

CONSIDERAȚII PRIVIND TEOREME DE ECHIVALENȚĂ PENTRU ALGORITMI DE CĂUTARE

ing. Cezar Ionescu

ing. Leon Bațachia

Institutul de Cercetări în Informatică

Rezumat: În acest articol se face o prezentare a teoremelor NFL ("No Free Lunch Theorems") a căror publicare a stârnit multe dezbateri în lumea științifică. Prezentarea este însoțită de considerații privind extinderi, corolare și implicații ale acestor teoreme.

Cuvinte cheie: algoritmi de căutare, optimizare, teoremele NFL.

1. Considerații preliminare

Teoremele de echivalență, prezentate în acest articol, se datorează cercetătorilor americani William Macready și David Wolpert. Articolul în care au fost publicate aceste teoreme este intitulat "No Free Lunch Theorems for Search", denumirea provenind din zicala englezească "there is no such thing as a free lunch". Articolul a fost anunțat în grupul de discuții, rezervat algoritmilor genetici pe Internet, comp.ai.genetic, pe data de 7 februarie 1995, și a generat cea mai lungă listă de discuții din istoria de până acum a grupului respectiv.

Teoremele de echivalență, date de Macready și Wolpert, demonstrează echivalența algoritmilor de căutare în spații discrete (noțiunea de algoritm de căutare va fi formalizată riguros în cele ce urmează), atunci când este considerată media performanței lor pe mulțimea tuturor funcțiilor de cost. Aceasta revine la imposibilitatea existenței unui algoritm mai bun "în medie" decât oricare altul: algoritmii pot fi comparați numai pentru clase de probleme precizate. Este, deci, inutilă încercarea de a găsi un algoritm de căutare "general": toți algoritmii de căutare obțin aceleași performanțe. În particular, algoritmul genetic nu va obține performanțe mai bune decât căutarea aleatoare care, la rândul ei, va avea aceleași performanțe cu metodele de *hill-climbing*.

Macready și Wolpert insistă, în articolul lor, asupra faptului că nici un algoritm de căutare nu poate fi considerat un *panaceu universal* și asupra necesității alegerii unui algoritm în funcție de problema dată (sau a unei reprezentări adecvate pentru problema considerată).

În continuare, articolul este structurat după cum urmează:

- prezentarea notațiilor folosite și formalizarea noțiunii de algoritm de căutare;
- enunțarea și demonstrarea teoremei de echivalență Macready și Wolpert;
- extinderea rezultatelor la algoritmi mai generali;
- principalele corolare ale teoremei;
- discutarea teoremei și a implicațiilor sale.

2. Notații

Vom considera funcții de cost de forma:

$f: X \rightarrow Y$, unde X și Y sunt mulțimi finite.

Mulțimea tuturor acestor funcții este Y^X , având cardinalul $|Y|^{|X|}$, unde prin $|A|$ am notat cardinalul mulțimii A .

Un algoritm de căutare a extrapolează pe baza unei mulțimi de puncte $(x_1, y_1) \dots (x_m, y_m)$ și propune un nou punct. Extrapolarea poate fi deterministă sau stocastică.

Notăm:

$$d_m^x = (x_1, \dots, x_m)$$

$$d_m^y = (y_1, \dots, y_m)$$

$$d_m = \{d_m(j)\} = \{d_m^x(j), d_m^y(j)\}, j=1 \dots m,$$

iar mulțimea tuturor d_m cu D_m . Fie $D = \cup_m D_m$. D conține mulțimea vidă.

Se presupune că punctele (x_j, y_j) sunt distincte, două câte două, și că rezultatul extrapolării algoritmului este, de fiecare dată, un punct nou. Atunci când $m = |X|$, algoritmul se oprește (rezultatul fiind echivalent cu al unei enumerări).

Cu aceste notații, un algoritm de căutare determinist este o funcție

$$a: d \in D \rightarrow \{x | x \notin d^x\}$$

Fie c histograma valorilor funcției de cost, obținute de un algoritm a după m evaluări ale funcției de cost. Avem:

$c \in \mathbb{N}^{|Y|}$, $c(i)$ = numărul de membri din populația d_m ce au valoarea f_i .

