTERE PUIET, VARIANTA CONSTRUCTIVA CU UNITATI DIN LEMN ACOPERITE CU HDPE

ANEXA 5 - PLAN SI SCHEMA FUNCTIONALA SISTEM ACVAPONIC CUPLAT LA MODUL CRESTERE PUIET, VARIANTA CONSTRUCTIVA CU UNITATI DIN TABLA PLANA INOX

ANEXA 6 - SECȚIUNE TRANSVERSALĂ SISTEM ACVAPONIC CUPLAT LA MODUL CRESTERE PUIET, VARIANTA CONSTRUCTIVA CU UNITATI DIN TABLA PLANA INOX, DESCRISA IN ANEXA 5

ANEXA 7 - PLAN SI SCHEMA FUNCTIONALA SISTEM ACVAPONIC CUPLAT LA MODUL CRESTERE MATERIAL PISCICOL ADULT, VARIANTA CONSTRUCTIVA CU UNITATI DIN LEMN ACOPERITE CU HDPE

ANEXA 8 - PLAN SI SCHEMA FUNCTIONALA SISTEM ACVAPONIC CUPLAT LA MODUL CRESTERE MATERIAL PISCICOL ADULT, VARIANTA CONSTRUCTIVA CU UNITATI DIN TABLA PLANA INOX

ANEXA 9 - PLAN SI SCHEMA FUNCTIONALA SISTEM ACVAPONIC CUPLAT DIRECT DEASUPRA UNITATE CRESTERE MATERIAL PISCICOL ADULT, VARIANTA CONSTRUCTIVA CU UNITATI LEMN ACOPERITE CU HDPE

ANEXA 10 - SECȚIUNE TRANSVERSALA SISTEM ACVAPONIC CUPLAT DIRECT DEASUPRA UNITATE CRESTERE MATERIAL PISCICOL ADULT, DESCRISA IN ANEXA 9

