

**Modelarea și evaluarea impactului investițiilor directe asupra
pieții muncii și evoluțiilor macroeconomice.
Metodologie pentru estimarea unor modele neuronale¹
- cerințe privind seriile de date -**

Corina Sâman²

Rezumat

Tehnica rețelelor neuronale poate fi aplicată în estimarea unor modele neliniare în problema clasică de regularizare când nu dorim sau nu putem să specificăm forma funcției neliniare. Flexibilitatea acestei tehnici permite oprirea la un model adecvat dintr-o serie de modele analizate. Metoda early-stopping asigură focalizarea pe modele de prognoză.

Introducere

Rețelele neuronale liniare au fost aplicate cu succes în găsirea unor soluții aproximative pentru o largă varietate de probleme, dintre care problema clasică de regularizare (sau estimare ne-parametrică) în care o funcție necunoscută $y = f(\vec{x})$ trebuie aproximată pornind de la o mulțime discretă de date (\vec{x}_t, y_t) .

Experiența a arătat că arhitecturi simple, cu relativ puține unități computaționale (noduri) pot avea foarte bune performanțe – totuși, cu cât numărul de variabile din model este mai mare, alegerea arhitecturii poate avea o importanță foarte mare în obținerea unui model adecvat.

Avantajele folosirii rețelelor neuronale în problema clasică de regularizare sunt: capacitatea de a procesa date de dimensiune mare, abilitatea de a extrage informație semnificativă din datele procesate și posibilitatea de a lua în considerare faptul că datele mai recente pot avea influență mai mare decât cele mai depărtate în timp.

Rețele neuronale liniare RNL – scurtă prezentare

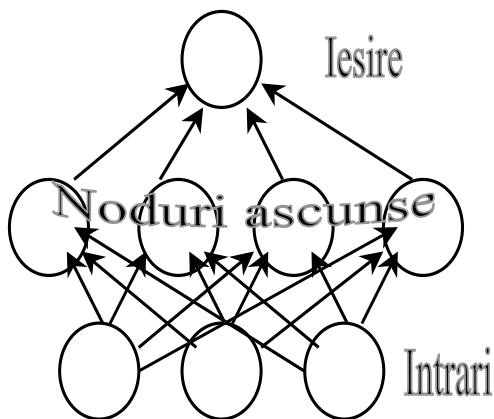
În ultimii 25 de ani s-au dezvoltat tehnici pentru modelarea relațiilor statistice neliniare care sunt denumite rețele de învățare, unele dintre acestea fiind rețelele neuronale liniare

¹ Prezentată în cadrul programului: “Modelarea și evaluarea impactului investițiilor directe naționale și internaționale asupra pieții muncii și evoluțiilor macroeconomice din România”, contract MEC 91-052/ 10 sept 2007, faza decembrie 2007: Etapa I: Documentare științifică, crearea bazei informaționale, rafinare și analiza exploratorie a datelor.

² Institutul de Prognoză Economică, Academia Română, București

(multilayer perceptrons), cel mai popular tip de rețele, care își au originea în modelele simple ale sistemului nervos biologic.

Formularea generală a unei RNL cu ieșire unică (un singur nod output) și un nivel de noduri ascunse poate fi scrisă:



$$\tilde{f}(\vec{x}) = h\left(\sum_{i=1}^k \alpha_i h(w_{i0} + w_{i1}'\vec{x}) + \alpha_0\right) \quad (1),$$

unde $h(\cdot)$ este o funcție netedă, crescătoare, ca, de pildă, funcția tangentă hiperbolică, $\{\alpha_i\}$ și w sunt coeficienți și k este numărul de noduri ascunse.

Pentru o mulțime dată de intrări $\{\vec{x}_t\}$ și valori de ieșire $\{y_t\}$, găsirea unui model RNL presupune estimarea a $(d+1)k$ parametri $\{w_{i0}\}$ și $\{w_{i1}\}$ și $k+1$ parametri $\{\alpha_i\}$, în total $(d+2)k+1$ parametri.

