

ANTRENAREA SUPERVIZATĂ A REȚELOR FEEDFORWARD MULTISTRAT ÎN PROBLEME DE CLASIFICARE

1. Considerații generale, motivație și obiectiv

Rețelele neuronale feed-forward multistrat cu noduri de intrare sigmoide sunt utilizate în probleme de clasificare a datelor. Alegerea funcțiilor de activare are o influență majoră asupra performanțelor rețelei. Performanța rețelei MLP este calculată pe baza procentajului elementelor clasificate corect. Pașii urmăți pentru crearea modelului conexiunilor folosite în rezolvarea problemei sunt : definirea unui set de trăsături folosite ca date de intrare precum și definirea structurii rețelei, a ratei de învățare și a metodelor de validare. Reperul de bază în utilizarea rețelelor neurale în recunoașterea de șabloane îl constituie setul de trăsături care trebuie să reprezinte fără ambiguitate toate șabloanele permise ca date de intrare pentru categoriile respective.

2. Cunoștințe prealabile necesare

- Capitolul "Antrenarea supervizată a rețelelor neuronale", secțiunea "Rețele feed-forward multistrat" din cursul "Aplicații ale rețelelor neurale în automatică".
- Experiență de programare în MATLAB.

3. Breviar teoretic

Utilizarea rețelelor neuronale feed-forward multistrat în probleme de clasificare se bazează pe antrenarea rețelelor prin algoritmul Backpropagation. Denumirea algoritmului provine din faptul că informațiile sunt procesate în sens invers de la ieșirea rețelei către intrare.

3.1. Algoritmul de clasificare

Se consideră imaginea:




Figura 1. Imaginea inițială

Pentru clasificarea pixelilor imaginii considerate se ține cont de faptul că fiecare fixel $\mathbf{p}$ al imaginii color este caracterizat prin:

- un vector cu două componente, notat $\mathbf{g}(\mathbf{p})$ care conține coordonatele geometrice ale pixelului
- un vector cu trei componente, $\mathbf{c}(\mathbf{p})$ care exprimă coordonatele de culoare din cubul RGB.

Folosind coordonatele geometrice, să definim mulțimea pixelilor $\mathbf{G}_k$ care corespund regiunilor ocupate de culoarea $\mathbf{e}_k$, $k = 1, 2, 3, 4$, unde:

- $\mathbf{e}_1$ semnifică culoarea neagră
- $\mathbf{e}_2$ semnifică culoarea roșie
- $\mathbf{e}_3$ semnifică culoarea verde și
- $\mathbf{e}_4$ semnifică culoarea albastră.

Evident mulțimile $\mathbf{G}_k$ sunt disjuncte. În cubul RGB scalat la $[0, 1] \times [0, 1] \times [0, 1]$ definim mulțimea de culori asociată fiecărui element $\mathbf{e}_k$ cu $k = 1, 2, 3$ sau 4 .

$$C_k = \{ \cup_p c(p) \mid g(p) \in G_k \} \quad (1)$$

Ipoteză de lucru: Cel puțin din punct de vedere teoretic se poate considera că mulțimile C_1, C_2, C_3 și C_4 sunt distincte. Satisfacerea practică a acestei ipoteze depinde de calitatea imaginii color.

Algoritm

Pasul 1. Se selectează eșantioane de culoare reprezentative pentru cele trei tipuri de regiuni și se definesc mulțimile de eșantioane $\tilde{C}_1, \tilde{C}_2, \tilde{C}_3$ și $\tilde{C}_4$. Acestea constituie cea mai bună posibilitate de a obține informații parțiale despre mulțimile de culori C_1, C_2, C_3 și C_4 care sunt necunoscute ca valori concrete în cubul RGB. Se elimină vectorii identici din fiecare mulțime de culoare. În baza ipotezei de lucru considerate, $\tilde{C}_k \subseteq C_k$, $k = 1, 2, 3, 4$ și drept urmare mulțimile de eșantioane $\tilde{C}_1, \tilde{C}_2, \tilde{C}_3$ și $\tilde{C}_4$ sunt disjuncte.




Figura 2. Alegerea eșantioanelor de culoare din regiuni reprezentative ale imaginii




Figura 3. Plasarea culorilor din mulțimile de eșantioane $\tilde{C}_1$, $\tilde{C}_2$, $\tilde{C}_3$ și $\tilde{C}_4$ în cubul RGB scalat la $[0, 1] \times [0, 1] \times [0, 1]$.

Pasul 2. Se antrenează o rețea neurală cu arhitectură adecvată astfel încât să clasifice în trei clase culorile din mulțimile de eșantioane $\tilde{C}_1$, $\tilde{C}_2$, $\tilde{C}_3$ și $\tilde{C}_4$.

Pasul 3. Se utilizează rețeaua antrenată pentru a clasifica toți pixelii din imagine în cele trei clase, corespunzătoare lui $\tilde{C}_1$, $\tilde{C}_2$, $\tilde{C}_3$ și $\tilde{C}_4$.




