FIATAL MŰSZAKIAK TUDOMÁNYOS ÜLÉSSZAKA

Kolozsvár, 2000. március 24-25.

GENETIKAI ALGORITMUSOK ALKALMAZÁSAI A GÉPGYÁRTÁSBAN

Tudose Lucian, Sóbester András

Throughout the last 20 years Artificial Intelligence has been increasingly successful in satisfying the ever growing demand for optimal design and manufacturing solutions. Optimal design based on Genetic Algorithms is one of the most promising areas in this relatively new field. Developed in the 70's, it has found a wide range of applications in mathematics, operations management, systems engineering, machine design etc. This article contains an overview of the method and an application: the minimum weight design of a spur gear drive.

A Genetikai Algoritmusokról általában

A többváltozós optimalizálási problémák tanulmányozásában az utóbbi évtizedek egyik legfontosabb újdonsága a mesterséges intelligencia térhódítása volt. Ezen az irányzaton belül jelentős szerepet töltenek be az evolucionista szimulációk körébe tartozó Genetikai Algoritmusok. John Holland, a Michigan University professzora dolgozta ki az első ilyen programot 1975-ben. A módszer azóta számos alkalmazást talált olyan változatos területeken mint a matematika, áramkörök, gépelemek és bonyolult mechanizmusok tervezése, telekommunikációs műholdak optimális elhelyezése, üzemszervezés stb.[1][2]

A Genetikai Algoritmus a természetes evolúció biológiai folyamatának egy sztochasztikus modellezése. A modellezett folyamat kiindulópontja a megoldani kívánt optimalizálási probléma néhány véletlenszerűen generált lehetséges megoldásának halmaza (populáció). Ahogy a természetben a legalkalmazkodóképesebb egyének maradnak fenn és hoznak létre utódokat, amelyekbe átörökítik bizonyos tulajdonságaikat, úgy itt is az optimalizálás objektívfüggvényébe

behelyettesítve a legjobb értékeket adó megoldások evolúálnak tovább. Az új generációk szintén a genetikában jól ismert természetes folyamatokat másoló operátorok segítségével jönnek létre; ezek a reprodukció, rekombináció és a mutáció. A kromoszómákat az egyes potenciális megoldások kódolt változatai képviselik, az őket alkotó gének pedig a vizsgált mechanikai rendszer tulajdonságai (azaz az optimalizálási probléma változói). Az evolúciós folyamatot modellező sorozatos iterációk eredményeképpen olyan populációk (megoldáshalmazok) jönnek létre, amelyekben egyes egyedek remélhetőleg jobbak lesznek szüleiknél. Ezzel elérkeztünk a Genetikai Algoritmusok hagyományos optimalizálási módszerekkel szembeni egyik legfontosabb előnyéhez: több lehetséges megoldás is fejlődik párhuzamosan egy populáción belül, ezáltal lehetővé téve azt, hogy a keresés ne "akadjon fenn" egy lokális optimumon -a populáció egy része mindig a lehetséges megoldások újabb és újabb területei felé evolúál.

Legyen $f(x_1, x_2, \dots, x_m)$ a függvény, amelynek a minimumát (vagy maximumát) keressük. Ez lehet a vizsgált rendszer tömege, költsége, az általa felhalmozott potenciális energia stb. A függvény változóit a rendszer m paramétere képviseli. Az előbbieken vázolt természeti analógiát folytatva ezeket a továbbiakban *géneknek* fogjuk nevezni, az m génből álló lehetséges megoldást pedig *kromoszómának*. A génektől függ a feladathoz csatolt n *korlátozás* is:

$$\begin{cases} g_1(x_1, x_2, \dots, x_m) \leq 0 \\ g_2(x_1, x_2, \dots, x_m) \leq 0 \\ \vdots \\ g_n(x_1, x_2, \dots, x_m) \leq 0 \end{cases} \quad (1)$$

Ezek általában szilárdságtani, méretbeni, gazdasági stb. természetűek – a megnevezés arra utal, hogy korlátozzák a lehetséges megoldások halmazát. E két elemből épül fel az optimalizálás objektív függvénye, amely az algoritmusban a környezethez való alkalmazkodóképességet fogja mérni:

$$\varphi(x_1, x_2, \dots, x_m) = f(x_1, x_2, \dots, x_m) + \sum_{j=1}^{n_y} r_j \cdot g_j^2(x_1, x_2, \dots, x_m) \quad (2)$$

ahol g_j az n_v megsértett korlátozás, r_j pedig az együttható, mely az illető korlátozás megsértésének súlyosságát mutatja.