Specificarea modelului

Pot fi construite RNL (Rețele Neuronale Liniare) ca soluții aproximative pentru problema clasică de regularizare în care o funcție necunoscută $y = f(\vec{x})$ trebuie aproximată pornind de la o mulțime de date discretă (\vec{x}_t, y_t) . Vectorul de dimensiune d \vec{x}_t poate fi considerat vectorul variabilelor independente, explicative, y_t variabila dependentă și $f(\cdot)$ funcția neliniară căutată, care să aproximeze valoarea așteptată y_t pentru o intrare \vec{x}_t , $y_t \approx f(\vec{x}_t)$.

Problema de regularizare (sau estimare ne-parametrică) poate fi privită ca minimizarea

$$\text{unei funcții obiectiv: } H(f) = \sum_{t=1}^d \left\| y_t - \hat{f}(\vec{x}_t) \right\|^2 \quad (2).$$

Căutarea unui model neliniar prin tehnica rețelelor neuronale are avantajul flexibilității. Prin ajustarea numărului de noduri și nivele obținem o varietate de funcții neliniare care pot fi luate în considerare în alegerea modelului neliniar optim.

Aproximarea și eroarea de convergență

RNL, ca orice rețea de învățare, s-a dovedit a avea o proprietate de *aproximare universală*. Cybenko (1988) și Hornik (1989) au demonstrat că RNL cu un nivel de

noduri ascunse pot reprezenta cu o precizie arbitrar aleasă clase de funcții continue, liniare sau neliniare, cu intrări și ieșiri mărginite.

Această proprietate nu spune însă nimic despre cât de ușor de găsit este o aproximare bună, sau cât de eficientă din punct de vedere computațional este obținerea soluției. În particular se pune întrebarea dacă numărul de date, dimensiunea mulțimii (\vec{x}_t, y_t) , de care avem nevoie pentru a estima parametrii rețelei crește exponențial cu mărimea ei – așa numita cursă a dimensionalității. Sunt rezultate care arată că dacă se restrânge complexitatea funcției modelate această *cursă a dimensionalității* poate fi evitată. Barron (1991) găsește limite ale ratei de convergență a erorii de aproximare în RNL în cazul unor ipoteze asupra netezimii funcției de aproximat.

Estimarea parametrilor

Structura unei RNL este descrisă prin numărul de neuroni și nivele din RNL. Ele determină organizarea funcției neliniare modelate. Crescând numărul funcțiilor de transfer (adăugând neuroni și nivele) se crește complexitatea și flexibilitatea RNL.

Tocmai flexibilitatea este o proprietate importantă în aproximarea unei multitudini de relații funcționale dintre intrări și ieșiri. Și RNL suficient de complexe sunt capabile să aproximeze funcții arbitrare suficient de bine.

Algoritmii folosiți în estimarea RNL sunt cunoscuți ca “algoritmi de antrenare”. Acești algoritmi sunt asemănători cu rutinele standard de minimizare folosite, de exemplu, în metoda celor mai mici pătrate aplicată funcțiilor neliniare. Algoritmii de antrenare ajustează iterativ parametri în direcția gradientului negativ al erorii.

Totuși practicile de estimare din RNL diferă de tehnicile econometrice în puncte importante.

Pentru a evita “*overfitting*” algoritmul trebuie oprit înainte de a atinge minimul local. Intuitiv, “*overfitting*” apare când RNL oferă o aproape-perfectă potrivire pentru datele folosite, dar o slabă predicție în afara datelor de intrare. RNL sunt susceptibile de acest fenomen tocmai datorită flexibilității în aproximarea formelor funcționale diferite.

Una dintre cele mai folosite tipuri de proceduri de oprire a algoritmului este o procedură de validare pe o submulțime a datelor de intrare (cross-validation). Datele sunt partiționate într-o mulțime de antrenare și una de validare. Apoi, algoritmul de antrenare este executat pe mulțimea de antrenare până când MSE (Mean Square Error) începe să crească pe mulțimea de validare – moment care apare înainte de atingerea minimului MSE pe mulțimea de antrenare.

Arhitectura modelelor considerate

Ideea folosirii rețelelor neuronale pentru o mai bună cunoaștere a unor mecanisme economice complexe a fost propusă în literatura științifică (Salzano 1999, Zhang 2003). Urmărim să obținem modele neuronale care să descrie relațiile dintre un set de variabile de intrare și o variabilă de ieșire care să modeleze investițiile directe totale.

