

ANALIZA DE REGRESIE ORIENTATĂ-OBJEKT

ing. Marius Nițu

Institutul de Cercetări în Informatică.

Rezumat: Lucrarea reprezintă o încercare de a ordona și ierarhiza diferite tipuri de regresii (simple și multiple, liniare sau nelineare) în scopul unei analize a implicațiilor posibile într-o abordare bazată pe programarea orientată-obiect. Modelul matematic al fiecărui tip de regresie este discutat sumar, (pentru detalii, cătătorii interesanți pot consulta [1],[2],[3]) și sunt reliefate unele probleme clasice legate de dificultăți de calcul numeric. Se propune o taxonomie a analizei de regresie, iar în final sunt discutate avantajele unei abordări OOP.

Cuvinte cheie: modelare matematică, analiza de regresie, programare orientată-obiect (OOP).

Analiza de regresie reprezintă un instrument statistic intens folosit într-o varietate de domenii între care se regăsesc prelucrarea datelor experimentale, analiza de marketing, etc. În special în acest din urmă domeniu analiza de regresie a fost aplicată într-o multitudine de probleme de "predicție" cum ar fi: prezicerea consumului săptămânal de bere al unei persoane în funcție de vîrstă, sexul, venitul și nivelul de educație al acesteia; estimarea atraktivității exercitate de diferite jurnale medicale asupra medicilor în funcție de stilul de scriere, calitatea ilustrațiilor, utilitatea reclamelor prezentate și calitatea științifică a informațiilor, iar lista poate continua fiind aproape fără sfîrșit. Din acest motiv aparatul matematic utilizat a fost puternic dezvoltat și există referințe vaste asupra algoritmilor ce pot fi utilizati. Ceea ce ne propunem în acest articol este ca, după o scurtă prezentare a modelelor matematice implicate de regresia simplă și multiplă, liniară sau nelineară să investigăm posibilitățile și avantajele oferite de abordarea problemei în spiritul conceptelor programării OOP.

1. Regresia simplă. Modelul matematic.

Să presupunem că plecând de la o serie de valori tabelate obținute experimental pentru două variabile aleatoare X și Y , ne propunem să găsim o relație generală între X și Y . În cazul cel mai simplu, căutăm o relație liniară de forma:

$$Y^* = a + bX \quad (1)$$

unde:

Y^* - desemnează valorile criteriu prezise de modelul linear;
a - desemnează termenul liber sau valoarea lui Y^* cînd X este zero;
b - desemnează panta dreptei sau variația în Y^* pe unitatea de variație în X .

Metoda folosită, numită metoda celor mai mici pătrate (sau principiul Gauss [1]), constă în esență din minimizarea expresiei:

$$\sum_{i=1}^n (y_i - a - bX_i)^2 \quad (2)$$

unde x_i, y_i reprezintă datele empirice.

În plus, așa numitul model "clasic" al regresiei, operează în următoarele ipoteze [1], [2]:

- pentru fiecare valoare fixată a lui X , presupunem o repartiție normală a lui Y ;
- media tuturor acestor repartiții normale ale lui Y - condiționate de X - se află pe o dreaptă cu panta τ ;
- toate repartițiile normale ale lui Y au aceeași dispersie.

Exprimat algebric modelul este:

$$Y = \alpha + \tau X + \varepsilon \quad (3)$$

unde: α - media populației Y cînd $X = 0$;

τ - variația în media populației Y pe unitatea de variație în X ;

ε - un termen de eroare independent, dedus dintr-un univers normal distribuit, și care are media 0.

În acest caz pentru calculul parametrilor (a și b) modelului de regresie liniară se folosesc în mod ușual următoarele relații:

$$b = \frac{\sum_{i=1}^n YX - n\bar{Y}\bar{X}}{\sum_{i=1}^n X^2 - n\bar{X}^2} \quad (4)$$

$$a = \bar{Y} - b\bar{X}$$

unde n desemnează mărimea eșantionului, iar \bar{Y} și \bar{X} desemnează mediile aritmetice pentru Y și X . Deducerea relațiilor (4) se face anulind derivele parțiale ale expresiei (2) în raport cu a și b , transformindu-le apoi, prin intermediul unor identități, pentru a minimiza erorile legate de calculul numeric și rezolvind sistemul astfel rezultat [1], [3].

