

Algoritmi genetici

Prep. Claudia Mihaela Mark
Universitatea "Tibiscus" din Timișoara

ABSTRACT. In this thesis is presented the main directions regarding evolutive algorithms, especially genetic algorithms. The practical application of these algorithms are many and they are more and more used in a various domains, like plane wing design or orbital space stations design. The power of genetical algorithms come from their implementation simplicity and from the fact that they always give good results, even if by using this algorithms we can not always give a global result.

1 Introducere

Algoritmii genetici sunt o familie de modele inspirate de teoria evoluției, sunt programe inteligente capabile să soluționeze probleme folosind un concept al evoluției speciilor. Acești algoritmi codifică soluțiile posibile ale unor probleme specifice într-o structură de date de tip *cromozom* și aplică acestor structuri operatori de recombinare, pentru a păstra informația utilă.

Un cromozom este un vector sau un șir de gene. Poziția unei gene este numită *locusul* ei. Valorile pe care le poate lua o genă sunt numite *alele*, sunt mulțimi finite de numere întregi, intervale de numere reale, sau chiar structuri complexe de date. Alele (genă de un anumit tip de pe același cromozom) variază de la un locus la altul.

Sarcina unui algoritm genetic e să descopere cromozomi din ce în ce mai buni, până la atingerea unei valori a raportului dintre evaluarea asociată unui șir și evaluarea medie a tuturor șirurilor populației (*fitness*) despre care se știe că este optimală, sau până când algoritmul genetic nu mai poate aduce îmbunătățiri.

Implementarea unui algoritm genetic începe cu o populație de cromozomi (aleasă aleator). Se evaluează, apoi, aceste structuri și se alocă

facilități reproductive astfel încât acei cromozomi, care reprezintă o soluție mai bună pentru problema țintă, să aibă mai multe șanse de a se reproduce decât acei cromozomi care sunt soluții mai puțin bune. Definiția unei soluții bune se face în raport cu populația curentă.

Într-un sens mai larg, algoritmul genetic este orice model bazat pe ideea de populație și care folosește selecție și operatori de recombinare pentru a genera noi puncte într-un spațiu de căutare. Multe modele au fost introduse de cercetători dintr-o perspectivă experimentală. Cercetătorii sunt orientați spre aplicații, fiind interesați de algoritmi genetici doar ca mijloace de optimizare.

Ei sunt recomandați pentru aflarea soluțiilor neliniare ale unor probleme atunci când nu este posibilă modelarea matematică și nici euristica în domeniu.

Adevărații profesioniști combină adesea cele mai variate tehnologii inteligente în scopul exploatarei avantajelor fiecăreia, obținând așa-numitele sisteme hibride. Sunt posibile combinații de genul:

1. folosirea rețelelor neuronale la ajustarea parametrilor în sistemele expert fuzzy;
2. extragerea cunoașterii din rețele neuronale pentru a fi utilizată în sistemele expert;
3. folosirea algoritmilor genetici la crearea unor rețele neuronale mai compacte și mai eficiente;
4. folosirea unei rețele neuronale pentru asistarea funcționării unui algoritmul genetic;
5. folosirea algoritmilor genetici la reglarea parametrilor unui sistem expert fuzzy pentru controlul proceselor;
6. îmbunătățirea performanței unui sistem expert prin încorporarea raționamentului bazat pe cazuri, etc.

Asemenea cercetări sunt în prezent în mare vogă în cele mai specializate laboratoare ale lumii științifice.

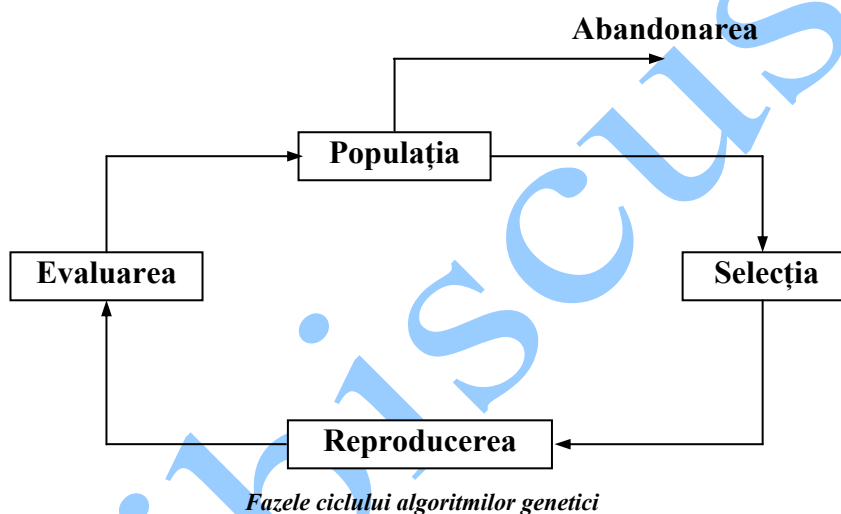
Mecanismul specific acestor sisteme este inspirat din funcționarea sistemelor biologice, în sensul că încurajează soluțiile candidat capabile să rezolve o problemă și penalizează soluțiile fără succes. În felul acesta se obțin, după mai multe generații, soluții foarte bune pentru probleme de optimizare complexe, cu un mare număr de parametri.

