

Intelligens Rendszerek

Genetikus algoritmus

Dr. Molnár András

Biológiai inspiráció

A genetikus programozás alapját Darwin evolúciós elmélete adja.

Fennáll egy életközösség, egy populáció valahány egyeddel. Az egyedek egy része szaporodik, létrehozzák utódaikat, valahány egyed tovább él, a többi egyed pedig elpusztul. A közösségben generációk sora váltja egymást, miközben az egyedek átalakulnak, jó esetben fejlődésen mennek át.

Ha jól szabályozott a rendszer, akkor az újonnan létrejött populáció hosszú távon átlagosan jobb "minőségű" egyedeket fog tartalmazni, és létrejöhet olyan egyed, ami valamilyen szempontból ideális.

Mikor használhatók?

A genetikus algoritmusokat akkor célszerű alkalmazni, ha:



- Ismert a probléma célértéke (kritériumfüggvény).
- Nem ismert a pontos célérték, de leírható (meghatározható) az egyes eredmények egymáshoz viszonyított jósága.
- Nem ismert az eredményhez vezető optimális út.
- Sok eljárás ismert, de nem ismert olyan módszer, amely optimális eredményt ad.

- Amikor a kritériumfüggvény felületének lokális minimumai vannak, önmagában a gradiens módszerek nem alkalmazhatóak, mert „beragadnak” egy lokális minimumba!
- Zaj bevezetése lehetővé teszi a lokális minimumokból való kiszabadulást.
- *Az evolúciós algoritmusokat sztochasztikus szélsőérték-keresésnek nevezzük. Ezek biológiai analógiákra épülnek.*
- *Az evolúciós algoritmusok négy fő csoportja:*
 - *a genetikus algoritmusok,*
 - *a genetikus programozás,*
 - *az evolúciós stratégiák és*
 - *az evolúciós programozás.*

Az algoritmus mechanizmusa

- A probléma grafikus reprezentációja:


Adott génkészlettel véges sok lépésben a rendszer „leáll”, azaz nem javul tovább!



Az algoritmus mechanizmusa

- A kezdeti populáció mértéke hatással van az eljárás sebességére:
 - Elvi megközelítéssel
 - Nagy populáció elvileg gyorsabb eredményt ad
 - Kis populáció elvileg lassabban ad eredményt
 - Számítás igény miatt
 - Nagy populáció lassú
 - Kis populáció gyors
 - Meg kell keresni az optimum közeli populációt!
 - A populáció mértéke nincs befolyással az eredmény jóságára!

Computer-Automated Design by Artificial Evolution



- A mutáció biztosítja a rendszer folyamatos működését (jóságának növekedését). A mutáció mértéke szintén hatással van az eljárás sebességére:
 - Mutáció nélkül a rendszer gyorsan leáll.
 - Alacsony mutáció esetében lassan jutunk eredményre.
 - Magas mutáció esetében a rendszer „szétesik”, nem ad eredményt.

Az algoritmus mechanizmusa

- Minden evolúciós algoritmus közös általános végrehajtási ciklusa:
 - stratégiai paraméterek választása (induló egyedek (individuumok) száma, szelekciós eljárás kiválasztása stb.)
 - a populáció kezdőértékeinek megadása
 - az individuumok értékelése (fitness számolás)
 - generációs ciklus:
 - » szülők választása, utódok generálása műveletekkel
 - » utódok értékelése (fitness számítás)
 - » új populáció kiválasztása (különböző stratégiákkal)
 - » megállási feltétel (általában adott számú ismétlés, azaz generáció szám után, vagy adott jóság elérése után)
 - eredmények közzlése

Szelekciós eljárások

- **Fitness arányos szelekció rulettkerék mintavételezéssel:** Ennél az eljárásnál minden egyednek kijelölünk egy szeletet a rulettkerékből úgy, hogy a szelet mérete arányos legyen az egyed fitness értékével. A kereket megpörgetjük, és az az egyed lesz kiválasztva, amelyik felett megáll. A gond ezzel az eljárással, hogy ha az egyedek fitness értékei között nincs nagy különbség a populáción belül, akkor minden egyed közel azonos eséllyel lehet szülőnek választva.
- **Rang szerinti szelekció:** A sorrend szerinti szelekció, éppúgy, mint a fitness arányos szelekció, a rulettkerék alapján választja ki az egyedeket. Itt a rulettkerék szelete egy egyednek a sorba rendezett populációban betöltött helye szerint határozódik meg. Így a leggyengébb egyed kap egy egységnyit, míg a legjobb n egységnyit, ahol n a populáció nagysága.
- **Verseny szelekció:** A verseny szelekció hasonló a sorrend szerinti szelekcióhoz a szelekciós nyomást tekintve, de sokkal hatékonyabban számítható. Két egyedet kiválasztunk véletlenszerűen a populációból. Egy véletlen r számot generálunk 0 és 1 között. Ha $r < k$ (ahol k egy paraméter, például 0,75), akkor a jobb egyedet választjuk. Egyébként a gyengébb egyed kerül kiválasztásra.
- **Legjobb szelekció:** Ennél az eljárásnál egyszerűen a populáció legjobb egyedét választjuk.
- **Véletlen szelekció:** Ennél az eljárásnál véletlenszerűen választunk ki egy egyedet.
- **Interaktív szelekció:** Ezt az eljárást az interaktív evolúció érdekében vezették be. Interaktív evolúcióval például grafikai elemeket lehet kifejleszteni, ahol az alkalmas fitness függvényt nem tudjuk megalkotni. Ebben az esetben a program felhasználója tud választani az egyedek közül. Egyéb területek mellett az interaktív szelekciót gyakran alkalmazzák tervezéshez és alakfelismeréshez.

Szelekciós eljárások

- **Szigma scaling:** A szigma scaling (mint a fitness csökkentés) egy másik eljárás a fitness arányos szelekció problémájának megoldására. Itt a rulettkerék szelete az egyed fitness értékének, a populáció átlagának és szórásának függvényében rendelődik az egyedekhez. A módosított fitness értékeket az alábbiak szerint számítjuk ki:

$$f^*(i) = \begin{cases} 1 + \frac{f(i) - F}{2s} & \text{ha } s \neq 0 \\ 1 & \text{ha } s = 0 \end{cases}$$

Ahol $f^*(i)$ az i egyed módosított fitness értéke, $f(i)$ az i egyedhez tartozó eredeti fitness érték, F a populáció átlag fitness értéke és s a populáció fitness értékeinek szórása.

- **Boltzmann szelekció:** A szigma scaling a "szelekciós nyomást" a folyamat alatt egy konstans érték körül tartja. Néha szükségünk lehet rá, hogy a szelekció jobban kihangsúlyozza a magasabb fitness értékű egyedeket. Ezen a felfogáson alapszik a Boltzmann szelekció. Ebben az eljárásban a rulettkerék szelete a következő formulával rendelődik egy i egyedhez:

$$f^*(i) = \frac{\exp(f(i)/T)}{\langle \exp(f(i)/T) \rangle}$$

Ahol $f^*(i)$ az i egyed módosított fitness értéke, $f(i)$ az i egyedhez tartozó eredeti fitness érték, a $\langle \dots \rangle$ az aktuális populáció középértékét jelöli és T egy hőmérséklet, mely egyenletesen csökken a folyamat során. Alacsonyabb T értékek mellett nő a különbség az $f^*(i)$ -ben az alacsony és magas fitness értékek között.