Histograma poate fi folosită pentru a aprecia calitatea căutării efectuate de algoritmul a în orice fel. De exemplu, în cazul încercării de a maximiza funcția f , un algoritm este cu atât mai bun cu cât histograma sa conține valori mai numeroase pentru valori f_i mai mari. Ca atare, măsura efectivă a performanței algoritmului depinde exclusiv de histogramă pe care o obține, prin intermediul unei funcții de performanță. Ca atare, ne putem ocupa de histogramele obținute de diverși algoritmi în m pași, fără să ne punem problema criteriului efectiv de performanță al algoritmului (dacă se încearcă minimizarea sau maximizarea funcției).

Valoarea de interes pentru comparația algoritmilor este, deci:

$P(c|f, m, a)$ (probabilitatea condiționată ca histograma c să fie obținută după m iterații ale algoritmului a aplicat pentru f).

3. Teorema de echivalență a algoritmilor de căutare (Macready, Wolpert)

Pentru orice algoritmi de căutare a_1, a_2 :

$$\sum_f P(c|f, m, a_1) = \sum_f P(c|f, m, a_2)$$

Demonstrație

Vom demonstra că $\sum_f P(c|f, m, a)$ nu depinde de a .

Dezvoltând suma după toate componentele y posibile ale unei populații d_m^y avem:

$$\sum_f P(c|f, m, a) = \sum_{f, d_m^y} P(c, d_m^y | f, m, a)$$

Dar

$P(c, d_m^y | f, m) = P(c | d_m^y, f, m, a) P(d_m^y | f, m, a)$ iar $P(c | d_m^y, f, m)$ depinde numai de valorile y ale populației d_m . Deci:

$$\begin{aligned} \sum_f P(c|f, m, a) &= \sum_{f, d_m^y} P(c | d_m^y) P(d_m^y | f, m, a) = \\ &= \sum_{d_m^y} P(c | d_m^y) \sum_f P(d_m^y | f, m, a) \end{aligned} \quad (*)$$

Pentru a demonstra că membrul drept al ecuației (*) este independent de a , este suficient să arătăm că, pentru orice m și d_m^y , $\sum_f P(d_m^y | f, m, a)$ este

independentă de a . Vom demonstra aceasta prin inducție.

Pentru $m=1$, $d_1 = \{d_1^x, f(d_1^x)\}$, deci avem:

$$\sum_f P(d_1^y | f, m=1, a) = \sum_f \delta(d_1^y, f(d_1^x))$$

unde δ este funcția Kronecker delta. De aici:

$$\sum_f P(d_1^y | f, m=1, a) = |Y|^{|X|-1}$$

cantitate independentă de a , deci pentru $m=1$ propoziția este verificată.

În continuare, demonstrăm ca $P(m) \Rightarrow P(m+1)$. Avem:

$$\begin{aligned} P(d_{m+1}^y | f, m+1, a) &= \\ P(\{d_{m+1}^y(1), \dots, d_{m+1}^y(m)\}, \\ d_{m+1}^y(m+1) | f, m+1, a) &= \\ P(d_m^y, d_{m+1}^y(m+1) | f, m+1, a) &= \\ = P(d_{m+1}^y(m+1) | d_m^y, f, m+1, a) \\ P(d_m^y | f, m+1, a) \end{aligned}$$

și deci:

$$\begin{aligned} \sum_f P(d_{m+1}^y | f, m+1, a) &= \\ = \sum_f P(d_{m+1}^y(m+1) | d_m^y, f, m+1, a) &= \\ = P(d_m^y | f, m+1, a) \end{aligned}$$

Dar $d_{m+1}^y(m+1)$ depinde numai de noua valoare x și de f , deci:

$$\begin{aligned} \sum_f P(d_{m+1}^y | f, m+1, a) &= \\ = \sum_{f, x} P(d_m^y(m+1) | f, x) P(x | d_m^y, f, m+1, a) \\ P(d_m^y | f, m+1, a) &= \\ = \sum_{f, x} \delta(d_{m+1}^y(m+1), f(x)) P(x | d_m^y, f, m+1, a) \\ P(d_m^y | f, m+1, a) \end{aligned}$$

Observăm că $x = a(d_m^x, d_m^y)$ nu depinde în mod direct de f . Rezultă:

$$\begin{aligned} \sum_f P(d_{m+1}^y | f, m+1, a) &= \sum_{f, x, d_m^y} \delta(d_{m+1}^y(m+1), f(x)) P(x | d_m^y, a) \\ P(d_m^x | d_m^y, f, m+1, a) P(d_m^y | f, m+1, a) &= \\ = \sum_{f, d_m^y} \delta(d_{m+1}^y(m+1), f(a(d_m^x))) P(d_m^y | f, m, a) \end{aligned}$$