Ideea de bază a unui algoritmul genetic constă în a începe cu o populație de soluții, fiecare mai performantă decât precedentele. Fazele ciclului prin care operează un asemenea algoritmul sunt:

1. crearea unei populații de “membri”, (soluții candidat la rezolvarea unei probleme),

2. selecția membrilor care s-au adaptat cel mai bine necesităților problemei de soluționat,
3. reproducerea (se folosesc operatorii genetici de încrucișare și mutație, pentru a obține noi membri),
4. evaluarea gradului în care noii membri corespund mai bine soluționării problemei,
5. abandonarea populației vechi prin înlocuirea ei cu populația nouă din noua generație.

Un asemenea ciclu se repetă până când este identificată cea mai bună soluție la problema în cauză.



Datorită structurii lor inerent paralele, sisteme inteligente bazate pe algoritmi genetici s-au dovedit performante în problemele de căutare și identificare a structurilor și relațiilor specifice în cadrul bazelor de date și bazelor de cunoștințe voluminoase (data mining). Un succes particular s-a obținut cu ele în problemele de optimizare referitoare la selectarea personalului și selectarea portofoliilor.

Și aceste sisteme, deoarece pot învăța relații și structuri complexe în cadrul seturilor de informații și cunoștințe incomplete, se pot adapta schimbărilor survenite în mediile în care funcționează, și pot fi utilizate ca instrumente pentru descoperirea unor cunoștințe noi. Ele pot oferi explicații la deciziile luate într-un format perceptibil de către om.

Aplicațiile acestor sisteme s-au diversificat rapid și s-au dovedit utile domeniul afacerilor financiare, comerțului cu titluri, evaluării creditelor, detecției fraudelor și predicției falimentului. De exemplu, unii cercetători au folosit asemenea sisteme la inferarea unor reguli pentru predicția

falimentului întreprinderilor, pe baza indicatorilor financiari obținuți din bilanț (financial ratios). Alți cercetători descriu modul de utilizare a algoritmilor genetici în alocarea bugetară, în vederea asistării guvernelor și administrațiilor locale la adoptarea celor mai bune decizii.

2 Calcul evolutiv

În general, orice sarcină abstractă care trebuie îndeplinită, poate fi privită ca fiind rezolvarea unei probleme, care, la rândul ei, poate fi percepută ca o căutare în spațiul soluțiilor potențiale.

Deoarece, de obicei, căutăm cea mai bună soluție, putem privi acest proces ca fiind unul de optimizare.

Pentru spații mici, metodele clasice exhaustive sunt suficiente; pentru spații mari, pot fi folosite tehnicile speciale ale inteligenței artificiale.

Metodele calculului evolutiv se numără printre aceste tehnici; ele folosesc algoritmi ale căror metode de căutare au ca model câteva fenomene naturale: moștenirea genetică și lupta pentru supraviețuire. Cele mai cunoscute tehnici din clasa calculului evolutiv sunt algoritmi genetici, strategiile evolutive, programarea genetică și programarea evolutivă. Există și alte sisteme hibride care încorporează diferite proprietăți ale paradigmelor de mai sus; mai mult, structura oricărui algoritm de calcul evolutiv este, în mare măsură, aceeași.

În ultimii 30 de ani, s-a manifestat un mare interes în rezolvarea problemelor de sistem bazate pe principiile evoluției și eredității. Astfel de sisteme mențin o populație de soluții potențiale, ele au unele procese de selecție bazate pe fitness individual, și cațiva operatori genetici. Un astfel de sistem este o clasa a evoluției strategice i.e. algoritmi care imită principiile evoluției naturale pentru problemele de optimizare de parametru (Rechemberg, Schwefel). Evoluția programării lui Fogel este o tehnică de căutare într-un spațiu finit, mic de mașini. Tehnologiile de căutare a mașinii lui Glover Scatter mențin o populație de puncte de referință, generând o stare specială prin greutatea combinațiilor liniare.

Alte tipuri de sisteme evoluționare sunt HollandTMs Genetic Algorithms. În 1990 Koza a propus un astfel de sistem evoluțional, *genetic programming*, pentru a căuta cel mai potrivit program de computer care să rezolve o problema particulară.

Structura evoluției programului este arată mai jos:

```
procedura algoritm_evolutiv
  t ← 0
  create P(t)
  evaluare P(t)
  cât timp nu condiția de terminare
    t ← t + 1
    selectare P(t) din P(t-1)
    modificare P(t)
    evaluare P(t)
  sfârșit cât timp
sfârșit procedura
```

În cele ce urmează vom explica algoritmul general propus mai sus.

Evoluția programului este un algoritm probabilistic ce conține elemente distincte, $P(t) = \{x_1^t, x_2^t, \dots, x_n^t\}$. Algoritmii evolutivi mențin o populație de indivizi la fiecare iterație t . O populație poate fi privită ca fiind un vector de valori. Fiecare element distinct reprezintă o soluție potențială a problemei în cauză și în orice program, este interpretat ca S structura de date.

Fiecare soluție $x_1^t, x_2^t, \dots, x_n^t$ este evaluată pentru a da o oarecare măsură a fitness-ului său.

