

Algoritmi genetici: evolutie in genetica si informatica

Lorentz JÄNTSCHI

Catre genetica modernă

- Carl LINNAEUS (Linnaei, 1735) – prima clasificare a viețuitoarelor după clase, ordine, genuri și specii (și denumirile acestora în Latină)
- Jean-Baptiste LAMARCK (Lamarck, 1809) – studii sistematice cu privire la trăsăturile și caracterele plantelor; moștenirea ușoară
- Charles Robert DARWIN (Darwin, 1859) – teoria evoluției; supraviețuirea celui mai tare
- Gregor Johann MENDEL (Mendel, 1866) – moștenirea caracterelor prin încrucișare (studii pe mazăre)
- Friedrich Leopold August WEISMANN (Weismann, 1893) - moștenirea dură
- Thomas Hunt MORGAN (Morgan și alții, 1915) - teoria cromozomială a moștenirii
- Sir Ronald Aylmer FISHER (Fisher 1918, 1922, și 1954) - demonstrarea teoriei evoluției, selecției naturale, legilor lui Mendel, și teoriei cromozomiale

Catre programarea evolutiva

- Primele simulări ale evoluției se regăsesc în studiile lui Nils Aall BARRICELLI (Barricelli, 1954)
- Alex FRASER (1923-2002) a publicat o serie de lucrări despre simularea selecției artificiale a organismelor cu locuși multipli (locus: poziția pe care o anumită genă o ocupă pe un cromozom) ce controlează o trăsătură măsurabilă
- Simulările lui Fraser (Fraser, 1957-1970) includ toate elementele esențiale ale algoritmilor genetici moderni

Solutia informatica a complexitatii

- Complexitate exponențială: cel mai bun algoritm rezolvă problema într-un timp de execuție ce crește exponențial cu volumul datelor de intrare
- Euristici: set de reguli ce rezolva o problema bazat pe bunul simt în ceea ce privește soluția așteptată prin evitarea erorilor grosolane; nu produc totdeauna soluția cu exactitate și respectiv nu sunt capabili să producă o soluție pentru orice valori de intrare
- Meta-euristici: euristici aplicabili la o mare varietate de probleme dificile

Algoritmii genetici: ultima generatie de meta-euristică

- Căutarea tabu (TS - Tabu Search; Glover, 1977 și 1986; Glover și alții, 1992)
- Călirea simulată (SA - Simulated Annealing; van Laarhoven and Aarts, 1987; Davis, 1987)
- Algoritmi genetici (în engleză GA - Genetic Algorithm): studii de amploare - după 1970 (Bosworth și alții, 1972; Holland, 1975); re-invenția după 1991 (Davis, 1991, Holland, 1992)


Probleme complexe

- Teorema *inexistenței mesei pe gratis* (NFLT - No Free Lunch Theorem; Wolpert and Macready, 1995 și 1997) arată ca este obligatorie stabilirea unui domeniu de aplicabilitate pentru un heuristică
- Categorii de probleme dificile:
 - de decizie, de clasificare (ex. clasificarea filogenetica), de optimizare (ex. a semaforizării în Cluj), de simulare (ex. a evoluției speciilor)

Ce sunt algoritmii genetici

- Euristică adaptivă bazată pe ideile teoriei evoluției;
- Elementele cheie la care se face apel:
 - Modelul genetic (dualismul genotip - fenotip) ca în (Morgan, 1915; Fisher, 1918);
 - Încrucișarea (dualismul caractere - gene) ca în (Lamarck, 1830; Mendel, 1865; Weismann, 1893);
 - Mutația: întâmplătoare (De Veies, 1902); deliberată prin expunerea la anumite condiții (Patterson, 1928; Auerbach și alții, 1947); sub presiunea factorilor de mediu: (Cains și alții, 1988); etc
- Selectia naturală: supraviețuirea celui mai tare (Darwin, 1859)

Un algoritm genetic



Din "Jäntschi and Bolboacă, A genetic algorithm for structure-activity relationships: software implementation", manuscript, 26 Jun 2009, <http://arxiv.org/abs/0906.4846>

Domeniul sau de aplicabilitate

- Relatii structura-activitate:
 - Coreleaza activitatea biologica cu structura chimica
 - Necesita serii de compusi potenti biologic
 - A fost aplicat pe $\log(K_{ow})$ al PCB
- Familii de descriptori de structura:
 - Poseda un cod genetic (genom; gene)
 - Creeaza o populatie ce caracterizeaza structura
 - Creeaza o problema complexa de optimizare
 - A fost aplicat pe familia MDF (Jäntschi, 2004; Jäntschi, 2005; Jäntschi and Bolboacă, 2007)

Evolutie


- Optimizare => Simulare
 - Genetic Algorithms in Optimization, Simulation and Modeling (Stender, Hillebrand, and Kingdon, 1994)
- lex parsimoniae: entia non sunt multiplicanda praeter necessitatem (William of OCKHAM, 1288 - 1348)
 - regula lamei de ras a lui Ockham: trebuie eliminate toate acele presupuneri care nu fac nici o diferență în predicțiile observate ale ipotezelor explicatoare sau teoriei
- Optimizare: evolutia MLR folosind un esantion din MDF pe $\log(K_{OW})$ al PCB avand ca obiectiv “ $r^2=\max$ ”
- Simulare: 46 de executii independente ale evolutiei la contingenta (Proportional, Turnir, Deterministic) strategiilor de Selectie vs. Supravietuire