Ținând cont că $a(d_m^x) \notin d_m^x$ avem:

$$\sum_f P(d_{m+1}^y | f, m+1, a) =$$

$$= \sum_{d_m} \sum_{f(x \in d_m)} P(d_m | f, m, a) \sum_{f(x \in d_m)} \delta(d_{m+1}^y(m+1), f(a(d_m)))$$

Dar $\sum_{f(x \in d_m)} \delta(d_{m+1}^y(m+1), f(a(d_m))) = |Y|^{|X|-m-1}$

și deci:

$$\sum_f P(d_{m+1}^y | f, m+, a) = |Y|^{|X|-m-1} \sum_{f(x \in d_m), d_m} P(d_m | f, m, a) =$$

$$= \frac{1}{|Y|} \sum_{f(x \in d_m), d_m} P(d_m | f, m, a)$$

$$\frac{1}{|Y|} \sum_{f, d_m} P(d_m | f, m, a) = \frac{1}{|Y|} \sum_f P(d_m^y | f, m, a)$$

Din ipoteza de inducție, membrul drept al acestei relații este independent de a , deci și membrul stang este independent de a . Cu acestea, teorema este demonstrată.

4. Extinderea teoremei la algoritmi de căutare generali

Teorema a fost demonstrată pentru cazul algoritmilor determinați care produc de fiecare dată un punct nou din spațiul X . Macready și Wolpert ar arătat însă cum se poate extinde rezultatul obținut de ei la cazul general al algoritmilor de căutare stocastici și care pot revizita puncte din X .

Extinderea la cazul algoritmilor ce revizitează puncte din X porneste de la observatia că, din orice 'drum' al unui algoritm a ce revizitează puncte, se poate extrage un drum compactat, care pastreaza numai o vizita a fiecarui punct din drumul inițial. Algoritmii compactați sunt supuși teoremei de echivalență și, ca atare, și algoritmi originali se supun acestei teoreme.

Trebuie subliniat ca raționamentul de mai sus este valabil doar în cazul algoritmilor originali care reușesc să exploreze tot spațiul X , fără să rămână prinși în "capcane", adică să genereze permanent puncte dintr-o anumită submulțime a lui X .

În mod similar, se pot compacta și algoritmi stocastici. Atunci, un algoritm stocastic s reprezintă o funcție definită pe d (ca la algoritmi determinați) care produce o distribuție de probabilitate peste X cu proprietatea ca distribuția este nulă în punctele $x \in d$. Ca atare, s poate fi privit ca un parametru în funcția $P(d_{m+1}^x(m+1) | d_m, s)$ pentru m și d dați.

Cu această definiție pentru s , dacă urmărim demonstrarea teoremei de echivalență, înlocuind peste tot a cu s , relațiile își păstrează valabilitatea.

Deci, teorema de echivalență este valabilă și pentru algoritmi stocastici.

5. Corolare ale teoremei de echivalență

1. Nu există algoritmi mai rapizi în medie (de exemplu pentru gasirea maximului) decât alții.
2. Pentru maximizarea funcțiilor, hill-climbing e, în medie, la fel de bun ca hill-descending.
3. Pentru o funcție de cost oarecare, nu există nici o modalitate de a prevedea performanța unui algoritm pe baza performanței anterioare (deci nu se poate prevedea calitatea punctului x_{m+1} pe baza punctelor x_1, \dots, x_m și a valorilor funcției f aleasă în mod aleator din Y^X în aceste puncte).

Demonstrație

Orice procedeu de alegere a unei funcții din Y^X după o distribuție de probabilitate aleatorie este echivalent cu următorul: pentru orice $x \in X$ se alege un $y = f(x) \in Y$ după o distribuție uniformă de probabilitate în Y (fiecare $y \in Y$ are o probabilitate de $1/|Y|$ de a fi ales). Ca atare, valorile funcției f sunt independente probabilistic, deci nici un algoritm nu poate prevedea mai bine decât pur aleator valoarea într-un punct nevizitat.

Observație

Demonstrația de mai sus, care ne aparține, are ca rezultat imediat echivalența tuturor algoritmilor de căutare, în medie, cu algoritmul de căutare aleatoare. Deci ea poate fi folosită ca o altă demonstrație a teoremei Macready și Wolpert.