Fiecare individ (element al vectorului) reprezintă o soluție potențială a problemei și este implementată sub forma unei structuri de date S . Un individ este uneori numit și *chromozom*. Fiecare soluție este evaluată ca fiind o măsură a "fitness-ului" său (speranța ei de viață). Acest fitness reprezintă calitatea individului. De obicei, cu cât individul este mai promițător, cu atât fitness-ul său este mai mare. Există unele probleme în cazul cărora fitness-ul trebuie să fie minimizat.

O nouă populație (iterația $t+1$) se formează prin selectarea mai multor potriviri individuale, alegând cei mai promițători indivizi (pasul de selecție) din populația curentă. O parte din membri populației nou formate suferă transformări (pasul de modificare) prin operarea "genetică", a noilor soluții. Vorbim despre o transformare unică a evoluției programului.

3 Operatori genetici - calculul evolutiv

Operatorii genetici sunt, de fapt, proceduri care operează asupra elementelor vectorului populație. Există doi operatori genetici principali:

- un operator unar m_i de transformare numit *mutație*, care creează un nou individ printr-o mică modificare a unui individ ales ($m_i: S \rightarrow S$);
- un operator mai puternic c_j numit *încrucișare*, care creează noi indivizi combinând părți din doi sau mai mulți indivizi ($c_j: S \times \dots \times S \rightarrow S$) (de cele mai multe ori se folosesc doi părinți).

După un anumit număr de generații algoritmul *converge*: se speră că cel mai promițător individ ajunge la o valoare cât mai apropiată de soluția optimă. În ciuda similarităților puternice între diferitele tehnici de calcul evolutiv, există și multe diferențe. Acestea sunt date, în principal, de structurile de date folosite pentru a reprezenta un individ și de ordinea în care se aplică operatorii genetici. De exemplu, cele două linii din algoritmul de mai sus:

selectare $P(t)$ din $P(t-1)$
modificare $P(t)$

pot apărea în ordine inversă: (în strategiile evolutive, întâi se modifică populația și apoi este formată o nouă populație prin procesul de selecție, în timp ce într-un algoritm genetic întâi se aplică selecția, iar apoi intră în acțiune operatorii genetici de transformare).

Există, de asemenea, și alte diferențe între metode. Una dintre acestea ar fi cea referitoare la metodele de selecție care includ:

- **selecția proporțională**, unde șansa (probabilitatea) ca un individ să fie selectat este proporțională cu fitness-ul lui;
- **metoda rangului**, în care toți indivizii din populație sunt sortați în funcție de fitness, iar probabilitatea (șansa) ca ei să fie selectați este fixată de întreg procesul de evoluție (de exemplu, probabilitatea de selecție a celui mai promițător individ este 0.15, a individului următor este 0.14, etc.; cel mai promițător individ are cea mai mare probabilitate și suma totală a probabilităților indivizilor este 1);
- **selecția prin turnir (prin concurs)** unde un anumit număr de indivizi (de obicei doi) luptă pentru a fi selectați în noua generație.

Această competiție (turnir) este repetată până sunt selectați un număr de indivizi egal cu dimensiunea populației. Pentru fiecare dintre aceste categorii de selecție există și alte detalii importante. Câteva exemple sunt:

- selecția *proporțională* poate necesita folosirea unor metode de trunchiere;
- există diferite moduri pentru stabilirea probabilității în metoda *rangului*;
- dimensiunea mulțimii alese pentru concurs poate juca un rol semnificativ în metoda selecției prin turnir.

Trecerea de la o generație la alta poate fi efectuată în două variante:

- *algoritm generațional* (noua populație este formată doar din descendenți ai vechii generații);
- *algoritm non-generațional* (în noua populație sunt introduși, de obicei, cei mai promițători indivizi din cele două populații, cea a părinților și cea a descendenților).

Este posibil, de asemenea, să creăm puțini (în particular, unul singur) descendenți, care înlocuiesc câțiva (cei mai puțin promițători) indivizi. Ca o regulă generală trebuie reținut faptul că, în majoritatea cazurilor, este de preferat să se utilizeze un model elitist, care păstrează cei mai promițători indivizi dintr-o generație și îi adaugă automat generației următoare (aceasta înseamnă că, dacă cel mai promițător individ din generația curentă este pierdut datorită selecției sau operatorilor genetici, sistemul forțează apariția lui într-o generație următoare). Un astfel de model este foarte folositor pentru rezolvarea multor probleme de optimizare. Totuși, structurile de date folosite pentru probleme particulare, împreună cu o mulțime de operatori genetici, constituie componenta esențială a oricărui algoritm evolutiv. Acestea sunt elementele cheie care ne permit să distingem între variatele paradigme ale metodelor evolutive.

4 Algoritmi genetici - paradigme ale calculului evolutiv

Există o mare clasă a problemelor interesante pentru care încă nu au fost dezvoltati algoritmi rapizi. Multe dintre acestea sunt probleme optimizate care intervin frecvent în aplicații.

Dându-se o problemă prost optimizată este posibil mereu să găsim un algoritm eficient a cărui soluție este aproximativ optimală. Pentru unele probleme prost optimizate putem folosi algoritmi probabilistici (acești algoritmi nu garantează valoarea optimă, dar prin alegeri aleatoare, suficient de multe "slăbiciuni" ale erorilor pot fi făcute astfel încât să putem trece peste ele).

