

Universitatea „1 Decembrie 1918” din Alba Iulia

Anul universitar 2018-2019,

**RECUNOAȘTEREA CARACTERELOR INSCRIȚIONATE PE OBIECTE  
CERAMICE FOLOSIND TEHNICI DE VEDERE ARTIFICIALĂ ȘI ÎNVĂȚARE  
AUTOMATĂ PROFUNDĂ**

RAPORT de CERCETARE

**Autor:** masterand Oancea Maria Nicoleta,  
Facultatea de Științe Exacte și Inginerești,  
specializarea: Programare Avansată și Baze de Date,  
anul de studiu: II

**Profesor coordonator:** Conf. univ. dr. Adriana Birluțiu

## Cuprins

INTRODUCERE.....	2
I. METODEDE ȘI INSTRUMENTE DE CERCETARE UTILIZATE .....	3
I.1. Tehnici de vedere artificială .....	3
I.2. Rețele neuronale adânci.....	4
I.3. Rețele neuronale convoluționale .....	4
II. REZULTATE OBȚINUTE ÎN URMA CERCETĂRII.....	5
II.1. Descrierea setului de date utilizat .....	5
II.2. Limbajul și pachetele utilizate.....	6
II.3. Prezentarea aplicației dezvoltate .....	7

II.4. Rezultate obținute.....	11
II.5. Vederea artificială în literatura de specialitate.....	12
III. COMENTARIII ASUPRA REZULTATELOR OBȚINUTE .....	13
CONCLUZIILE CERCETĂRII .....	13

## INTRODUCERE

Proiectul dezvoltat sub coordonarea doamnei Conf. univ. dr. Adriana Birluțiu în cadrul bursei de performanță științifică a avut ca obiectiv dezvoltarea unui sistem inteligent care să fie capabil să recunoască caracterele inscripționate pe obiectele ceramice.

Pe perioada celor 6 luni în care s-a desfășurat proiectul de cercetare ne-am propus studiul unei teme actuale și cu mare potențial în viitor bazată pe învățare profundă și tehnici de vedere artificială. Aceste două concepte se îmbină perfect și își găsesc utilizare în tot mai multe domenii precum: automotiv, producție, sănătate, agricultură sau unele aplicații social media.

**Rețele neuronale adânci** (*en. Deep Learning*) sunt considerate o ramură a învățării automate (*en. Machine Learning*) care are rezultate foarte bune în recunoașterea și clasificarea imaginilor precum și a vocii. Calitatea rezultatelor obținute de aceste rețele neuronale este strâns legată de volumul setului de date folosit pentru antrenare cât și de calitatea imaginilor. Cu cât setul de date este mai consistent și de o calitate net superioară cu atât rezultatele sunt mai precise uneori ajungându-se chiar la o acuratețe de peste 95%.

**Vederea artificială** este un concept care definește operațiunile efectuate pentru a oferi calculatoarelor capacitatea de a vedea în mod asemănător omului. Această tehnologie este tot mai populară și implementată pe tot mai multe dispozitive și sisteme software. Vederea artificială este tot mai căutată în ziua de azi deoarece pe piață este o tendință majoră de automatizare a cât mai multor activități cotidiene și nu numai.

Rezultatele obținute pe perioada desfășurării proiectului de cercetare științifică au fost prezentate la sesiunea de comunicări științifice a studenților *In-Extenso*, Ediția A XIX-A din 12 aprilie 2019 desfășurată de Universitatea “1 Decembrie 1918” din Alba Iulia și publicate în

volumul aferent sesiunii în lucrarea cu titlul *Recunoașterea caracterelor inscripționate pe obiecte ceramice folosind tehnici de vedere artificială și învățare automată profundă*. [1]

Rezultatele acestei activități de cercetare au fost prezentate și la sesiunea de comunicări a cercurilor științifice studențești în domeniile - inginerie electrică, electronică, control și calculatoare *SCCSS-IEECC*, Ediția A VI-A din 5-6 iunie 2019 desfășurată la Universitatea "Lucian Blaga" din Sibiu. Lucrarea *Tehnici de vedere artificială și învățare automată pentru optimizarea procesului de producție în industria porțelanului* a fost realizată împreună cu Copîndean Alin Gabriel și Golgoț Mihai Radu. [2]