Bibliografie

- [1] A. Bansal, A. Kowdle, D. Parikh, A. Gallagher, and L. Zitnick, "Which Edges Matter?," in *2013 IEEE International Conference on Computer Vision Workshops*, Sydney, Australia, Dec. 2013, pp. 578–585, doi: 10.1109/ICCVW.2013.80.
- [2] "OpenCV: Canny Edge Detection." https://docs.opencv.org/master/da/d22/tutorial_py_canny.html (accessed Dec. 01, 2020).
- [3] "edge-detection - crates.io: Rust Package Registry." <https://crates.io/crates/edge-detection> (accessed Dec. 04, 2020).
- [4] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, San Diego, CA, USA, 2005, vol. 1, pp. 886–893, doi: 10.1109/CVPR.2005.177.
- [5] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," *IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, p. 8, 2005.
- [6] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," *ArXiv150602640 Cs*, May 2016, Accessed: Nov. 26, 2020. [Online]. Available: <http://arxiv.org/abs/1506.02640>.
- [7] W. Liu *et al.*, "SSD: Single Shot MultiBox Detector," *ArXiv151202325 Cs*, vol. 9905, pp. 21–37, 2016, doi: 10.1007/978-3-319-46448-0_2.
- [8] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, "Focal Loss for Dense Object Detection," *ArXiv170802002 Cs*, Feb. 2018, Accessed: Nov. 26, 2020. [Online]. Available: <http://arxiv.org/abs/1708.02002>.
- [9] A. M. Hafiz and G. M. Bhat, "A Survey on Instance Segmentation: State of the art," p. 28.
- [10] "COCO - Common Objects in Context." <https://cocodataset.org/#home> (accessed Dec. 01, 2020).
- [11] K. Chen *et al.*, "Hybrid Task Cascade for Instance Segmentation," *ArXiv190107518 Cs*, Apr. 2019, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1901.07518>.
- [12] S. Liu, L. Qi, H. Qin, J. Shi, and J. Jia, "Path Aggregation Network for Instance Segmentation," *ArXiv180301534 Cs*, Sep. 2018, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1803.01534>.
- [13] X. Wang, R. Zhang, T. Kong, L. Li, and C. Shen, "SOLOv2: Dynamic and Fast Instance Segmentation," *ArXiv200310152 Cs*, Oct. 2020, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/2003.10152>.
- [14] Y. Cao, J. Xu, S. Lin, F. Wei, and H. Hu, "GCNet: Non-local Networks Meet Squeeze-Excitation Networks and Beyond," *ArXiv190411492 Cs*, Apr. 2019, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1904.11492>.
- [15] H. Chen, K. Sun, Z. Tian, C. Shen, Y. Huang, and Y. Yan, "BlendMask: Top-Down Meets Bottom-Up for Instance Segmentation," *ArXiv200100309 Cs*, Apr. 2020, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/2001.00309>.
- [16] X. Wang, T. Kong, C. Shen, Y. Jiang, and L. Li, "SOLO: Segmenting Objects by Locations," *ArXiv191204488 Cs*, Jul. 2020, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1912.04488>.
- [17] X. Wang, R. Girshick, A. Gupta, and K. He, "Non-local Neural Networks," in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Jun. 2018, pp. 7794–7803, doi: 10.1109/CVPR.2018.00813.
- [18] Z. Huang, L. Huang, Y. Gong, C. Huang, and X. Wang, "Mask Scoring R-CNN," *ArXiv190300241 Cs*, Mar. 2019, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1903.00241>.
- [19] Y. Lee and J. Park, "CenterMask : Real-Time Anchor-Free Instance Segmentation," *ArXiv191106667 Cs*, Apr. 2020, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1911.06667>.
- [20] L.-C. Chen, A. Hermans, G. Papandreou, F. Schroff, P. Wang, and H. Adam, "MaskLab: Instance Segmentation by Refining Object Detection with Semantic and Direction Features," *ArXiv171204837 Cs*, Dec. 2017, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1712.04837>.
- [21] X. Chen, R. Girshick, K. He, and P. Dollár, "TensorMask: A Foundation for Dense Object Segmentation," *ArXiv190312174 Cs*, Aug. 2019, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1903.12174>.
- [22] K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask R-CNN," *ArXiv170306870 Cs*, Jan. 2018, Accessed: Dec. 01, 2020. [Online]. Available: <http://arxiv.org/abs/1703.06870>.