Există multe probleme importante, practic optimizate, pentru care asemenea algoritmi, de o înaltă calitate, devin disponibili. În orice caz, putem aplica simultan rularea pe mai multe fire de execuție și transfera competența amplasării problemelor VLSI design pentru problemele gen agent comercial. În plus, multe alte probleme aparținând unei game largi de probleme optimizate combinatorial pot fi, în ziua de astăzi, rezolvate aproximativ, prin computer, în genul tehnicilor Monte Carlo.

În general, orice proces abstract, pentru a fi îndeplinit, poate fi gândit ca o rezolvare a problemei care, în schimb, poate fi percepută ca o căutare prin spațiul soluțiilor potențiale. Cum suntem în căutarea “celei mai bune soluții”, putem privi această sarcină ca un proces optimizat. Pentru spațiile mici, metodele clasice executive sunt suficiente; pentru spațiile largi tehnica specială a inteligenței artificiale trebuie să fie luată în vedere. Algoritmii genetici sunt printre aceste tehnici; ei sunt algoritmi stohastici a căror metode de căutare modelează unele fenomene naturale.

Ideea în spatele algoritmilor genetici este de a face ceea ce natura face. Începuturile algoritmilor genetici se situează undeva în jurul anului 1950, când mai mulți biologi au folosit calculatoarele pentru simularea sistemelor biologice. Rezultatele muncii au început să apară după 1960, când la Universitatea din Michigan, sub directa îndrumare a lui John Holland, algoritmii genetici au apărut în forma în care sunt cunoscuți astăzi.

După cum sugerează și numele, algoritmii genetici folosesc principii din genetica naturală. Câteva principii fundamentale ale geneticii sunt împrumutate și folosite artificial pentru a construi algoritmi de căutare care sunt robuști și cer informații minime despre problemă.

Algoritmii genetici au fost inventați folosind modelul procesului de adaptare. Ei operează, în principal, cu șiruri binare și folosesc un operator de recombinare și unul de mutație. Prin mutație se schimbă un element (genă) dintr-un cromozom, iar prin încrucișare se schimbă material genetic între doi părinți; dacă părinții sunt reprezentați prin șiruri de cinci biți, de exemplu $(0, 0, 0, 0, 0)$ și $(1, 1, 1, 1, 1)$, încrucișarea celor doi vectori poate duce la obținerea descendenților $(0, 0, 1, 1, 1)$ și $(1, 1, 0, 0, 0)$ (acesta este un exemplu al așa-numitei încrucișări cu un punct de tăietură).

Fitness-ul unui individ este atribuit proporțional cu valoarea funcției criteriu corespunzătoare individului; indivizii sunt selectați pentru generația următoare pe baza fitness-ului lor.

Vom ilustra **modul de lucru al algoritmilor genetici** cu ajutorul unei probleme simple: proiectarea unei cutii de conserve. Considerăm o cutie de conserve cilindrică, cu numai doi parametri: diametrul d și înălțimea h (evident, pot fi considerați și alți parametri, cum ar fi grosimea, proprietăți ale materialului, formă, dar sunt suficienți doar cei doi parametri pentru a ilustra lucrul cu algoritmii genetici).

Să considerăm că această conservă trebuie să aibă un volum de cel puțin 300 ml și obiectivul proiectului este de a minimiza costul materialului folosit la fabricarea conservei.

Putem formula problema noastră astfel:
să se minimizeze valoarea funcției

$$f(d, h) = c \left(\frac{\pi \cdot d^2}{2} + \pi \cdot d \cdot h \right)$$

unde c reprezintă costul materialului conservei per cm^2 , iar expresia din paranteză reprezintă suprafața conservei. Funcția f se mai numește și *funcție criteriu* (sau *funcție obiectiv*). Mai trebuie îndeplinită și condiția ca volumul cutiei să fie cel puțin 300 ml și vom formula aceasta astfel:

$$g(d, h) = \frac{\pi \cdot d^2 \cdot h}{4} \geq 300.$$

Parametrii d și h pot varia între anumite limite $d_{\min} \leq d \leq d_{\max}$ și $h_{\min} \leq h \leq h_{\max}$.

4.1 Reprezentarea soluției

Primul pas în utilizarea unui algoritm genetic este stabilirea unei codificări a problemei.

Codificarea binară este cea mai obișnuită dintre tehnicile de codificare; ea este simplu de manipulat și conferă robustețe problemei.

Reprezentarea binară poate codifica aproape orice situație, iar operatorii nu includ cunoștințe despre domeniul problemei. Este motivul pentru care un algoritm genetic se poate aplica unor probleme foarte diferite. În cazul codificării binare, fiecare valoare se reprezintă printr-un șir de lungime specificată care conține valorile 0 și 1. În anumite situații este necesar să utilizăm codificarea "naturală" a problemei, în locul reprezentării binare. Un exemplu de codificare naturală ar fi codificarea reală, care utilizează numere reale pentru reprezentare. Pentru a folosi algoritmi genetici la găsirea unor valori optime pentru parametri d și h , care să satisfacă condiția prezentată sub forma funcției g și care să minimizeze funcția f , vom avea în primul rând nevoie de reprezentarea valorilor parametrilor în șiruri binare (vom folosi, așadar, o codificare binară a problemei).