Figura 4. Ieșirile rețelei neurale pe setul de antrenare

Pasul 4. Se construiește o nouă imagine digitală în care se definesc următoarele patru regiuni care estimează regiunile ideale de interes G_k . Se utilizează trei culori distincte pentru a reprezenta regiunile estimate $\tilde{G}_1$, $\tilde{G}_2$, $\tilde{G}_3$ și $\tilde{G}_4$, pentru a asigura o mai bună vizualizare. Estimarea regiunilor ideale se va obține prin segmentare.




Figura 5. Performanța rețelei neurale antrenate prin algoritmul Levenberg-Marquardt




Figura 6. Separarea în clase – regiuni de interes realizată de o rețea neurală antrenată prin algoritmul Levenberg-Marquardt

Pasul 5. Se măsoară ariile regiunilor estimate $\tilde{G}_1$, $\tilde{G}_2$, $\tilde{G}_3$ și $\tilde{G}_4$ și se calculează procentele ocupate de fiecare.

3.2. Reducerea numărului de culori dintr-o imagine cu funcția imapprox

Funcția `imapprox` este folosită atunci când se dorește reducerea numărului de culori dintr-o imagine. Are la bază funcția `rgb2ind` și folosește aceleași metode de aproximare. De fapt, `imapprox` apelează `ind2rgb` pentru a converti imaginea în formatul RGB, după care apelează `rgb2ind` pentru a obține o imagine indexată cu mai puține culori decât imaginea inițială.




Figura 7. Aproximarea imaginii inițiale cu funcția `imapprox`

Calitatea imaginii rezultate depinde de metoda de aproximare utilizată, gama de culori a imaginii inițiale sau folosirea sau nu a oscilațiilor.

3.3. Identificarea regiunilor de interes cu funcția roicolor

Funcția **roicolor** poate fi folosită pentru a selecta regiuni de interes într-o imagine pe baza culorii și returnează o imagine binară.

```
BW = roicolor(A, low, high)
BW = roicolor(A, v)
```

Primul mod de apel returnează o regiune de interes ai cărei pixeli sunt în gama mapată de culori [low high]. BW este o imagine binară, semnificația unui pixel de 0 fiind că este în afara regiunii de interes, iar a unui pixel de 1 că aparține regiunii de interes.

```
BW = (A >= low) & (A <= high)
```

Cel de-al doilea tip de apel returnează o regiune de interes ai cărei pixeli corespund ca valoare elementelor din vectorul v. Semnificația elementelor de 1 ale imaginii binare BW este că elementele aferente din A corespund elementelor vectorului v. Imaginea A trebuie să fie numerică.




Figura 8. Aproximarea imaginii inițiale cu roicolor




Figura 9. Diferențele între segmentarea utilizând o rețea neurală sau segmentarea cu funcția roicolor.

4. Problematika propusă pentru studiu

Problema 4.1.

Se consideră imaginea RGB din figura 1 reprezentând o un peisaj ce conține patru elemente diferite de culoare: negru, roșu, verde și albastru.

Să se precizeze componentele rețelei neurale:

- mulțimea vectorilor prototip;
- mulțimea vectorilor țintă;
- numărul de straturi și numărul de neuroni de pe fiecare strat;
- rutina de antrenare și rutina de învățare;
- numărul epocilor de antrenare;
- funcția de evaluare a performanțelor rețelei;
- denumirea și dimensiunile matricii care stochează imaginea segmentată.

Să se determine procentele din aria totală a imaginii pe care le ocupă fiecare din cele patru elemente.

Se va studia și se va lansa în execuție programul **nn_segment** elaborat în MATLAB.

NEURAL NETWORK TOOLBOX – FUNCȚIILE INTERFEȚEI GRAFICE

5. Interfața grafică a NNToolbox

Interfața grafică a NNToolbox oferă următoarele facilități pentru a lucra cu rețele neurale:
>>nnstart




Figura xx. Neural Network Start

- **nctool** – toolbox pentru clasificare sau clusterizare folosind rețele neurale;
- **nftool** – toolbox pentru aproximare folosind rețele neurale;
- **nntraintool** – toolbox pentru antrenarea unei rețele neurale;
- **nprtool** – toolbox pentru recunoașterea caracteristicilor;
- **ntstool** – toolbox pentru rețele neurale cu serii și
- **view** - pentru vizualizarea arhitecturii unei rețele neurale.

5.1. Nftool

Welcome to the Neural Network Fitting Tool.
Solve an input-output fitting problem with a two-layer feed-forward neural network.

Introduction
In fitting problems, you want a neural network to map between a data set of numeric inputs and a set of numeric targets.
Examples of this type of problem include estimating house prices from such input variables as tax rate, pupil/teacher ratio in local schools and crime rate (`house_data.mat`); estimating engine emission levels based on measurements of fuel consumption and speed (`engine_data.mat`); or predicting a patient's bodyfat level based on body measurements (`bodyfat_data.mat`).
The Neural Network Fitting Tool will help you select data, create and train a network, and evaluate its performance using mean square error and regression analysis.