Fără a intra în detalii menționăm că, de obicei, calculul impune evaluarea unor parametri statistici ce măsoară tăria corelației, dintre care menționăm coeficientul determinării R^2 și coeficientul corelației R_{yx} (vezi [2], [3] pentru detalii).

Este evident că regresia liniară simplă poate fi adeseori nepotrivită. Dacă desenăm graficul datelor, acesta poate să sugereze uneori o hiperbolă, o curbă exponențială, o curbă geometrică sau chiar o curbă trigonometrică. Modele matematice pentru aceste tipuri de curbe pot fi, respectiv:

$$y = \frac{1}{a_0 + a_1 x}$$

$$y = a(b^x)$$

$$y = a \cdot x^b$$

$$y = a_0 + a_1 \cos(\omega \cdot x)$$

De remarcat că, unele lucrări trec în revistă chiar mai multe tipuri de curbe, posibil de utilizat [3]. Să menționăm că regresia în acest caz nu mai este lineară, dar că **metoda celor mai mici pătrate nelineare** poate fi utilizată în continuare. Algoritmul de rezolvare în acest caz se bazează pe linearizarea expresiei funcției utilizate prin intermediul unei schimbări de variabilă adecvată [1], [3], iar apoi se ajunge la cazul clasic. Se mai poate menționa că nu întotdeauna funcțiile propuse pot fi transformate ușor în forme lineare și că exceptând funcția trigonometrică, în celelalte cazuri baza statistică discutată anterior nu mai este valabilă (nu se mai minimizează suma pătratelor abaterilor din y , ci mai degrabă se minimizează suma pătratelor abaterilor din schimbarea de variabilă utilizată [1]).

2.O propunere de taxonomie pentru regresia simplă.

Se poate încerca acum, în baza celor prezentate anterior, să se definească mai întâi o clasă de obiecte pentru regresia lineară simplă, folosind un pseudocod bazat pe limbajul Turbo-Pascal:

```
type RL2 = object
  {datele obiectului RL2}
  X1,X2,Xest:TVector;
  n          :integer;
  a,b        :float;
  direct:boolean;Stat_Param: TVector; {vector de
                                         parametri statistici}
  {procedurile obiectului RL2}
  constructor Init(...);
  procedure Compute_Reg; virtual;
  procedure Plot_Data; virtual;
  destructor Done;
end;
```

Se poate remarcă, față de cele prezentate anterior, notația X_1, X_2 pentru Y respectiv X , prezența unei variabile booleene (`direct`) prin intermediul căreia se poate comuta sensul regresiei (regresie în Y sau regresie în X) că și prezența unei proceduri de reprezentare grafică a datelor inițiale și a celor estimate (procedura `Plot_Data`). De asemenea, nu sunt precizate parametrii procedurii de inițializare, lucru nerelevant în contextul actual.

Acum se poate încerca să se deriveze următoarea clasă de obiecte pentru regresia nelineară. Această clasă generică, este considerată ca o moștenire a clasei definite anterior (`RL2`). Se moștenesc atât datele clasei anterioare, că și procedurile definite, dar se mai poate introduce o procedură generică numită "Change_Variable" cu rolul de a efectua schimbarea de variabilă adecvată:

```
type RN2 = object(RL2)
  Z:TVector;
```

```
constructor Init(...);
procedure Change_Variable;
procedure Compute_Reg; virtual;
procedure Plot_Data; virtual;
destructor Done;
end;
```

Este evident acum că, scriind în mod adevarat procedura de schimbare de variabilă, practic prelucrând în mod corespunzător vectorul de date inițiale, se poate particulariza această clasă pentru diferite tipuri de funcții nelineare, dorite a fi utilizate ca modele matematice. Se poate, în acest moment, să se definească efectiv obiectele de tip regresie hiperbolică exponențială, geometrică etc.

În cele ce urmează se discută foarte pe scurt regresia polinomială bivariată.

3. Regresia polinomială. O nouă clasă.

Motivul abordării regresiei polinomiale este datora aceluiși fapt care a dus la prezentarea regresiei nelineare și anume nepotrivirea dintre forma sugerată de graficul valorilor și modelul linear. Abordarea separată a acestui tip de regresie (evident tot nelinear) este justificată în continuare.