A Genetikai Algoritmus lehetővé teszi, hogy pontosan, változónként meghatározzuk azt a halmazt, amelyben a megoldások keresendők. Ezek a halmazok lehetnek (kvázi)folyamatos intervallumok, de lehetnek diszkrét elemekből állók is. Ez különösen fontos a gépelemek tervezésében, ahol bizonyos változók csak meghatározott vagy szabvány értékeket vehetnek fel: normalizált méretek, fogaskerék modulok, kódolt változók (például egy anyagtípus) stb.

A következőkben egy konkrét alkalmazás segítségével próbáljuk megvilágítani egy Genetikai Algoritmus működését.

Egy egyenesfogú hengeres fogaskerék-hajtás optimális tervezése [3]

A tervezési feladat a következő volt: *méretezni kell egy egyenesfogú általános fogazású lassító fogaskerék-hajtást, ismerve a bemenő teljesítményt (P_1), a kiskerék fordulatszámát (n_1), az áttételt (i_{12}), az anyagot, a hőkezelést, valamint a kívánt élettartamot (L_h).* A minimizálni kívánt objektív függvény a hajtás tömege (a jelölések a szokásosak):

$$M = \frac{\pi \cdot (d_{w1}^2 + d_{w2}^2) \cdot b \cdot \rho}{4} \quad (3)$$

A megoldás első lépése a kromoszóma felépítése, amely, amint az 1. ábrán látható, 5 génből áll. Az érték-halmazok elemszámait összeszorozva megkapjuk a lehetséges megoldások halmazának elemszámát: $3 \cdot 4 \cdot 10^{10}$.

0.gén	1.gén	2.gén	3.gén	4.gén
z_1	m	a_w	x_1	Ψ_a
A KISKERÉK FOGSZÁMA	MODUL	TENGELYTÁV	A KISKERÉK PROFILELTOLÁSI TÉNYEZŐJE	A FOGSZÉLESSÉG ÉS A TENGELYTÁV VISZONYA
32 egész érték	32 szabv. érték	32 szabv. érték	1024 érték	1024 érték
{14,...,45}	{0.55,...,20}	{40,...,1400}	[-0.5,1]	[0.25,0.75]

1. ábra A fogaskerék-feladat kromoszómájának szerkezete (az utolsó két sorban a változó érték-halmaza)

Az objektív függvényhez 9 korlátozást is kapcsolunk (a (2)-es összefüggés alapján):

g_1 : A fogfelületi terhelés ellenőrzése (Hertz)

g_{2,3}: A kiskerék/nagykerék ellenőrzése fogtőhajlítási igénybevételre

g_{4,5}: A kiskerék/nagykerék fogazatának ellenőrzése alámetszésre

g_{6,7}: A kiskerék/nagykerék ellenőrzése foghegyesedésre

g₈: A kapcsolószám minimális értékének biztosítása

g₉: A kiskerék fogszámának összehasonlítása egy minimális értékkel

John Greffenstette *Genesis 1.6* genetikai programját alkalmazva a fent leírt feladat megoldására, az evolucionista szimuláció 1,000,000 generáció után egy olyan fogaskerékpárt generált, melynek a tömege kb. 15%-al kisebb volt a hagyományos módszerrel tervezettnél (ugyanazon adatokból kiindulva).

Következtetések

A fent bemutatott alkalmazás, valamint a Kolozsvári Műszaki Egyetemen tanulmányozott más alkalmazások is (csavaros összeszerelések optimális tervezése, egy tartálysorozat gyártási költségeinek minimizálása stb.) egyértelműen bizonyítják a Genetikai Algoritmusok alkalmasságát olyan feladatok megoldására, amik a változók nagy száma, a megoldások terének nagy mérete, vagy az objektív függvény komplexitása (esetleg diszkontinuitása, differenciálhatatlansága) miatt nagyon nehezen vagy egyáltalán nem lennének megoldhatók hagyományos módszerekkel.

Irodalom

1. Chacksfield J. E. *Multivariate Optimisation Techniques and their Impact on the Aircraft Design Process*, Prog. Aerospace Sci., Vol. 33, p. 731-757, 1997
2. Goldberg D. *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley Publishing Co., New-York, 1989
3. Tudose L., Giurgiu H. *Proiectare optimală. Organe de mașini*, Ed. U.T.Pres, Cluj-Napoca, 1999

Tudose Lucian egyetemi docens, Sóbester András gépészmérnök

Universitatea Tehnică Cluj-Napoca, Catedra de Organe de Mașini și Tribologie, Bdul. Muncii nr. 103-105, Tel. (0040)64-415007