6. Critici și implicațiile teoremei

Principala critică adusă teoremei NFL a fost ca demonstrația ei depinde în mod esențial de o distribuție de probabilitate uniformă pe mulțimea funcțiilor Y^X . Critică a fost adusă autorilor de către Kihong Park, de la Boston University, dar teorema a fost sprijinită și de autori mult mai cunoscuți, cum ar fi dr. Vose, autorul modelării cu Lanțuri Markov a algoritmilor genetici.

Obiecția ridicată de Kihong Park este următoarea: în aproape toate situațiile în care lucrăm cu optimizări combinatoriale, avem un mod de a genera funcția de cost f pe calculator. Or, mulțimea funcțiilor de cost generabile pe calculator este foarte mică în comparație cu mulțimea tuturor funcțiilor de la X la Y . Ca atare, nu se poate vorbi despre o distribuție uniformă pe mulțimea Y^X ,

pentru ca știm de la bun început ca probabilitatea asociată celor mai multe funcții (funcțiilor aproape incompresabile în sens Kolmogorov) este nulă. Aceste funcții nu pot fi descrise într-un limbaj de programare printr-un program mai scurt decât tabela lor de valori; pentru o funcție booleană de 300 de variabile s-ar obține astfel $2^{300} \approx 8 \cdot 10^{30}$ linii de cod, mai mult decât orice program cunoscut. Or, algoritmi genetici sunt frecvent folosiți pentru optimizarea funcțiilor booleene de sute de variabile. Deci, conchide Park, nu se poate susține afirmația ca distribuția de probabilitate este uniformă pe mulțimea funcțiilor și, ca atare, teorema nu are o relevanță reală în practică.

Autorii teoremei s-au apărut susținând ca:

1. Teorema prezintă un fapt matematic real, indiferent de limitările cu care ne confruntăm în viață;
- și
2. Nu există nici un motiv pentru care un rezultat demonstrat pentru mulțimea tuturor funcțiilor nu ar putea fi aproximativ corect și pentru o submulțime cum este cea a funcțiilor suficient de puțin complexe în sens Kolmogorov pentru a putea fi implementate pe calculator.

La acestea putem adauga că:

1. Multe aplicații ale algoritmilor genetici maximizează o funcție de cost ce nu este simulată pe calculator (cum ar fi, de exemplu, în aplicațiile economice, în care valoarea funcției pentru o anumită stare este măsurată din indicatori reali);
2. Mulțimea funcțiilor "suficient" de complexe din punct de vedere Kolmogorov nu este bine definită, iar rezultatele caracteristice pentru diverșii algoritmi sunt obținute pentru mulțimea tuturor funcțiilor definite pe mulțimile X și Y respective (vezi, de pildă, teorema șablonului).

Cu toate acestea, relevanța practică a teoremei rămâne discutabilă.

Importanța teoremei de echivalență și a corolariilor ei constă, însă, în următoarele:

1. Au fost expuse formulările eronate de genul "algoritmii genetici reprezintă metode, în general, mai bune decât căutarea aleatoare";
2. S-a stabilit o direcție clară pentru adaptarea algoritmilor la problema. Până acum, nu a fost evident ce însemna "a cunoaște o problema", pentru a putea adapta un algoritm la ea. În formularea teoremei NFL, se vede clar ca a cunoaște o funcție de cost revine la:

a) a cunoaște o distribuție de probabilitate $P(f)$ după care se extrage funcția;

sau, echivalent:

b) a cunoaște distribuțiile posibile ale valorilor $P(f(x)=y)$ pentru $y \in Y$.

De altfel, teoremele de convergență, demonstrate până acum, relativ la algoritmii genetici cad, în linii mari, în două categorii:

i) teoreme bazate pe o bună adecvare a reprezentării la funcția de cost, cum este teorema șablonului;

ii) teoreme de convergență globală, care se bazează pe proprietatea unui algoritm genetic de a "epuiza" spațiul X pentru un timp de rulare suficient de mare.

Bibliografie

1. **BAȚACHIA, I. L., C. IONESCU:** Metode de optimizare bazate pe algoritmi genetici. Raport de cercetare, 2064GR/1996.
2. **WOLPERT, D.H., MACREADY, W.G.:** No Free Lunch Theorems for Search. Technical Report, Santa Fe Institute, Argentina, 1995, <ftp://ftp.santafe.edu/pub/wgm/nfl.ps>.
3. * * *: GA-Digest. Vol. 9-16, <http://www.aic.nrl.navy.mil/galist>.
4. **MICHALEWICZ, Z.:** Genetic Algorithms + Data Structures = Evolution Programs, Springer Verlag, New York, 1994.