Mai întâi se formulează însă, modelul matematic:

$$Y^* = a + b_1 x + b_2 x^2 + \dots + b_k x^k \quad (5)$$

Se dorește minimizarea expresiei:

$$\sum_{i=1}^n (y_i - b_k x_i^k - b_{k-1} x_i^{k-1} - \dots - b_1 x_i - a)^2 \quad (6)$$

Este evident că, urmând aceeași cale cu cea menționată anterior, se ajunge la un sistem de $k+1$ ecuații cu $k+1$ necunoscute, ce poate fi rezolvat printră eliminare gaussiană [1], [3], [4], [5].

Se poate demonstra [1] însă că, dacă k este rezonabil de mare ($k > 7$), matricea coeficienților sistemului se apropie de aşa-numita matrice Hilbert, matrice care este cunoscută ca fiind rău condiționată. Oricum, chiar și neglijind dificultățile legate de calculul numeric, creșterea nejustificată a gradului polinomului (k aproximativ de același ordin de mărime cu n) duce la expresie ce descrie exact toate datele, inclusiv erorile aleatorii de măsurare.

Aceste considerații fac adeseori ca pentru problemele de regresie de tip polinomial să fie preferată utilizarea funcțiilor ortogonale. Cel mai adesea sunt preferate polinoame ortogonale de tip Cebîșev, datorită relației de recurență a acestora că și datorită faptului că valorile parametrilor b_j nu depind de gradul polinomului [1], [3].

Revenind însă la ierarhia în dezvoltare pe care o propunem, se poate adăuga acum o nouă clasă de obiecte, exploataind și de această dată posibilitățile

oferite de proprietatea de moștenire:

```
type RNP2 = object(RL2)
  B:TVector;
  k:integer;
  constructor Init(...);
  procedure Compute_Reg; virtual;
  procedure Plot_Data; virtual;
  destructor Done;
end;
```

Este pusă în evidență în acest moment și mai clar proprietatea de polimorfism ce caracterizează metoda de programare orientată-obiect. La transmiterea de către programul principal a mesajului de calcul de regresie, procedura Compute_Reg se va comporta adecvat tipului de obiect creat.

Se atrage atenția că se poate pune în evidență și o soluție elegantă legată de deficiențele eliminării gaussiene, ca și de alegerea judicioasă a gradului k al polinomului utilizat. Testând raportul k/n și calculând criteriul de concordanță al lui Gauss [3] se poate comuta între metoda rezolvării sistemului de ecuații pentru calculul coeficienților regresiei și metoda bazată pe polinoame Cebîșev, comutare ce poate să fie transparentă utilizatorului.

4. Regresia multiplă. Definitivarea taxonomiei.

Modelul matematic al regresiei lineare multiple poate fi definit restrictiv prin introducerea unei a două variabile predictor în modelul bivariat linear:

$$Y = \alpha + \tau_1 X_1 + \tau_2 X_2 + \varepsilon \quad (7)$$

cu parametrii estimati de:

$$Y^* = a + b_1 X_1 + b_2 X_2$$

în acest caz se caută un plan particular - și anume acel plan a cărui sumă a pătratelor abaterilor din y_i este minimă. Metoda generală de rezolvare constă în minimizarea expresiei:

$$\sum_{i=1}^n (y_i - a - b_1 \cdot x_{i,1} - b_2 \cdot x_{i,2})^2 \quad (8)$$

După derivare rezultă și în acest caz un sistem de ecuații ce poate fi rezolvat [1], [3].

Dar, revenind la formularea restrictivă a problemei (7), se pot observa unele lucruri interesante. Studiind interpretarea ce se poate da coeficientului b_1 [2] putem să imaginăm mai întii o regresie a lui X_1 în X_2 . Calculând apoi reziduurile $x_{j,1} - x_{i,2}$ ^{*} din această regresie și regresind apoi valorile lui Y pe mulțimea reziduurilor lui X_1 , coeficientul regresiei "simple" va fi egal cu coeficientul regresiei parțiale b_1 . În mod analog se poate trata și coeficientul b_2 . Ca o consecință practică, înseamnă că putem rezolva problema formulată de relația (7), efectuând trei regresii simple în loc să se rezolve un sistem de 3 ecuații în cele 3 necunoscute a, b_1 , b_2 .