Scopul acestei cercetări a fost implementarea unei aplicații care să fie capabilă să recunoască caracterele inscripționate pe farfurii. Primul pas a fost procesarea imaginilor prin tehnici de vedere artificială pentru a le îmbunătăți calitatea și a ușura procesul de recunoaștere a caracterelor. Al doilea pas a fost recunoașterea caracterelor ștanțate pe obiectele ceramice folosind rețelele neuronale de învățare profundă.

Această aplicație este utilă în industria porțelanului deoarece reduce semnificativ timpii și costurile de producție permițând automatizarea completă a procesului de fabricație.

## **I. METODE ȘI INSTRUMENTE DE CERCETARE UTILIZATE**

### **I.1. Tehnici de vedere artificială**

Vederea artificială poate fi definită ca un domeniu științific de interes care se află la intersecția dintre informatică, matematică, inginerie, biologie și psihologie. Aceasta își propune să reproducă vederea umană pe diferite dispozitive [1].

La baza vederii artificiale stau trei elemente majore: procesarea imaginilor, segmentarea imaginilor și inteligența artificială. Combinarea celor trei elemente și adăugarea de noi tehnici mult mai avansate va permite în viitor unui calculator să vadă lumea înconjurătoare în mod asemănător omului, primii pași spre această direcție fiind făcuți deja.

Procesarea imaginilor presupune aplicarea unor algoritmi de îmbunătățirea a calității sau a extragerii zonelor de interes. Procesarea digitală a imaginilor se ocupă în principal de: identificarea unor pattern-uri, clasificare, extragerea zonelor de interes și proiecția grafică [3].

## I.2. Rețele neuronale adânci

O subramură a învățării automate o constituie învățarea profundă (*Deep Learning*). Acest tip de rețea neuronală este alcătuită din mai multe straturi ascunse fiecare strat îndeplinind o anumită funcție. Acest mod de organizare crește cu mult performanța rezultatelor obținute.

Pentru crearea unei rețele neuronale adânci care să execute sarcini cât mai apropiate de cele executate de om este nevoie de un volum imens de date pentru antrenarea ei. În ziua de azi oamenii creează acest volum de date care ar putea fi folosite pentru antrenarea unei astfel de rețele, dar marea problemă este etichetarea datelor. Împărțirea datelor și selectarea lor este un proces care trebuie efectuat de oameni ceea ce implică un consum de timp și de forță umană.

În prezent rețelele profunde au început să se integreze în cât mai multe activități cotidiene îndeplinind sarcini precum: asistenți virtuali (exemplu Cortana, Alexa și Siri), traducători, șoferi automați, recunoașterea facială, medicină, sisteme de recomandări [4]. Rețelele Deep Learning sunt excelente în recunoașterea imaginilor și a sunetelor dar și în sistemele de recomandări. Un exemplu bun de a scoate în evidență performanța acestui tip de rețele este algoritmul dezvoltat de *DeepMind*, *AlphaGo*, care a bătut campionul mondial, Lee Sedol, la Go din 2016 și pe noul campion mondial din 2017, Ke Jie [5].

## I.3. Rețele neuronale convoluționale

Rețelele neuronale convoluționale (en. *Convolutional Neural Network (CNN)*) pot fi considerate o subcategorie a rețelelor neuronale adânci și au fost menționate pentru prima dată în anul 1940 dar au putut fi folosite abia mulți ani mai târziu din cauza resurselor hardware care erau mult inferioare la acea vreme. Acest tip de rețele necesită o putere imensă de procesare și un volum mare de date dar obțin rezultate excelente în recunoașterea imaginilor și a textului [6].

Denumirea acestor rețele este dată după operația matematică de convoluție. Convoluția este o operație în care două funcții produc o a treia funcție care arată cum forma uneia este modificată de cealaltă. Convoluția este similară corelației încrucișate [7].