Algoritmii genetici nu ne impun numai valori întregi dintr-un anumit interval; în general, putem folosi orice altă valoare întreagă sau reală, prin schimbarea lungimii șirului binar.

4.2 Atribuirea fitness-ului

Am afirmat anterior că algoritmi genetici lucrează cu șiruri de biți reprezentând valorile parametrilor și nu cu parametrii înșiși. După ce a fost creat un nou șir (o nouă soluție) prin operatori genetici, trebuie să-l

evaluăm. În majoritatea cazurilor, fitness-ul este chiar valoarea funcției criteriu pentru soluția respectivă. Dacă obiectivul nostru este de a minimiza funcția criteriu, atunci vom spune că o soluție este mai bună decât alta, dacă fitness-ul celei de-a doua este mai mare.

5. Structura unui algoritm genetic

Vom descrie în continuare structura algoritmilor genetici. Pentru început vom stabili următoarele:

- cromozomii utilizați au lungime constantă;
- populația (generația) $P(t + 1)$ de la momentul $t + 1$ se obține reținând toți descendenții populației $P(t)$ și ștergând ulterior cromozomii generației precedente ($P(t)$);
- numărul cromozomilor este constant.

Putem prezenta acum structura algoritmului genetic fundamental:

Pasul 1: $t \leftarrow 0$.

Pasul 2: Se inițializează aleator populația $P(t)$.

Pasul 3: Se evaluează cromozomii populației $P(t)$. În acest scop se utilizează o funcție de performanță ce depinde de problemă.

Pasul 4: Cât timp nu este îndeplinită condiția de terminare se execută pașii următori:

Pasul 4.1: Se selectează cromozomii din $P(t)$ care vor contribui la formarea noii generații. Fie P_1 mulțimea cromozomilor selectați (P_1 reprezintă o populație intermediară).

Pasul 4.2: Se aplică cromozomilor din P_1 operatorii genetici. Cei mai utilizați sunt operatorii de mutație și încrucișare. În funcție de problemă se pot alege și alți operatori (inversiune, reordonare, operatori speciali). Fie P_2 populația astfel obținută (descendenții populației $P(t)$). Se șterg din P_1 părinții descendenților obținuți. Cromozomii rămași în P_1 sunt incluși în populația P_2 . Se construiește noua generație, astfel: $P(t+1) \leftarrow P_2$; se șterg toți cromozomii din $P(t)$; se execută atribuirea $t \leftarrow t+1$; se evaluează $P(t)$.

Condiția de terminare se referă, de regulă, la atingerea numărului de generații specificate. Dacă numărul maxim admis de generații este N , atunci condiția de oprire este $t > N$. Se admite că rezultatul algoritmului este dat de cel mai promițător individ din ultima generație. În realitate, nimic nu ne garantează că un individ mai performant nu a fost obținut într-o generație anterioară. De aceea, este normal ca la fiecare pas (la fiecare generație t) să

reținem cel mai promițător individ care a fost generat până atunci. Acest proces se numește *elitism*.

6 Selecția

Un rol important în cadrul unui algoritm genetic îl ocupă operatorul de selecție. Acest operator decide care dintre indivizii unei populații vor putea participa la formarea populației următoare. Scopul selecției este de a asigura mai multe șanse de reproducere celor mai performanți indivizi dintr-o populație dată. Prin selecție se urmărește maximizarea performanței indivizilor. În continuare vom prezenta succint cele mai importante mecanisme de selecție.

Selecția proporțională

În cazul selecției proporționale, probabilitatea de selecție a unui individ depinde de valoarea performanței acestuia. Să presupunem că avem o mulțime de cromozomi x_1, x_2, \dots, x_n . Pentru fiecare cromozom x_i vom calcula performanța sa $f(x_i)$. Se impune condiția ca $f(x_i) \geq 0$. Suma performanțelor tuturor cromozomilor din populație va constitui performanța totală și o vom nota cu F .

Selecția bazată pe ordonare

Această modalitate de selecție constă în a calcula (pentru fiecare generație) valorile funcției de fitness și de a aranja indivizii în ordinea descrescătoare a acestor valori. Se va atribui fiecărui individ i o probabilitate de selecție p_i care depinde de rangul său în șirul stabilit. Probabilitățile depind acum doar de poziția cromozomului. Cel mai promițător individ are probabilitatea 1.

Selecția prin concurs

Selecția prin concurs sau selecția turnir se bazează pe compararea directă a câte doi cromozomi și selectarea celui mai performant.

Operațiile implicate sunt următoarele:

- se aleg în mod aleator doi cromozomi;
- se calculează performanțele cromozomilor selectați;
- cromozomul mai performant este selectat (copiat în populația intermediară asupra căreia se aplică operatorii genetici).

Alte mecanisme de selecție

Un alt tip de selecție este selecția elitistă. În acest caz, la fiecare generație se păstrează cel mai promițător sau cei mai promițători indivizi. O altă idee ar fi ca, la fiecare generație, să fie înlocuită doar o parte restrânsă a populației.

7 Operatorii genetici

Descriem în continuare operatorii genetici folosiți, de obicei, într-un algoritm genetic.