Cadrul evolutiei


- Obiectiv (fenotipic):
 - $r^2(\text{Act.Biol}; \text{MLR(4 indivizi MDF)}) = \text{max.}$
- Cultivar: max. $6 \times 12 = 72$ indivizi MDF (12 genotipuri)
- Strategia de Evolutie:
 - Cate 4 genotipuri (2 perechi) creeaza descendenti (mutatie si incruisare) in fiecare generatie
- Strategia de Selectie (pentru Mutatie si Incruisare):
 - Scor de selectie individ (Obiectiv \rightarrow max): $\min\{r^2(\text{Act.Biol}; \text{MLR(individ, 3MDF})\}$
 - Modalitate: Proportional, Turnir, Deterministic
- Strategia de Supravietuire (pentru inlocuirea materialului genetic crescut in Cultivar):
 - Scor de supravietuire individ: inversul mediei de similaritate genotipica si similaritate fenotipica
 - Similaritate genotipica: distante Manhattan intre genotipuri
 - Similaritate fenotipica: distante Manhattan intre scorurile de selectie
 - Modalitate: Proportional, Turnir, Deterministic
- Modalitatati de extragere:
 - Proportional: Sansa de calificare propotionala cu scorul
 - Turnir: Concureaza cate doi alesi la intamplare, se extrage cel mai tare
 - Deterministic: Cel mai tare dintre toti este extras

Care e viteza evolutiei?

- Calculul vitezei de evoluție medie ca raport dintre numărul de evoluții și numărul de generații arată că ordinul de mărime al vitezei de evoluție (în cazul studiat și pentru parametrii de experiment definiti) este de 1.37% adică în medie 1.37 evoluții la 1000 de generații




Cât de timpuriu se produc evoluțiile?




(Selectie, Supraviețuire) [CI(95%, Medie_{n=46}(generație medie))]

Cât de frecvent se produc evoluțiile?




(Selectie, Supraviețuire) [CI(95%,Medie_{n=46}(număr evoluții))]

Cât de dispers se produc evoluțiile?



(Selectie, Supraviețuire) [CI(95%, Deviație_{n=46}(generație medie))]

Cât de predictibil se produc evoluțiile?



(Selectie, Supraviețuire) [CI(95%, Deviație_{n=46}(număr evoluții))]

Distributia evolutiei

- Evolutia este supusa unor factori de stres:
 - Spatiul limitat (max. 12 genotipuri reprezentate de indivizi in cultivar)
 - Crearea de descendenti (prin selectie pentru mutatie si incruisare) este oferita doar celor mai bune 4 genotipuri
 - Ramanerea in spatiu (prin supravietuire) le este refuzata celor mai slabe 4 genotipuri
- Este de asteptat ca distributia scorurilor obiectiv ale unei generatii (estimata din cele 46 de executii independente) sa fie o distributie de valori extreme (nu distributie Normala – Gauss !!)
- S-a verificat (ca alternativa cu alte 45 legi de distributie) si demonstrat (semnificativ statistic, risc mai mic de 5% de a fi in eroare) ca evolutia (supusa factorilor de stres) creeaza o (sub)populatie distibuita dupa legea Fisher-Tippett (sau generalizata a valorilor extreme GEV) pe parcursul intregii evolutii si imediat dupa primele generatii

Fisher-Tippet (Generalized Extreme Value)


$$FT_{PDF}(X) = \begin{cases} \frac{1}{\beta} \exp\left(-(1+k\frac{x-\lambda}{\beta})^{-1/k}\right) \left(1+k\frac{x-\lambda}{\beta}\right)^{-1-1/k}, & k < 0 \quad \text{Weibull} \\ \frac{1}{\beta} \exp\left(-\frac{x-\lambda}{\beta} - \exp\left(-\frac{x-\lambda}{\beta}\right)\right), & k = 0 \quad \text{Gumbel} \\ \frac{1}{\beta} \exp\left(-(1+k\frac{x-\lambda}{\beta})^{-1/k}\right) \left(1+k\frac{x-\lambda}{\beta}\right)^{-1-1/k}, & k > 0 \quad \text{Fréchet} \end{cases}$$

$$FT_{CDF}(X) = \begin{cases} \exp\left(-(1+k\frac{x-\lambda}{\beta})^{-1/k}\right), & k < 0 \quad \text{Weibull} \\ \exp\left(-\exp\left(-\frac{x-\lambda}{\beta}\right)\right), & k = 0 \quad \text{Gumbel} \\ \exp\left(-(1+k\frac{x-\lambda}{\beta})^{-1/k}\right), & k > 0 \quad \text{Fréchet} \end{cases} \quad \text{Fisher - Tippett}$$

Lege de distributie introdusa in 1928 de Ronald A FISHER si Leonard HC TIPPETT
FISHER RA, TIPPETT LHC. 1928. Limiting Forms of the Frequency Distribution of the Largest of Smallest Member of a Sample. Proceedings of the Cambridge Philosophical Society 24:180-190


Distributii F-T(GEV) observe - $FT_{PDF}(r^2, \log_{10} \text{Generatie})$

Strategiile cu selectie proporcionala: PP, PT si PD




Distributii F-T(GEV) observe - $FT_{PDF}(r^2, \log_{10} \text{Generatie})$

Strategiile cu selectie in turnir: TP, TT si TD




Distributii F-T(GEV) observe - $FT_{PDF}(r^2, \log_{10} \text{Generatie})$


Strategiile cu selectie determinista: DP, DT si DD



Loteria norocosilor (CDF_{FT}=95%)



Loteria norocosilor (CDF_{FT}=5%)



Lărgimea intervalului de normalitate în selecție și supraviețuire (fără noroc, fără ghinion)