Rețelele neuronale convoluționale folosesc filtre care analizează pixelii din jur și pe baza relației de convoluție calculează o nouă valoare, acest procedeu este reprezentat în *Fig. 1.1* [8]. Acest tip de rețele neuronale sunt excelente în analizarea imaginilor și a textului,

fiind folosite într-o gamă variată de domenii. De exemplu în medicină au reușit să dea diagnostice la fel de bine ca un medic cu mulți ani de experiență.




Fig. 1.1: Operația de convoluție

Sursa: [https://cdn-images-1.medium.com/max/1600/1\\*p-47puSuVNmRjNjOXYPQCg.png](https://cdn-images-1.medium.com/max/1600/1*p-47puSuVNmRjNjOXYPQCg.png)

## II. REZULTATE OBȚINUTE ÎN URMA CERCETĂRII

### II.1. Descrierea setului de date utilizat

Acest proiect de cercetare a fost o continuare a unui studiu publicat într-un articol științific [9], motiv pentru care în prima fază am folosit rețeaua neuronală dezvoltată în acel studiu. Acea rețea neuronală a fost antrenată pe un set de aproximativ 10000 de imagini. Folosind acea rețea am încercat să implementez recunoașterea caracterelor pe farfuriile dreptunghiulare, prima versiune a aplicației recunoștea caracterele doar de pe farfuriile rotunde.

Setul de date pe care am lucrat conține 50 de imagini cu farfuriile dreptunghiulare obținute de la o companie care activează în industria porțelanului și cu care universitatea noastră are un parteneriat de colaborare. Un exemplu de astfel de imagine este redat în Fig 2.1.



**Fig 2.1: Exemplu de imagine analizată pentru recunoașterea caracterelor ștanțate pe farfurii.**

Deoarece rezultatele obținute în procesul de recunoaștere a caracterelor nu au fost cele așteptate am ajuns la concluzia că rețeaua neuronală trebuie reantrenată adăugându-se mai multe imagini dintr-o gamă mult mai variată de tipuri. Pentru aceasta am început etichetarea unui nou set de date. La momentul actual avem în jur de 1000 de imagini noi etichetate. Când reușim să etichetăm un nou set de aproximativ 10000 de imagini vom reantrena rețeaua neuronală, aplicând și noi algoritmi pentru îmbunătățirea rezultatelor.

## **II.2. Limbajul și pachetele utilizate**

Pentru realizarea experimentelor propuse în această lucrare științifică s-a folosit Matlab și pachetele: Deep Learning Toolbox, Image Processing Toolbox și Statistics and Machine Learning Toolbox [10].

**Matlab** este un limbaj de programare bazat pe matrici care poate fi integrat cu alte limbaje de programare. Ingineri și oameni de știință din întreaga lume îl folosesc pentru a analiza și proiecta sisteme și produse care ne influențează viața.

**Deep Learning Toolbox** oferă un framework pentru proiectarea și implementarea rețelelor neuronale profunde. Acest pachet vine cu un set de algoritmi, modele precompilate și aplicații care ușurează munca de dezvoltare a unui algoritm de recunoaștere a formelor, obiectelor sau caracterelor; sau a oricărui alt algoritm de *deep learning*.

**Image Processing Toolbox** oferă o gamă variată de algoritmi de procesare, analiză, vizualizare și dezvoltare de imagini. Acest pachet poate fi folosit pentru segmentarea și îmbunătățirea imaginilor, reducerea zgomotului și pentru diverse transformări geometrice.

**Statistics and Machine Learning Toolbox** oferă funcții și aplicații pentru a descrie, analiza și modela datele. Setul de instrumente conține algoritmi de învățare automată supervizată și nesupervizată.

### II.3. Prezentarea aplicației dezvoltate

Primul pas în identificarea caracterelor inscripționate pe obiectele ceramice este identificarea zonei în care acestea sunt ștanțate. După ce s-au identificat zonele se extrage din imaginea în care este reprezentată farfuria doar segmentele de interes. Acest proces este cunoscut sub numele de segmentarea imaginii.