Neural Network
A two-layer feed-forward network with sigmoid hidden neurons and linear output neurons (`trainnn`) can fit multi-dimensional mapping problems arbitrarily well, given consistent data and enough neurons in its hidden layer.
The network will be trained with Levenberg-Marquardt backpropagation algorithm (`trainlm`), unless there is not enough memory, in which case scaled conjugate gradient backpropagation (`traincg`) will be used.

To continue, click [Next].
Neural Network Start Welcome Back Next Cancel

Select Data
What inputs and targets define your fitting problem?

Get Data from Workspace:
Input data to present to the network:
Inputs: (none)
Target data defining desired network output:
Targets: (none)
Samples are: ☒ Matrix columns ☐ Matrix rows

Summary:
No inputs selected.
No targets selected.

Want to try out this tool with an example data set?
Load Example Data Set

Select inputs and targets, then click [Next].
Neural Network Start Welcome Back Next Cancel

Select Data
What inputs and targets define your fitting problem?

Get Data from Workspace:
Input data to present to the network:
Inputs: buildingInputs
Target data defining desired network output:
Targets: buildingTargets
Samples are: ☒ Matrix columns ☐ Matrix rows

Summary:
Inputs: 'buildingInputs' is a 14x4208 matrix, representing static data: 4208 samples of 14 elements.
Targets: 'buildingTargets' is a 3x4208 matrix, representing static data: 4208 samples of 3 elements.

Want to try out this tool with an example data set?
Load Example Data Set

To continue, click [Next].
Neural Network Start Welcome Back Next Cancel

Validation and Test Data
Set aside some samples for validation and testing.

Select Percentages:
Randomly divide up the 4208 samples:
Training: 70% 2946 samples
Validation: 15% 631 samples
Testing: 15% 631 samples

Explanation:
Three Kinds of Samples:
Training: These are presented to the network during training, and the network is adjusted according to its error.
Validation: These are used to measure network generalization, and to halt training when generalization stops improving.
Testing: These have no effect on training and so provide an independent measure of network performance during and after training.

Change percentages if desired, then click [Next] to continue.
Neural Network Start Welcome Back Next Cancel

Network Architecture
Set the number of neurons in the fitting network's hidden layer.

Hidden Layer:
Define a fitting neural network: (fittnet)
Number of Hidden Neurons: 10

Recommendation:
Return to this panel and change the number of neurons if the network does not perform well after training.

Neural Network:
Input: 14
Hidden Layer: 10
Output Layer: 3
Output: 3

Change settings if desired, then click [Next] to continue.
Neural Network Start Welcome Back Next Cancel

Train Network
Train the network to fit the inputs and targets.

Train Network:
Train using Levenberg-Marquardt backpropagation: (trainlm)
Train




Results:

	Samples	MSE	R
Training	2946	-	-
Validation	631	-	-
Testing	631	-	-

Plot Fit Plot Error Histogram Plot Regression



Notes:
Training automatically stops when generalization stops improving, as indicated by an increase in the mean square error of the validation samples.
Training multiple times will generate different results due to different initial conditions and sampling.
Mean Squared Error is the average squared difference between outputs and targets. Lower values are better. Zero means no error.
Regression R Values measure the correlation between outputs and targets. An R value of 1 means a close relationship. 0 a random relationship.



Train network, then click [Next].
Neural Network Start Welcome Back Next Cancel




5.2. Nntool

>>nntool





5.3. Nntraintool




The screenshot shows the 'Training Info' tab. The 'Training Data' section has the following settings:





- Inputs: P
- Targets: T
- Init Input Delay States: (zeros)
- Init Layer Delay States: (zeros)

The 'Training Results' section has the following settings:

- Outputs: network1_outputs
- Errors: network1_errors
- Final Input Delay States: network1_inputStates
- Final Layer Delay States: network1_layerStates

An orange arrow points to the 'Train Network' button at the bottom right.





6. Problematika propusă pentru studiu

Problema 6.1.

Să se construiască o rețea neurală cu două straturi, cu $s = 2, 4$ sau 8 neuroni, cu funcție de activare sigmoid bipolar pe stratul ascuns și 1 neuron cu funcție de activare liniară pe stratul de ieșire. Se consideră vectorul prototip P calculat după formula:

$$P = \frac{i - 1}{50} \text{ cu } i = 1, \dots, 51$$

și vectorul țintă calculat după formula:

$$T = 1 + \exp(-P(i)) \cdot \sin\left(2 \cdot \pi \cdot P(i) - \frac{\pi}{2}\right) \text{ cu } i = 1, \dots, 51.$$

Pentru fiecare din cele trei cazuri să se deseneze

- arhitectura rețelei;
- graficul evoluției erorii medii pătratice pe parcursul antrenării;
- graficul funcției (P, T) și al aproximării cu rețeaua MLP pe aceeași figură.

și să se noteze:

- numărul de iterații cât a durat antrenarea;
- ponderile și deplasările aferente neuronilor de pe stratul ascuns;
- ponderile pentru conexiunile dintre stratul de ieșire și stratul ascuns.