Se pot adăuga acum două noi ramuri taxonomiei precedente:

```
type RL3 = object(RL2)
  ob1,ob2:^RL2; {^ - pointer la}
  constructor Init(...);
  procedure Compute_Reg; virtual;
  procedure Plot_Data; virtual;
  destructor Done;
end;
```

```
type RN3 = object(RN2)
  ob1,ob2:^RN2; {^ - pointer la}
  constructor Init(...);
  procedure Compute_Reg; virtual;
  procedure Plot_Data; virtual;
  destructor Done;
end;
```

Obiectul RN3 poate fi considerat ca o extrapolare a regresiei nelineare bivariate și care este, bineînteleș, o clasă generică. Particularizarea funcțiilor de schimbare de variabilă conduce la forma dorită a clasei pentru obiecte de acest tip. Prin similitudine, se poate adăuga o nouă clasă pentru regresia polinomială multiplă:

type RNP3 = object (RNP2)

{date și proceduri proprii}

.....

end;

În sfîrșit, revenind la cazul general al regresiei multiple lineare în "v" variabile, se poate alege și în acest caz o variabilă dependentă (afectată de erori statistică) și se regresează în cele "v-1" variabile rămase. Modelul matematic în acest caz devine:

$$Y = \alpha + \tau_1 X_1 + \tau_2 X_2 + \dots + \tau_{v-1} X_{v-1} + \varepsilon \quad (9)$$

care prin minimizarea expresiei:

$$\sum_{i=1}^n (y_i - a - b_1 \cdot x_{1,i} - b_2 \cdot x_{2,i} - \dots - b_{v-1} \cdot x_{v-1,i})^2$$

conduce la un sistem de "v" ecuații cu "v" necunoscute ce poate fi rezolvat [1], [3], [4], [5].

Se poate completa taxonomia construind această nouă clasă ca moștenire a clasei RL3 și rescriind în mod adecvat procedurile de calcul:

```
type RLV = object (RL2)
  {date și proceduri proprii}
  .....
```

end;

5. Concluzii.

În această lucrare s-a făcut o sumară trecere în revistă a problemelor legate de regresia simplă și multiplă lineară sau nelineară și s-a încercat să se construiască o taxonomie în spiritul conceptelor

programării orientate-obiect. Fără a intra în detaliile legate de algoritmii propriu-zisi, s-a încercat relevarea particularităților legate de dificultățile de calcul numeric și exploatarea cunoștințelor acumulate în domeniu. Ierarhizarea propusă a avut ca principal criteriu de clasificare unitatea algoritmilor de rezolvare.

Această abordare are în mod clar un mare avantaj evident. Utilizarea proprietății de moștenire și a celei de încapsulare a datelor permit simplificarea la maxim a procedurilor de calcul prin preluarea automată a codului identic din obiectul părinte. Un alt avantaj constă în faptul că este posibilă o afișare în paralel a rezultatelor calculelor diferitelor tipuri de regresii (chiar și sub formă grafică) pentru unul și același set de date, și, chiar mai mult decât atât, printr-o îmbinare judicioasă a secvențelor de creare a obiectelor și a celor de calcul în programul principal, este posibilă implementarea cu succes a metodei de "regresie în trepte" (Stepwise Regression), intens folosită în cercetarea de marketing.

De asemenea, abordând în același spirit metodele de analiză de varianță și covarianță, analiza factorială și discriminatorie, se poate anticipa că pot fi obținute rezultate interesante din punct de vedere al efortului de programare.

NOTĂ:

Acest articol reprezintă versiunea în limba română revizuită a materialului "An Object Oriented approach for Regression Analysis" care a fost prezentat la TWELTH IASTED INTERNATIONAL CONFERENCE, "Modelling, Identification and Control" 15-17 februarie 1993, Innsbruck, Austria.

Bibliografie

1. DORN, W., MCCRACKEN, D.: Metode numerice cu programe în Fortran IV, Editura Tehnică, București 1976.
2. GREEN, P., TULL, D., Albaum, G: Research for Marketing Decisions. Prentice-Hall, Englewood Cliffs, New Jersey, 1988.
3. CONSTANTINESCU, L., s.a.: Prelucrarea datelor experimentale cu calculatoare numerice, Editura Tehnică, București, 1980.
4. SALVADORI, M., BARON, L.: Metode numerice în tehnica, Editura Tehnică, București, 1972.
5. SIMIONESCU I., s.a.: Metode Numerice, IPB, București, 1992.
6. DEMIDOVICH, B., MARON I.: Computational Mathematics, MIR Publisher, Moscow, 1981.
7. MEYER, B.: Object Oriented Software Construction, Prentice Hall, Englewood Cliffs, New Jersey, 1986.