Pentru fiecare segment de imagine obținut se stabilește dacă conține unul sau mai multe caractere. În cazul în care un segment conține mai multe caractere acesta este împărțit la rândul sau în alte subsegmente.

După ce imaginea a fost segmentată la nivel de caracter se folosește rețeaua neuronală pentru a identifica simbolurile.

Deoarece imaginea în care este reprezentat obiectul ceramic conține și alte informații ne semnificative cum ar fi mediul unde a fost făcută, este important să se identifice conturul farfuriei și să se extragă doar acea zonă pentru următoarele procesări. Procedul de identificare a conturului este următorul:

- Imaginea se convertește în alb negru
- Se elimină toate zonele conectate care conțin un număr de pixeli mai mic decât o valoare care se stabilește prin teste (aci s-a ales valoarea 80), pentru aceasta se folosește funcția *bwareaopen*.
- Se găsește zona în care se află farfuria folosind funcția *regionprops*, care permite identificarea regiunilor conectate, și măsurarea proprietăților acestora.

Secvența de cod prin care sunt efectuate aceste operațiuni dar și alte elemente de procesare este reprezentată în *Fig. 2. 2*, iar rezultatul obținut în *Fig. 2.3*.

```

% to gray
Ig = rgb2gray(I);
% to black and white
Ibw = im2bw(Ig,graythresh(Ig));

% erode holes
Ibw2 = bwareaopen(Ibw, 80, 8);
SE = strel('disk',4);
Ibw2 = imerode(Ibw2,SE);

% Find conected region and their properties
stats = regionprops(Ibw2,'boundingbox','Area','Perimeter');

```

Fig. 2.2: Procesarea imaginii și identificarea zonei în care se găsește farfuria.




Fig. 2.3: Încadrarea zonei în care se găsește farfuria.

La farfuriile dreptunghiulare caracterele sunt inscripționate fie pe partea dreaptă fie pe partea stângă. Având această informație este important să extragem din imagine doar partea pe care se găsesc ștanțate caracterele. Pași pentru identificarea părții care conține simbolurile sunt:

- Se identifică contururile din imagine folosind funcția *edge*, cu cât valoarea pragului este mai mică cu atât se găsesc mai multe margini. Valoarea optimă s-a obținut prin teste succesive și este de 0.15
- Pe baza marginilor obținute se aplică funcția *imdilate* care dilatează imaginea scoțând în evidență zonele în care se găsesc caracterele



- Se identifică zonele conectate care au o arie mai mică de 25000 (valoare obținută prin încercări)
- Se împarte imaginea în două părți
- Se numără zonele conexe din ambele părți. Se stabilește mijlocul imaginii și toate zonele conexe care au coordonatele mai mici decât jumătatea imaginii pe X, se numără ca fiind zone din partea stângă; iar cele cu coordonate mai mare ca fiind din partea dreaptă.
- Pe baza valorilor obținute se stabilește pe ce parte sunt ștanțate caracterele, stânga sau dreapta.
- Se extrage din imagine segmentul care încadrează toate caracterele


O parte din secvența de cod care face cele menționate mai sus este reprezentată în *Fig. 2.4*, iar rezultatul obținut se regăsește în *Fig. 2.5*.

```

Ig = rgb2gray(I1);
Ig_ad = imadjust(Ig);
% Edge detection
I_edge = edge(Ig_ad, 'Canny', 0.15, 2.0);
% Dilate edge
SE = strel('Disk', 18, 4);
I_edge = imdilate(I_edge, SE);
% Find connected region and their properties
stats = regionprops(I_edge, 'Area', 'BoundingBox', 'Orientation');


```

*Fig. 2.4:* Secvența de cod prin care se identifică zona în care sunt inscripționate caracterele.



*Fig. 2.5:* Zona în care sunt ștanțate caracterele.

După ce s-a identificat partea care conține caracterele (în exemplul prezentat partea stângă) se trece la un nivel și mai detaliat de segmentare și anume identificarea segmentelor care conțin caracterele ștanțate. Aceste acțiuni se execută folosind pașii menționați mai sus. În *Fig. 2.6* este reprezentat rezultatul obținut.