Datele luate în considerare de model sunt lunare, pentru perioada 2000-2006.

În tehnica rețelelor neuronale cu cât avem mai multe date cu atât mai bine. Învățarea structurii intrinseci a relației existente între variabila de ieșire și variabilele explicative necesită un volum cât mai mare de date. Orice învățare se obține în timp, intervalul de timp considerat fiind pentru model egal cu dimensiunea datelor de intrare.

Modelul I evaluează impactul investițiilor directe asupra pieții muncii.

Vom avea : investițiile directe totale ca variabilă dependentă y ;
variabilele explicative : numărul de șomeri și/sau salariul mediu.

Modelul II evaluează impactul investițiilor directe asupra evoluției macroeconomice.

Vom avea : investițiile directe totale ca variabilă dependentă y ;
variabilele explicative vor fi indicatorii macroeconomici: PIB și/sau rata inflației, (eventual soldul balanței de plăți, deficitul de cont curent).

Modelul III evaluează impactul pieții muncii asupra investițiilor directe.

Vom avea : numărul de șomeri și/sau salariul mediu, ca variabilă dependentă y ;
variabilă explicativă : investițiile directe totale

Modelul IV evaluează impactul investițiilor directe asupra evoluției macroeconomice.

Vom avea : PIB și/sau rata inflației, ca variabilă dependentă y ;
variabilă explicativă: investițiile directe totale.

Pentru acuratețea modelării și pentru ca modelele să devină unele predictive, trebuie avută în vedere influența valorilor din trecut ale variabilei modelate asupra valorilor ei actuale. De aceea sistemele vor căuta să ghicească valorile curente ale variabilei de ieșire prin ajustarea unei funcții dependente de valorile trecute ale intrărilor și ieșirilor.

La momentul curent t , ieșirea este determinată de intrările x la momente trecute diferite ($t-i_1, \dots, t-i_m$) și de ieșirea y la momente trecute ($t-o_1, \dots, t-o_n$).

Relația obținută de model este de tipul:

$$y(t+1) = f(x(t+1-i_1), \dots, x(t+1-i_m), y(t+1-o_1), \dots, y(t+1-o_n)).$$

Preprocesarea datelor

Datele vor fi **normalizate**, deoarece la valori medii pentru variabilele de intrare și ieșire foarte diferite, algoritmi vor converge foarte încet apărând probleme care, din punct de vedere matematic, se numesc ill-conditioning.

Dacă nu am normaliza datele, convergența spre optim poate să apară după un număr de pași foarte mare, care depinde de diferența ca ordin de mărime dintre media variabilelor implicate în model, dar și de valorile inițiale pentru ponderi.

În final se va proceda la un proces invers normalizării pentru a găsi valorile reale ale variabilei de ieșire simulate de rețeaua neuronală.


Procedura de antrenare a rețelei neuronale

Proprietatea de *aproximare universală* este cea care dă măsura de flexibilitate a rețelelor neuronale în procesul de învățare a unei structuri și relații necunoscute. Riscul potențial este apariția problemei de supra-învățare (overfitting), adică antrenarea rețelei pentru a învăța toate particularitățile aflate în eșantionul de date, nu numai a relației reale existente în model.


Să ne imaginăm ca avem niște date inițiale cu o anumită eroare ϵ :

$$y(x) = h(x) + \epsilon$$

Vrem să găsim un model $g(x)$ care aproximează $h(x)$.



Modelul liniar $g(x)$ este prea simplu și are o mare deplasare (bias) față de date, pe când modelul din graficul 2 se potrivește foarte bine pe intrări (overfitting), dar nu predicționează bine pe $h(x)$.



Obținerea unui echilibru între capacitatea de învățare și puterea de generalizare a modelului este foarte importantă în modelarea neuronală, iar soluția este metoda early-stopping.