Operatorul de reproducere

Rolul operatorului de reproducere este de a menține soluțiile promițătoare din populație și de a le elimina pe cele mai puțin promițătoare, păstrând constant dimensiunea populației.

Aceasta se realizează astfel:

- se identifică soluțiile promițătoare din populație;
- se creează mai multe copii ale soluțiilor promițătoare;
- se elimină soluțiile mai puțin promițătoare din populație astfel încât multiplele copii ale soluțiilor promițătoare să poată fi plasate în populație.

Există mai multe moduri de a realiza acest lucru. Cele mai uzuale metode sunt selecția proporțională, selecția prin turnir și selecția prin ordonare. Este ușor de observat că soluțiile promițătoare au mai mult de o copie în populația intermediară.

Operatorul de încrucișare

Operatorul de încrucișare este aplicat asupra indivizilor din populația intermediară. Operatorul de încrucișare acționează în felul următor: sunt aleși aleator doi indivizi din populația intermediară (care se mai numește și piscină de încrucișare) și anumite porțiuni din cei doi indivizi sunt interschimbate. Operatorul imită încrucișarea intercromozomială naturală.

De regulă, se utilizează operatori de încrucișare de tipul (2,2), adică doi părinți dau naștere la doi descendenți. Încrucișarea realizează un schimb de informație între cei doi părinți. Descendenții obținuți prin încrucișare vor avea caracteristici ale ambilor părinți.

Trebuie reținut faptul că încrucișarea nu generează descendenți aleatori. Deși este improbabil ca fiecare încrucișare între două soluții din populație să genereze soluții fii mai promițătoare decât soluțiile părinte, totuși în scurt timp devine clar că șansa de a crea soluții mai promițătoare

este mai mare decât în cazul căutării aleatoare. Din încrucișarea cu un singur punct de tăietură a unei perechi de șiruri binare, se pot crea doar două șiruri pereche diferite care vor avea în componența lor și combinați din ambii părinți; soluțiile fiu create sunt, probabil, șiruri cel puțin la fel de promițătoare. Prin urmare, nu fiecare încrucișare poate crea soluții la fel de promițătoare, dar nu vor fi mai puțin promițătoare decât părinții.

Operatorul de mutație

Operatorul de încrucișare este, în principal, responsabil cu aspectul de căutare al algoritmilor genetici, în timp ce operatorul de mutație este folosit pentru alte scopuri. Mutația este cel de-al doilea operator genetic în ordinea importanței și folosirii sale. Efectul acestui operator este schimbarea valorii unei singure poziții dintr-un cromozom. Prin mutație se introduc în populație indivizi care nu ar fi putut fi obținuți prin alte mecanisme.

Operatorul de mutație acționează asupra biților indiferent de poziția lor în cromozom. Fiecare bit al cromozomului poate suferi o mutație. Într-un cromozom pot exista, așadar, mai multe poziții care suferă o mutație. Mutația este un operator probabilist (adică nu se aplică cu siguranță). Considerăm o populație de n indivizi (cromozomi), fiecare având lungimea r . Fiecare bit are aceeași probabilitate p_m de a suferi mutația.

Există mai multe variante ale operatorului de mutație. Una dintre ele ar fi *mutația în formare*.

În această situație se procedează în felul următor: se generează un număr aleator q în intervalul $[0, 1)$.

Dacă $q < p_m$, atunci se execută mutația poziției respective schimbând 0 în 1 sau 1 în 0. În caz contrar, poziția respectivă nu se schimbă. Soluția obținută este mai promițătoare decât soluția originală. În consecință, operatorul de reproducere selectează cele mai promițătoare șiruri, operatorul de încrucișare combină subșiruri din două șiruri promițătoare pentru a forma șiruri mai promițătoare, iar operatorul de mutație schimbă șirurile local, de asemenea, pentru a îmbunătăți soluția.

8 Strategii evolutive

Strategiile evolutive au fost dezvoltate ca metode de rezolvare pentru problemele de optimizare a parametrilor. Prima strategie evolutivă a fost bazată pe o populație constând dintr-un singur individ.

De asemenea, este folosit un singur operator în procesul de evoluție: mutația. Aceasta este în concordanță cu conceptul biologic potrivit căruia

modificări mici au loc mai frecvent decât o modificare mare. De obicei această strategie, conform căreia un părinte dă naștere, prin mutație, unui singur descendent, este cunoscută sub numele de strategie evolutivă 1+1. Felul în care se aplică, practic, acest algoritm este simplu: se generează o soluție aleatoare pe domeniul de căutare și se efectuează mutații asupra ei. Este acceptat cel mai bun dintre părinte și descendent. Operatorul de mutație se aplică repetat până când se ajunge la soluție.

Un alt tip de strategie este strategia $\mu\lambda$: μ părinți produc λ descendenți. Noua populație (temporară) de $\mu\lambda$ indivizi este redusă din nou - printr-un proces de selecție - la μ indivizi. Pe de altă parte, în strategia $\mu\lambda$, μ indivizi produc λ descendenți ($\lambda > \mu$) și prin procesul de selecție se alege o nouă populație de μ indivizi numai din mulțimea celor λ descendenți. Astfel, viața fiecărui individ este limitată la o generație.