**Fig. 2.6:** În partea stângă este reprezentată identificarea zonelor cu caracterele pe imaginea alb-negru, iar în partea dreaptă pe imaginea color cu care se va lucra mai departe

Pe baza informațiilor obținute se extrag segmentele de imagine care conțin caracterele. Rezultatul obținut în urma aplicării algoritmului de extracție este reprezentat în *Fig. 2.7*.



**Fig. 2.7:** Caracterele și grupurile de caractere după extragerea din imagine.

Pentru fiecare imagine obținută se trece la recunoașterea caracterului sau a caracterelor inscripționate. Deoarece rețeaua neuronală a fost antrenată doar pe anumite tipuri de farfurii și nu conținea informații cu toate caracterele s-a hotărât să se facă doar recunoașterea caracterului "E" (care reprezintă tura de producție). Pentru identificare se folosește funcția

*classify* care primește ca input rețeaua neuronală și imaginea și returnează valoarea caracterului inscripționat în imagine. Secvența de cod care face cele menționate este reprezentată în *Fig. 2.8*.

```
332 - grayIm = imresize(grayIm, [53 26]);
333 - [label, score] = classify(convnet, grayIm(:,:,1));
334 - labels = [labels label];
335 - scores = [scores max(score)];
336
```

---

Command Window

```
ans =
    'E'
```

*Fig. 2.8: Secvența de cod prin care se clasifică caracterele din imagine.*

#### II.4. Rezultate obținute

Din cele 50 de imagini analizate, a fost identificat corect caracterul "E" în 10 (20%) dintre acestea, în 30 (60%) dintre ele s-a obținut ca și rezultat caracterul "9" (care este apropiat de E), iar în celelalte 10 (20%) imagini s-au clasificat ca fiind alte caractere.

Aceste rezultate s-au obținut din cauză că s-a folosit o rețea neuronală care a fost antrenată pe un alt tip de farfurii, în care caracterul "9" seamănă mult cu caracterul "E" din setul curent de farfurii. Un alt motiv al obținerii acestor rezultate este calitatea mult mai scăzută a imaginilor. În *Fig. 2.9* sunt reprezentate cele două caractere, în partea stângă este caracterul "9" inscripționat pe primul tip de farfurii, iar în partea dreaptă este caracterul "E" ștanțat pe actualul tip de farfurii.



*Fig. 2.9: Reprezentarea caracterului "9" și "E".*

## II.5. Vederea artificială în literatura de specialitate

În prezent în literatura de specialitate nu există menționări despre recunoașterea caracterelor inscripționate pe obiectele ceramice, existând doar câteva articole de cercetare. Cel mai relevant articol [9] fiind cel de la care a plecat și cercetarea de față.

Deși nu sunt exemple din industria porțelanului trebuie menționate companiile care au implementat vederea artificială îmbinată cu rețelele neuronale adânci în linia de producție [11]:

- **Aquifi** – combină senzorii 3D cu deep learning pentru a crea o vedere 3D fluidă. Această implementare este utilă în automatizarea industriei și în controlul calității.
- **LMI Technologies** - a implementat o serie de scanner-e și senzori laser pe linia de producție care sunt capabili să măsoare obiectele și să le verifice defectele la viteza liniei de producție.
- **Prophesee** – și-a propus crearea unor mașini industriale care să fie capabile să manipuleze obiectele, să le inspecteze și să le urmărească.
- **3D Infotech** – folosește lumina albastră și lasere pentru a putea măsura obiectele de pe bandă în timp real.
- **VAIA Technologies** - oferă soluții în procesul de ambalare și etichetare a produselor prin implementarea unui soft care este capabil să citească etichetele și să identifice dacă sunt corecte sau nu.
- **Stemmer Imaging** – au automatizat procesul de inspecție pe linia de producție.
- **Industrial Vision** - au creat aparate de fotografiat pentru industria mașinilor cu scopul de a automatiza procesul de producție și pe partea de inspecție a calității.
- **Pick-It 3D** – a creat un robot care este capabil să scaneze obiectele de pe banda de producție și să le amplaseze în poziția corectă.