Se divide spațiul de intrare în două mulțimi: Tr , o mulțime de antrenare și Val o mulțime de validare. Antrenăm rețeaua numai pe mulțimea Tr , dar oprim algoritmul și testăm rețeaua pe mulțimea Val . Cum Val este independentă de Tr , performanța obținută de model pe mulțimea Val este o bună măsură de generalizare a modelului (de predicție).

Atâta timp cât rețeaua învață structura datelor ($h(x)$), performanța modelului pe mulțimea Val se va îmbunătăți. O dată ce rețeaua încetează să învețe structura corectă pentru orice date de intrare și învață numai lucruri adevărate pentru această mulțime de intrare Tr , performanța pe datele de validare Val se va deteriora, rețeaua se va opri din trendul de învățare și de fapt continuarea procesului de învățare va duce la potrivirea pe datele eșantionului avut. Pentru a evita această problemă, oprim algoritmul la timpul t , unde performanța pe mulțimea Val este optimă. Pentru a evita ca modelul să dea o mare diferență între eroarea pe mulțimea de antrenare E_{Tr} față de eroarea obținută pe mulțimea de validare E_{Val} , vom impune și o condiție prin care această diferență să fie de 10% până la 25%, deci o condiție de tipul: $E_{Val} < (1 + p) E_{Tr}$.

Este o procedură standard să se antreneze rețelele folosind un număr mare de valori inițiale aleatoare pentru parametrii și să se aleagă cea mai bună RNL. Totuși nu este indicat să se satureze spațiul parametrilor cu prea multe valori inițiale, deoarece astfel s-ar găsi minimul global, ceea ce nu este de dorit în tehnica de oprire prematură (early-stopping).

Se vor folosi un număr rezonabil de valori inițiale aleatoare pentru parametrii. Rețeaua se va antrena pentru fiecare set de valori ale parametrilor, urmând să se aleagă cea mai bună soluție găsită ca model.

În esență, tehnica găsirii rețelei inițiale constă în următorii pași:

- Se alege o arhitectură a RNL (k noduri ascunse);
- Fiecare arhitectură se antrenează cu metoda *early-stopping* de n ori (n este un număr mic $5 < n < 10$), cu valori aleatoare pentru ponderi și diferite partiții ale mulțimii de date în Tr și Val ;
- Se reduc ponderile cu un factor de scalare γ ($0 < \gamma < 1$);
- Se reantrenează rețeaua cu noile ponderi;
- Se alege cea mai bună arhitectură RNL față de criteriul „cea mai mică eroare dintre valorile simulate și cele dorite pentru variabila de ieșire”.

Rezultate

Se compară rezultatele obținute prin cele 4 modele neuronale propuse cu modele de tip VAR corespunzătoare, pentru mai multe orizonturi de previziune. Comparăția se poate face în ceea ce privește R^2 și MSN (mean square error). Orizonturile de previziune pot fi de 1 lună, 2 luni, un trimestru.

Rezultatele vor permite o discuție asupra adecvării modelelor obținute. Avantajele și dezavantajele utilizării celor două tipuri de modele pot fi analizate sub rezerva

semnificației reduse datorate dimensiunii datelor - relativ mică din perspectiva tehnicii rețelelor neuronale.

Bibliografie

B. Lebaron, A.S. Weigend *A bootstrap evaluation of the effect of data splitting on financial time series*, IEEE Trans. Neural Network, vol.1, nr.9, 1998

F. Girosi, T. Poggio *Networks and the Best Approximation Property*, MIT, paper no.45, 1989

K. Hornik, M. Stinchcombe, H. White *Multilayer feedforward networks are universal approximators*, Neural Networks, vol.2, 1989

V. Kurkovic, M. Sanguineti *Bounds on Rates of Variable-Basis and Neural-Network Approximation*, IEEE Trans. Inform. Theory, vol.47.no.6 Sept.2001

T. Poggio, F. Girosi *Networks for approximation and learning*, Proc. of IEEE vol 78, no.9, 1990

M. Salzano *Neural Networks as tools for increasing the forecast and control of complex systems*, Economics & Complexity, Vol. 2, No. 2, 1999

G. Zang, B.E. Patuwo, M.Y. Hu *Forecasting with artificial neural networks : The state of art*, Int. J.Forecasting vol.14, 1998