



(12)

## CERERE DE BREVET DE INVENȚIE

(21) Nr. cerere: a 2019 00388

(22) Data de depozit: 27/06/2019

(41) Data publicării cererii:  
30/12/2020 BOPI nr. 12/2020

(71) Solicitant:  
• **ACTIV ROBIONIC S.R.L.**,  
STR.PETRU MAIOR, NR.61, SECTOR 1,  
BUCUREȘTI, B, RO

(72) Inventatori:  
• **NECULA LUCIAN**, STR.PATRIOTILOR,  
NR.9, BL.PM 7, SC.A, AP.32, SECTOR 3,  
BUCUREȘTI, B, RO;

• **COSTEA MARIANA**,  
STR.CONSTANTIN LANGA, NR.1031, SAT  
MIROSLAVA, IAȘI, IS, RO;  
• **SARGHIE BOGDAN THEODOR**,  
STR.FRUMOASA, NR.12, BL.636B, SC.B,  
ET.4, AP.12, IAȘI, IS, RO;  
• **MIHAI AURA**, ALEEA SALCĂMILOR,  
NR. 11, IAȘI, IS, RO;  
• **GHEBUTA FLOREA**, STR.OLĂNEȘTI,  
NR.3, BL.76A, SC.1, ET.8, AP.53,  
BUCUREȘTI, B, RO

(54) **METODĂ DE ETALONARE A PRESIUNILOR PLANTARE  
PRIN CORELAREA DINTRE VALORILE PRESIUNILOR  
ȘI CULORILE CORESPONDENTE DE LA IMAGINEA SURSĂ  
ȘI IMAGINEA ȚINTĂ**

(57) Rezumat:

Invenția se referă la o metodă de etalonare a presiunilor plantare prin corelarea dintre valorile presiunilor și culorilor corespundente de la o imagine sursă cu cele de la o imagine considerată etalon. Metoda conform invenției cuprinde următoarele etape: preprocesarea imaginii care constă în preluarea unei imagini RGB color și transformarea acesteia în spațiul de culoare CIELUV, urmată de separarea imaginii în două imagini noi: una doar cu componenta L și una doar cu componentele U și V, apoi, pornind de la imaginile preprocesate, se trece la etapa de construire a setului de date pentru etapa de antrenare a unei rețele neuronale, aceasta din urmă fiind efectuată cu ajutorul unui algoritm de propagare inversă, într-un proces de tip batch, folosind setul de date construit anterior, iar după antrenarea rețelei neuronale se trece la efectuarea procesului de colorizare care constă în trei pași principali pentru fiecare pixel având un nivel de gri al imaginii, și

anume: se utilizează rețeaua neuronală pentru a prezice un indice din lista de coduri pentru pixeli, indicele și lista de coduri fiind folosite pentru a obține componentele U și V ale pixelului, se combină componenta L din imaginea sursă cu valorile prezise ale componentelor U și V pentru a obține în final pixelul cu cele trei componente R, G și B.

Revendicări: 1


Figuri: 5



Fig. 1

Cu începere de la data publicării cererii de brevet, cererea asigură, în mod provizoriu, solicitantului, protecția conferită potrivit dispozițiilor art.32 din Legea nr.64/1991, cu excepția cazurilor în care cererea de brevet de invenție a fost respinsă, retrasă sau considerată ca fiind retrasă. Întinderea protecției conferite de cererea de brevet de invenție este determinată de revendicările conținute în cererea publicată în conformitate cu art.23 alin.(1) - (3).





## **Metodă de etalonare a presiunilor plantare prin corelarea dintre valorile presiunilor și culorile corespondente de la imaginea sursă și imaginea țintă**

Invenția se referă la o metodă de mapare a culorilor folosind rețele neuronale și anume folosind un set de date de antrenament format dintr-o serie de imagini sursă și o serie de imagine țintă, prin care antrenăm o rețea neuronală, urmând ca apoi această rețea să fie folosită ca funcție de predicție pentru alte seturi de imagini [4, 7].

Metoda este folosită pentru etalonarea presiunilor pentru amprenta plantară și pentru efectuarea de măsurători și corelarea dintre valorile presiunilor și culorilor corespondente de la imaginea sursă cu valorile presiunilor și a culorilor de la o imagine obținută cu un sistem de senzori rezistivi, considerată etalon. Pentru a realiza aceste deziderate propunerea principală constă în utilizarea unei rețele neuronale (NN) care va învăța relațiile dintre setul de date sursă și setul de date țintă [8].

Această abordare cuprinde o serie de pași pentru pregătirea imaginii:

- reducerea dimensiunii problemei;
- antrenarea rețelei neuronale;
- post procesarea imaginii rezultate.

Fluxul de activități de antrenare a rețelei este reprezentat în figura 1 (Fluxul general de activități de antrenament).