8.1 Programarea evolutivă

Tehnicile programării evolutive originale au fost dezvoltate de Lawrence Fogel. El urmărea o dezvoltare a inteligenței artificiale în sensul dezvoltării abilității de a prezice schimbările într-un mediu înconjurător.

Mediul înconjurător a fost descris ca o secvență de simboluri, iar evoluarea algoritmului presupunea obținerea unui nou produs, și anume a unui nou simbol. Simbolul obținut va maximiza funcția finală care măsoară acuratețea predicției. De exemplu, putem considera o serie de evenimente notate a_1, a_2, \dots, a_n ; un algoritm va determina următorul simbol (a_{n+1}), bazându-se pe simbolurile cunoscute a_1, a_2, \dots, a_n .

Ideea care stă la baza programării evolutive este de a evolua un algoritm. Ca și în strategiile evolutive, și în tehnica programării evolutive se creează mai întâi descendenții și apoi se vor selecta indivizii pentru generația următoare.

Fiecare părinte produce un singur descendent; deci dimensiunea populației intermediare se dublează (ca în strategia evolutivă (n,n), unde n este dimensiunea populației). Descendentul este creat printr-o mutație aleatoare a părintelui (este posibil să se aplice mai mult de o mutație unui individ). Un număr de indivizi (cei mai promițători) egal cu dimensiunea populației sunt reținuți pentru noua generație.

În versiunea originală acest proces este repetat până se obține un nou simbol care este disponibil. După ce s-a obținut un nou simbol, acesta este adăugat listei simbolurilor cunoscute și întregul proces se repetă. Recent,

tehnicile de programare evolutivă au fost folosite pentru rezolvarea problemelor de optimizare numerică precum și în numeroase alte scopuri.

8.2 Programarea genetică

O altă abordare interesantă a fost descoperită relativ recent de John Koza. Koza sugerează că programul dorit va evolua el însuși pe parcursul unui proces de evoluție. Cu alte cuvinte, în loc de a rezolva o problemă și în loc de a construi un program evolutiv care să rezolve problema, vom încerca să găsim un cod sursă care să o rezolve.

Koza a dezvoltat o nouă metodologie care furnizează un mod de a efectua această căutare. De exemplu, se dorește obținerea unui program Pascal sau C++ care să rezolve problema drumului hamiltonian sau problema ieșirii dintr-un labirint. Deci, nu ne interesează să obținem o soluție pentru un set oarecare de date, ci, mai degrabă, ne interesează să obținem un program sursă care să genereze o soluție corectă pentru orice intrare dată. Cu alte cuvinte, ne interesează să obținem ca rezultat un program asemănător cu cel pe care l-am fi putut scrie noi dacă am fi știut să rezolvăm problema.

Din punct de vedere evolutiv abordarea unor astfel de probleme se face generând o mulțime (populație) aleatoare de coduri sursă care apoi sunt selectate pe baza funcției de fitness și evolute cu ajutorul unor operatori genetici specifici. În primul rând trebuie să atribuim o funcție de calitate (funcția fitness) fiecărui program generat. Această funcție de fitness trebuie să reflecte performanțele programului căruia îi este atașată.

De obicei atașarea unei funcții de fitness se face rulând programul respectiv și măsurând calitatea soluției în raport cu o soluție care se cunoaște a fi optimă. Un program va avea o calitate mai mare dacă soluția generată va fi mai asemănătoare cu cea a soluției corecte. Nu este grav dacă o soluție optimă nu se cunoaște anterior, deoarece noi dorim să obținem soluții cu un fitness cât mai mare (sau cât mai mic).

Evoluarea programelor sursă se realizează prin operatori genetici specifici. De exemplu, un operator de recombinare poate însemna alipirea secvențelor dintr-un cod sursă cu secvențe din alt cod sursă. Un operator de mutație ar putea însemna inserarea de noi instrucțiuni în codul sursă, ștergerea de instrucțiuni, transformarea de instrucțiuni. Evident, în urma aplicării acestor operatori genetici se generează cod sursă care conține greșeli de sintaxă. De asemenea, sunt generate secvențe de cod sursă nefolositoare.

Exemple în acest sens sunt secvența de instrucțiuni:

```
i := i + 1;  
i := i - 1;  
sau secvența:  
a := 0;  
b := c / a;
```

De obicei, se evoluează reprezentări mai simple ale programelor de calculator și anume reprezentările arborescente. Există limbaje de programare (de exemplu LISP) în care programele sunt scrise sub forma unor liste ușor transformabile în arbori.

Aplicație

În cele ce urmează vom prezenta rezolvarea unei probleme folosind algoritmi genetici.

Enunț (Submulțime de sumă dată)

Se consideră o mulțime M de n numere și un număr S . Să se determine o submulțime a mulțimii M care are suma elementelor cât mai apropiată de numărul S .

Rezolvare

Determinarea unei submulțimi de sumă dată este o problemă NP-complet. Aceasta înseamnă că nu se știe dacă există sau nu un algoritm de complexitate polinomială pentru rezolvarea acestei probleme. Până în prezent, algoritmi folosiți au complexitate exponențială, iar pentru anumite cazuri particulare au complexitate pseudopolinomială. De exemplu, putem rezolva rezonabil această problemă, dacă datele de intrare îndeplinesc următoarele condiții:

- sunt cel mult 100 de numere naturale;
- suma numerelor nu depășește 500 (mai exact, produsul dintre numărul numerelor și suma acestora nu trebuie să depășească dimensiunea maxim admisă pentru alocarea unei matrice -presupunem că aceasta este alocată static).