### III. COMENTARIILE ASUPRA REZULTATELOR OBTINUTE

Experimentele realizate în acest proiect de cercetare au îmbinat tehnicile de vedere artificială cu rețelele neuronale adânci și rețelele neuronale convoluționale cu scopul creării unei aplicații care să poată recunoaște caracterele inscripționate pe obiectele ceramice.

Rezultatele experimentale obținute în acest proiect de cercetare au fost prezentate la sesiunea de comunicări științifice a studenților *In-Extenso*, Ediția A XIX-A din 12 aprilie 2019 desfășurată de Universitatea "1 Decembrie 1918" din Alba Iulia unde am obținut o **Mențiune** și la sesiunea de comunicări a cercurilor științifice studențești în domeniile - inginerie electrică, electronică, control și calculatoare *SCCSS-IEECC*, Ediția A VI-A din 5-6 iunie 2019 desfășurată la Universitatea "Lucian Blaga" din Sibiu unde lucrarea prezentată a obținut **Premiu Special**.

### CONCLUZIILE CERCETĂRII

În acest raport s-a demonstrat că se pot recunoaște caracterele inscripționate pe obiecte ceramice folosind tehnici de vedere artificială, Deep Learning și rețele neuronale convoluționale.

Aplicația dezvoltată în acest proiect de cercetare vine în sprijinul companiilor din industria porțelanului care au nevoie de identificarea caracterelor ștanțate pe obiecte ceramice cu scopul de a automatiza procesul de control al calității.

### BIBLIOGRAFIE

[1] Oancea Maria-Nicoleta, *Recunoașterea caracterelor inscripționate pe obiecte ceramice folosind tehnici de vedere artificială și învățare automată profundă*. TOM II Științe Exacte și Inginerești, IN-EXTENSO Nr. 6/2019, Ed. Aeternitas, Alba Iulia, 2019, ISSN 2360 - 0675, ISSN-L 2360 - 0675

[2] Copîndean Alin Gabriel, Golgoț Mihai Radu, Oancea Maria Nicoleta, *Tehnici de vedere artificială și învățare automată pentru optimizarea procesului de producție în industria porțelanului*, Sibiu.....

- [3] Robert Boscacci, *What Even is Computer Vision?*, 16 decembrie 2018, URL: <https://towardsdatascience.com/what-even-is-computer-vision-531e4f07d7d0>
- [4] Bernard Marr, *What Is Deep Learning AI? A Simple Guide With 8 Practical Examples*, 1 octombrie 2018, URL: <https://www.forbes.com/sites/bernardmarr/2018/10/01/what-is-deep-learning-ai-a-simple-guide-with-8-practical-examples/#ae4f0ab8d4ba>
- [5] *Artificial Intelligence (AI) vs. Machine Learning vs. Deep Learning*, URL: <https://skymind.ai/wiki/ai-vs-machine-learning-vs-deep-learning>
- [6] Tristan Greene , *A beginner's guide to AI: Neural networks*, URL: <https://thenextweb.com/artificial-intelligence/2018/07/03/a-beginners-guide-to-ai-neural-networks/>
- [7] *Convolution*, URL: <http://mathworld.wolfram.com/Convolution.html>
- [8] Matthew Stewart, *Simple Introduction to Convolutional Neural Networks*, 7 februarie 2019, URL: <https://towardsdatascience.com/simple-introduction-to-convolutional-neural-networks-cdf8d3077bac>
- [9] D.A. Sanchez, S.G. Bulon, L. Moreno, A. Birlutiu, M. Kadar. *Automatic Character Recognition in Porcelain Ware*, ACTA TECHNICA NAPOCENSIS – Electronica - telecomunicatii (Electronics and Telecommunications) ISSN 1221 – 6542, vol. 59, nr.3/2018-seria electronica.
- [10] *Matlab*, URL: <https://www.mathworks.com/help/matlab/>
- [11] George Kollias, *Machine Vision: 8 Companies that enable Industrial Robots to see*, 13 martie 2018, URL: <https://medium.com/smarterchains/machine-vision-8-companies-that-enable-robots-to-see-a2f0f9562feb>