

# *Detecția imaginilor folosind rețele neuronale convoluționale*

Răzvan George Ilașcu

## **Rezumat**

Scopul lucrării este crearea unei aplicații ce implementează rețele de convoluție, permițând configurarea unei rețele, precum și a unui algoritm de antrenare pentru aceasta. Parametrii care descriu rețeaua și algoritmul de antrenare sunt preluați din fișiere de configurare, iar rezultatele (parametrii învățați) sunt salvate sub formă binară, pentru folosirea eficientă a spațiului de stocare. Folosind această platformă, este antrenată o rețea convoluțională care este utilizată pentru clasificarea imaginilor.

La modul general, o rețea neuronală este o succesiune de straturi ce conțin o serie de parametri inițiali cu valori aleatorii. Intrarea, care poate fi un scalar, un vector sau un volum tridimensional, este transformată la trecerea prin rețea, calculându-se sume ponderate la nivelul fiecărui strat, pentru a obține o ieșire. Aceasta poate reprezenta o valoare numerică – caz în care rețeaua rezolvă o problemă de regresie numerică, sau o etichetă dintr-un set – caz în care problema este una de clasificare. Dacă se cunoaște ieșirea dorită, procesul de învățare este supervizat. Ponderile menționate anterior sunt ajustate astfel încât eroarea dintre ieșirea dorită și ieșirea generată de rețea să fie minimă.

Aplicația a fost implementată într-o manieră orientată obiect, folosind principiul moștenirii pentru diversele tipuri de straturi care sunt implementate. Limbajul ales pentru implementare a fost C++ pentru nucleul aplicației și NodeJS pentru o interfață web. Problemele pe care le poate aborda sunt atât de regresie numerică, cât și de clasificare, pentru învățarea supervizată.

Platforma astfel construită este folosită pentru a genera modele pentru rețele neuronale convoluționale, care sunt apoi folosite la clasificarea unor imagini din seturi de date disponibile public. Seturile de date folosite sunt: MNIST – set de date care conține cifre scrise de mână, CIFAR-10 – set de date ce conține imagini color clasificate în 10 categorii și CIFAR-100 – asemănător CIFAR-10, dar în care imaginile sunt împărțite în 100 de categorii.

Ca indicator de performanță este folosită acuratețea pe imagini care nu au fost trecute prin rețea la antrenare, ce fac parte din așa numitul set de validare. Pentru a declara un model ca fiind funcțional, trebuie ca eroarea pe setul de validare să fie descrescătoare pe măsură ce se avansează în epoci, iar acuratețea pe setul de date de validare să aibă o valoare asemănătoare cu acuratețea pe setul de date de antrenare.