- [23] E. Xie *et al.*, "PolarMask: Single Shot Instance Segmentation with Polar Representation," *ArXiv190913226 Cs*, Feb. 2020, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1909.13226>.
- [24] D. Bolya, C. Zhou, F. Xiao, and Y. J. Lee, "YOLACT: Real-time Instance Segmentation," *ArXiv190402689 Cs*, Oct. 2019, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1904.02689>.
- [25] S. Zagoruyko *et al.*, "A MultiPath Network for Object Detection," *ArXiv160402135 Cs*, Aug. 2016, Accessed: Dec. 03, 2020. [Online]. Available: <http://arxiv.org/abs/1604.02135>.
- [26] T. R. P. Foundation, "Raspberry Pi 4 Model B specifications," *Raspberry Pi*. <https://www.raspberrypi.org/products/raspberry-pi-4-model-b/specifications/?resellerType=home> (accessed Nov. 01, 2020).
- [27] T. R. P. Foundation, "Buy a Camera Module V2," *Raspberry Pi*. <https://www.raspberrypi.org/products/camera-module-v2/?resellerType=home> (accessed Nov. 01, 2020).
- [28] T. R. P. Foundation, "Buy a Pi NoIR Camera V2," *Raspberry Pi*. <https://www.raspberrypi.org/products/pi-noir-camera-v2/?resellerType=home> (accessed Nov. 01, 2020).
- [29] T. R. P. Foundation, "Buy a Raspberry Pi High Quality Camera," *Raspberry Pi*. <https://www.raspberrypi.org/products/raspberry-pi-high-quality-camera/?resellerType=home> (accessed Nov. 01, 2020).
- [30] "Intel RealSense depth camera SR305," *Intel® RealSense™ Depth and Tracking Cameras*. <https://www.intelrealsense.com/depth-camera-sr305/> (accessed Nov. 01, 2020).
- [31] "Depth Camera D415," *Intel® RealSense™ Depth and Tracking Cameras*. <https://www.intelrealsense.com/depth-camera-d415/> (accessed Nov. 01, 2020).
- [32] "Introducing the Intel® RealSense™ Depth Camera D455," *Intel® RealSense™ Depth and Tracking Cameras*. <https://www.intelrealsense.com/depth-camera-d455/> (accessed Nov. 01, 2020).
- [33] "Compare Intel RealSense Depth Cameras (Tech specs and Review)," *Intel® RealSense™ Depth and Tracking Cameras*. <https://www.intelrealsense.com/compare-depth-cameras/> (accessed Nov. 01, 2020).
- [34] "Dimensional weight software," *Intel® RealSense™ Depth and Tracking Cameras*. <https://www.intelrealsense.com/dimensional-weight-software/> (accessed Nov. 01, 2020).
- [35] "Intel® RealSense™ LiDAR Camera L515," *Intel® RealSense™ Depth and Tracking Cameras*. <https://www.intelrealsense.com/lidar-camera-l515/> (accessed Nov. 01, 2020).
- [36] Gomag, "Alimentator oficial Raspberry Pi 4 Model B - negru cu conector USB-C si priza EU." <https://www.robofun.ro/raspberry-pi-23/alimentator-oficial-raspberry-pi-4-model-b-negru-cu-conector-usb-c-si-priza-eu.html> (accessed Nov. 01, 2020).
- [37] T. R. P. Foundation, "Buy a Raspberry Pi 15.3W USB-C Power Supply," *Raspberry Pi*. <https://www.raspberrypi.org/products/type-c-power-supply/?resellerType=home> (accessed Nov. 01, 2020).
- [38] Gomag, "Carcasa aluminiu cu doua ventilatoare pentru Raspberry Pi 4 model B." <https://www.robofun.ro/accesorii/carcasa-aluminiu-doua-ventilatoare-raspberry-pi-4-model-b.html> (accessed Nov. 01, 2020).
- [39] "Card microSDHC 32GB Kingston Canvas Select + Adaptor," *Optimus Digital*. <https://www.optimusdigital.ro/ro/memorii/6834-card-microsdhc-32gb-kingston-canvas-select-adaptor.html> (accessed Nov. 01, 2020).
- [40] "Obiectiv 6mm WIDE pentru cameră Raspberry Pi HQ," *Clește*. <https://cleste.ro/obiectiv-de-6-mm-pentru-camera-foto-raspberry-pi.html> (accessed Nov. 01, 2020).
- [41] "Obiectiv 16mm TELEPHOTO pentru cameră Raspberry Pi HQ," *Clește*. <https://cleste.ro/obiectiv-de-16-mm-pentru-aparat-foto-raspberry-pi.html> (accessed Nov. 01, 2020).
- [42] R. Pydipati, T. F. Burks, and W. S. Lee, "Identification of citrus disease using color texture features and discriminant analysis," *Comput. Electron. Agric.*, vol. 52, no. 1, pp. 49–59, Jun. 2006, doi: 10.1016/j.compag.2006.01.004.
- [43] K.-Y. Huang, "Application of artificial neural network for detecting Phalaenopsis seedling diseases using color and texture features," *Comput. Electron. Agric.*, vol. 57, no. 1, pp. 3–11, May 2007, doi: 10.1016/j.compag.2007.01.015.
- [44] "Application of Support Vector Machine for Detecting Rice Diseases Using Shape and Color Texture Features." <https://www.computer.org/csdl/proceedings-article/icec/2009/3655a079/12OmNx76TWS> (accessed Dec. 03, 2020).
- [45] M. Zhang and Q. Meng, "Automatic citrus canker detection from leaf images captured in field," *Pattern Recognit. Lett.*, vol. 32, no. 15, pp. 2036–2046, Nov. 2011, doi: 10.1016/j.patrec.2011.08.003.
- [46] H. Wang, G. Li, Z. Ma, and X. Li, "Image recognition of plant diseases based on principal component analysis and neural networks," in *2012 8th International Conference on Natural Computation*, May 2012, pp. 246–251, doi: 10.1109/ICNC.2012.6234701.
- [47] A. Selvaraj, N. Shebiah, S. Ananthi, and S. Varthini, "Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features," *Agric. Eng. Int. CIGR J.*, vol. 15, pp. 211–217, Jan. 2013.
- [48] E. K. Ratnasari, M. Mentari, R. K. Dewi, and R. V. H. Ginardi, "Sugarcane leaf disease detection and severity estimation based on segmented spots image," in *Proceedings of International Conference on Information, Communication Technology and System (ICTS) 2014*, Sep. 2014, pp. 93–98, doi: 10.1109/ICTS.2014.7010564.
- [49] M. Ali, U. Mokhtar, A. E. Hassanien, and H. Hefny, "Tomato leaves diseases detection approach based on Support Vector Machines," Dec. 2015, doi: 10.1109/ICENCO.2015.7416356.