Dacă aceste condiții ar fi îndeplinite am putea rezolva ușor această problemă prin metoda programării dinamice, folosind un algoritm de complexitate $O(n \cdot S)$. Însă, dacă numerele nu ar fi întregi ci reale, sau suma lor ar fi mai mare decât 500, sau diferențele între ele ar fi mari etc., atunci algoritmul prin programare dinamică nu mai poate fi folosit. Am enumerat aici doar cazurile importante, dar pot fi imaginate și alte dificultăți.

Din aceste motive vom rezolva această problemă cu ajutorul unui algoritm genetic. Va trebui să găsim o reprezentare a soluției și, de asemenea, o funcție de fitness. Modul în care vom reprezenta soluția ne este

dată chiar în enunțul problemei: se cere o submulțime a unei mulțimi M cu n elemente.

Deci, o soluție a problemei este o submulțime. Vom codifica o submulțime printr-un șir de lungime n care conține doar valorile 0 și 1. Dacă o poziție k va avea valoarea 1, atunci submulțimea respectivă va conține elementul M_k (al k -lea element din mulțimea M), iar dacă pe poziția k este valoarea 0, atunci elementul respectiv nu aparține submulțimii. Această reprezentare a unei submulțimi este specifică tipului set din Turbo Pascal.

Modul de calcul al fitness-ului (calității) unei soluții (submulțimi) este simplu. Calculăm suma elementelor submulțimii, iar fitness-ul va fi diferența (în valoare absolută) dintre suma obținută și numărul dat S . În aceste condiții fitness-ul va trebui minimizat, deoarece noi dorim să determinăm o submulțime pentru care suma elementelor este cât mai apropiată de valoarea dată S .

Structura algoritmului genetic propus pentru rezolvarea acestei probleme a fost prezentată mai sus. Vom folosi selecția turnir pentru obținerea populației intermediare. Operatorii genetici folosiți sunt specifici codificării binare (încrucișare cu un singur punct de tăietură, mutație cu probabilitate $p_m = 0.1$).

9 Concluzii

În acest articol au fost prezentate principalele direcții ale algoritmilor evolutivi, în special ale algoritmilor genetici. Aplicațiile practice ale acestor algoritmi sunt nenumărate. Ei sunt folosiți în domenii tot mai neașteptate cum ar fi proiectarea aripilor de avion sau proiectarea formei stațiilor orbitale.

Dacă se dorește rezolvarea unei probleme genetice, trebuie ținut cont de următorii pași:

- Pentru a rezolva o problemă cu algoritmi genetici trebuie să o transformăm mai întâi într-o problemă de optimizare, adică să minimizăm sau să maximizăm o valoare (cel mai scurt lanț hamiltonian, cea mai mare componentă internă stabilă, etc.).
- Algoritmii genetici sunt algoritmi euristici, adică soluția găsită de ei nu este întotdeauna cea mai bună, dar se află într-o vecinătate a soluției optime. Deci, dacă avem de ales între un algoritm polinomial, care rezolvă sigur problema, și un algoritm genetic, ar fi de preferat să folosim algoritmul polinomial.

- Algoritmii genetici, de obicei, au complexitate polinomială. De aceea ei sunt foarte des utilizați pentru a rezolva problemele dificile (NP-complete). Rezultatele obținute sunt foarte apropiate de cele obținute de algoritmi siguri, dar care au rulat mii de ore.
- Dacă problema este complexă, folosim un algoritm genetic și nu o strategie evolutivă. De obicei mutația este un operator de căutare slab și prin urmare, dacă se folosește doar acesta, există șanse mari să se obțină soluții locale și nu globale.

Putem concludiona că puterea algoritmilor genetici constă în ușurința cu care sunt implementați și în faptul că dau de multe ori rezultate bune, chiar dacă nu găsesc întotdeauna optimul global.

Bibliografie:

- [BBM93] **Beasley D., Bull D.R. and Martin R.R.**, *An Overview of Genetic Algorithms*, Part 1, Foundations, University Computing, Vol.15, No.4, pp. 170-181, 1993.
- [Dum00] **Dumitrescu D.**, *Algoritmi genetici și strategii evolutive - Aplicații în inteligența artificială și în domenii conexe*, Editura Albastră, Cluj-Napoca, 2000.
- [GJ78] **Garey M.R. and Johnson D.S.**, *Computers and Intractability: A Guide to NP-completeness*, W.H. Freeman and Company, New York, 1978.
- [Gol89] **Goldberg D.E.**, *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison -Wesley, Reading, MA, 1989.
- [Koz92] **Koza J.R.**, *Genetic Programming*, MIT Press, Cambridge, MA, 1992.
- [Mic99] **Michalewicz Z.**, *Genetic Algorithms + Data Structures = Evolution Programs*, Second Extended Edition, 1999.
- [Olt00] **Oltean M.**, *Proiectarea și implementarea algoritmilor*, Computer Libris Agora, Cluj-Napoca, 2000.