Primul pas este preprocesarea imaginii care în principal constă în preluarea unei imagini RGB color și transformarea acesteia în spațiul de culoare CIELUV. Apoi al doilea pas al preprocesării imaginii este de a separa imaginea în două imagini noi: una cu doar componenta L și una cu componentele U și V [2].

În scopul reducerii spațiului de valori posibile necesare pentru a antrena (a învăța) rețeaua neuronală este propusă reducerea intervalului de culori. Pentru a îndeplini acest obiectiv va fi folosită tehnica de *cuantificare vectorială* [9].

Pornind de la imaginile preprocesate și folosind lista de indecși ai culorilor, următorul pas este construirea setului de date pentru instruire.

Rețeaua neuronală (NN) de clasificare folosită este o rețea multistart. Obiectivul NN este de a clasifica fiecare patch din clusterul SOM corespunzător pixelului central. Antrenarea NN se face cu algoritm de propagare inversă (back-propagation algorithm) într-un proces de tip batch folosind setul de date anterior construit, figura 2 (Fluxul antrenării rețelei neuronale) [3, 6].

În cele din urmă după ce a fost antrenată rețeaua neuronală (NN) ce conține relațiile dintre valorile cromatice a imaginii color și a imaginii ce conține reprezentarea izobară a distribuției presiunii plantare, este posibil să colorizăm o imagine arbitrară folosind aceste relații și să obținem o reprezentare izobară [1].

Procesul de colorizare constă în trei pași principali pentru fiecare pixel de nivel de gri imagine:

- Este utilizată rețeaua neuronală (NN) pentru a prezice indexul din lista de coduri pentru pixeli.
- Indexul și lista de coduri sunt folosite pentru a obține componente U și V ale pixelului.
- Combinăm componenta L din imaginea sursă cu valorile prezise ale componentelor U și V pentru a obține în final pixelul cu cele 3 componente R, G, B.

Este important de observat că datorită procesului de reducere a spațiului culorii imaginea finală obținută va avea o dimensiune redusă pentru numărul de culori. Spațiul de culoare al imaginii finale va depinde de dimensiunea rețelei SOM utilizată [10].

Datele folosite pentru studiu de caz consistă din 4 seturi și anume: 2 seturi cu înregistrări ce conțin peisaje diferite: lacuri, vegetație, lanțuri muntoase și 2 seturi cu înregistrări ale amprentei plantare. Înregistrările variază în calitate, condiții atmosferice și informație cromatică.

Pentru a obține o cantitate suficientă de informație necesară antrenării rețelei neuronale au fost procesate cantități variate de pixeli selectați aleatoriu din seturile de date. S-au folosit diferite valori pentru arhitectura rețelei neuronale precum și diferite rate de învățare [1].

În experimentele efectuate au fost testate diferite valori pentru dimensiunea rețelei SOM și anume: 9, 25, 100, 400 neuroni. Pentru fiecare dimensiune a fost antrenată rețeaua folosind același set de date și au fost obținute erorile reziduale prezentate în tabelul 1.

Predicțiile pot fi văzute în tabelul 2 și tabelul 3. Prima coloană conține imaginea sursă, a doua coloană conține imaginea țintă iar în a treia coloană este rezultatul predicției.

Metoda propusă constă dintr-o serie de pași ce trebuie executați pentru a obține în final o rețea neuronală antrenată cu ajutorul căreia se pot face predicții de culoare pentru a obține reprezentarea izobară a unei imaginii color.

Metoda reunește două tehnici prezentate anterior și anume: reducerea valorilor cromatice prin cuantizarea vectorilor și folosirea unui grup de pixeli vecini pixelului de interes pentru care se face predicția.

Metoda a fost implementată și testată cu un set de imagini. Rezultatele obținute sunt bune și promițătoare iar imaginile obținute din punct de vedere al ochiului uman sunt foarte apropiate de intuiție. Deoarece predicția depinde foarte mult de setul de imagini folosit pentru antrenarea rețelei neuronale pentru imagini asemănătoare cu cele folosite la antrenament se obțin rezultate foarte bune.