- [50] F. Qin, D. Liu, B. Sun, L. Ruan, Z. Ma, and H. Wang, "Identification of Alfalfa Leaf Diseases Using Image Recognition Technology," *PLOS ONE*, vol. 11, no. 12, p. e0168274, Dec. 2016, doi: 10.1371/journal.pone.0168274.
- [51] Y. Es-saady, I. E. Massi, M. E. Yassa, D. Mammass, and A. Benazoun, "Automatic recognition of plant leaves diseases based on serial combination of two SVM classifiers," in *2016 International Conference on Electrical and Information Technologies (ICEIT)*, May 2016, pp. 561–566, doi: 10.1109/EITech.2016.7519661.
- [52] H. Ali, M. I. Lali, M. Z. Nawaz, M. Sharif, and B. A. Saleem, "Symptom based automated detection of citrus diseases using color histogram and textural descriptors," *Comput. Electron. Agric.*, vol. 138, pp. 92–104, Jun. 2017, doi: 10.1016/j.compag.2017.04.008.
- [53] M. Al-Otaibi, A. S. Ashour, N. Dey, R. Quthami, A. AL-Nufaei, and S. Fuqian, "Statistical Image Analysis based Automated leaves Classification," May 2017.
- [54] S. S. Chouhan, A. Kaul, U. P. Singh, and S. Jain, "Bacterial Foraging Optimization Based Radial Basis Function Neural Network (BRBFNN) for Identification and Classification of Plant Leaf Diseases: An Automatic Approach Towards Plant Pathology," *IEEE Access*, vol. 6, pp. 8852–8863, 2018, doi: 10.1109/ACCESS.2018.2800685.
- [55] S. Zhang, H. Wang, W. Huang, and Z. You, "Plant diseased leaf segmentation and recognition by fusion of superpixel, K-means and PHOG," *Optik*, vol. 157, pp. 866–872, Mar. 2018, doi: 10.1016/j.ijleo.2017.11.190.
- [56] A. Picon, A. Alvarez-Gila, M. Seitz, A. Ortiz-Barredo, J. Echazarra, and A. Johannes, "Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild," *Comput. Electron. Agric.*, vol. 161, pp. 280–290, Jun. 2019, doi: 10.1016/j.compag.2018.04.002.
- [57] M. Nababan *et al.*, "The diagnose of oil palm disease using Naive Bayes Method based on Expert System Technology," *J. Phys. Conf. Ser.*, vol. 1007, no. 1, p. 012015, Apr. 2018, doi: 10.1088/1742-6596/1007/1/012015.
- [58] A. F. Fuentes, S. Yoon, J. Lee, and D. S. Park, "High-Performance Deep Neural Network-Based Tomato Plant Diseases and Pests Diagnosis System With Refinement Filter Bank," *Front. Plant Sci.*, vol. 9, 2018, doi: 10.3389/fpls.2018.01162.