## Bibliografie

- [1] A. Levin, D. Lischinski, and Y. Weiss, "Colorization using optimization," in ACM transactions on graphics (tog), vol. 23, no. 3. ACM, 2004, pp. 689–694
- [2] R. Ironi, D. Cohen-Or, and D. Lischinski, "Colorization by example." in Rendering Techniques, 2005, pp. 201–210.
- [3] Z. Cheng, Q. Yang, and B. Sheng, "Deep colorization," in Proceedings of the IEEE International Conference on Computer Vision, 2015, pp. 415–423
- [4] G. Larsson, M. Maire, and G. Shakhnarovich, "Learning representations for automatic colorization," arXiv preprint arXiv:1603.06668, 2016
- [5] J. Yoo and S.-Y. Oh, "A coloring method of gray-level image using neural network," in Proceedings of the 1997 International Conference on Neural Information Processing and Intelligent Information Systems, vol. 2, 1997, pp. 1203–1206
- [6] T. Kohonen, "Self-organized formation of topologically correct feature maps," Biological cybernetics, vol. 43, no. 1, pp. 59–69, 1982
- [7] L. Necula "Modelarea numerică a terenului pe baza înregistrărilor fotogrammetrice și satelitare", Teză de doctorat, Academia Tehnică Militară, 2011
- [8] J. Hwang and Y. Zhou, "Image colorization with deep convolutional neural networks," Stanford University, Tech. Rep., 2016. [Online]. Available: [http://cs231n.stanford.edu/reports2016/219\\_Report.pdf](http://cs231n.stanford.edu/reports2016/219_Report.pdf)
- [9] Y. Linde, A. Buzo, and R. Gray, "An algorithm for vector quantizer design," IEEE Transactions on communications, vol. 28, no. 1, pp. 84–95, 1980.
- [10] H. J. Trussell, J. Allebach, M. D. Fairchild, B. Funt, and P. W. Wong Eds., Special Issue on Color Imaging, IEEE Transactions on Image Processing, Vol. 6, No. 7, July 1997

## Revendicări

Metoda de etalonare a presiunilor pentru amprenta plantară, pentru efectuarea de măsurători și corelarea dintre valorile presiunilor și culori, **este caracterizată prin aceea că,** folosește o rețea neuronală multistrat care este antrenată să stabilească relații între setul de date sursă și setul de date țintă, urmând ca apoi această rețea să fie folosită ca funcție de predicție pentru alte seturi de imagini. Metoda urmărește următorii pași: preprocesarea imaginilor, antrenarea rețelei neuronale de tip SOM (Self Organizing Map), construcția setului de date și antrenarea rețelei neuronale multistrat. Fluxul de activități de antrenare a rețelei este: preprocesare imagini, antrenare SOM, construcția setului de date, antrenare NN.

Procesul de colorizare constă în trei pași principali pentru fiecare pixel de nivel de gri imagine: este utilizată rețeaua neuronală (NN) pentru a prezice indexul din lista de coduri pentru pixeli, indexul și lista de coduri sunt folosite pentru a obține componente U și V ale pixelului; combinăm componenta L din imaginea sursă cu valorile prezise ale componentelor U și V pentru a obține în final pixelul cu cele 3 componente R, G, B.

Metoda propusă constă dintr-o serie de pași ce trebuie executați pentru a obține în final o rețea neuronală antrenată cu ajutorul căreia se pot face predicții de culoare pentru a obține reprezentarea izobară a unei imagini color. Metoda reunește două tehnici și anume: reducerea valorilor cromatice prin cuantizarea vectorilor și folosirea unui grup de pixeli vecini pixelului de interes pentru care se face predicția.

Problema tehnică pe care o rezolvă invenția este reprezentată de înlocuirea folosirii unui colorimetru în etapa de etalonare pentru calibrarea culorilor.

Folosirea rețelelor neuronale pentru etalonarea presiunilor pentru amprenta plantară, măsurători și corelare presiuni-culori are avantajul de a elimina aspectul subiectiv precum și obținerea unei funcții de predicție universale care asigură o independență absolută de dispozitivele folosite.




Figura 1

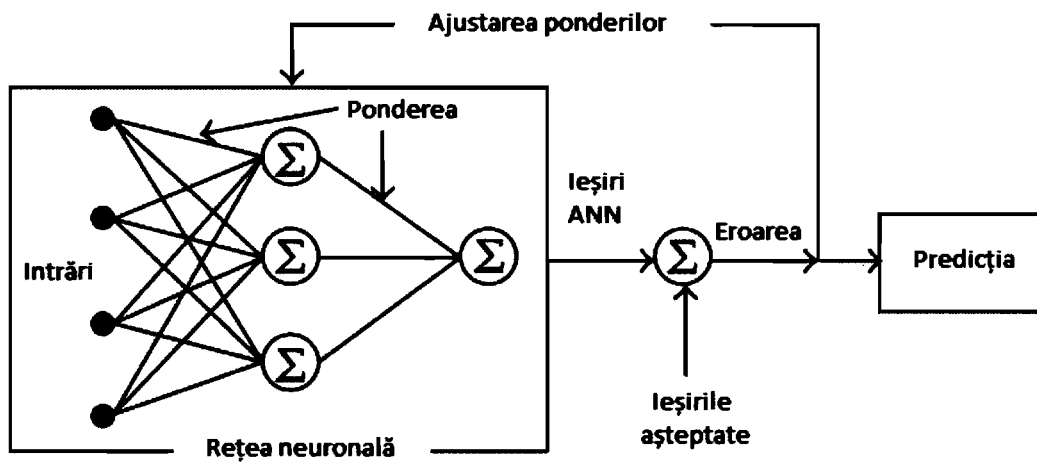


Figura 2

Numărul de neuroni	Eroarea reziduală
9	0.621739
25	0.4585945
100	0.19889
400	0.100954

Figura 3



Figura 4





Figura 5