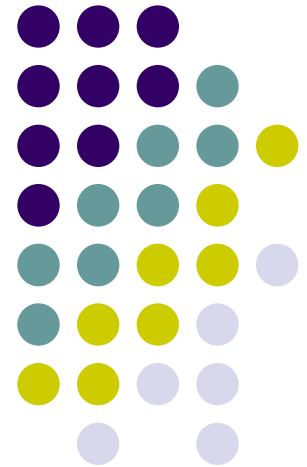


الگوریتم های ژنتیک

Instructor : Saeed Shiry




Mitchell Ch. 9





الگوریتم ژنتیک



- الگوریتم ژنتیک روش یادگیری بر پایه تکامل بیولوژیک است.
- این روش در سال 1970 توسط John Holland معرفی گردید
- این روشها با نام Evolutionary Algorithms نیز خوانده میشوند.

ایده کلی



- یک GA برای حل یک مسئله مجموعه بسیار بزرگی از راه حل‌های ممکن را تولید میکند.
- هر یک از این راه حل‌ها با استفاده از یک "تابع تناسب" مورد ارزیابی قرار میگیرد.
- آنگاه تعدادی از بهترین راه حل‌ها باعث تولید راه حل‌های جدیدی میشوند . که اینکار باعث تکامل راه حل‌ها میگردد.
- بدین ترتیب فضای جستجو در جهتی تکامل پیدا میکند که به راه حل مطلوب برسد
- در صورت انتخاب صحیح پارامترها، این روش میتواند بسیار موثر عمل نماید.



فضای فرضیه

- الگوریتم ژنتیک بجای جستجوی فرضیه های general-to specific یا simple to complex فرضیه های جدید را با تغییر و ترکیب متوالی اجزا بهترین فرضیه های موجود بدست میآورد.
- در هر مرحله مجموعه ای از فرضیه ها که جمعیت (population) نامیده میشوند از طریق جایگزینی بخشی از جمعیت فعلی با فرزندان که از بهترین فرضیه های موجود حاصل شده اند بدست میآید.



ویژگیها

- الگوریتم های ژنتیک در مسائلی که فضای جستجوی بزرگی داشته باشند میتواند بکار گرفته شود.
- همچنین در مسایلی با فضای فرضیه پیچیده که تاثیر اجزا آن در فرضیه کلی ناشناخته باشند میتوان از GA برای جستجو استفاده نمود.
- برای discrete optimization بسیار مورد استفاده قرار میگیرد.
- الگوریتم های ژنتیک را میتوان براحتی بصورت موازی اجرا نمود از اینرو میتوان کامپیوترهای ارزان قیمت تری را بصورت موازی مورد استفاده قرار داد.
- امکان به تله افتادن این الگوریتم در مینیمم محلی کمتر از سایر روشهاست.
- از لحاظ محاسباتی پرهزینه هستند.
- تضمینی برای رسیدن به جواب بهینه وجود ندارد.



Parallelization of Genetic Programming

- در سال 1999 شرکت Genetic Programming Inc. یک کامپیوتر موازی با 1000 گره هر یک شامل کامپیوتر های P2, 350 MHz برای پیاده سازی روش های ژنتیک را مورد استفاده قرار داد.





● کاربرد الگوریتم های ژنتیک بسیار زیاد میباشد

- optimization,
- automatic programming,
- machine learning,
- economics,
- operations research,
- ecology,
- studies of evolution and learning, and
- social systems



زیر شاخه های EA

روش های EA به دو نوع مرتبط به هم ولی مجزا دسته بندی میشوند:

۱. Genetic Algorithms (GAs)

در این روش راه حل یک مسئله بصورت یک bit string نشان داده میشود .

۲. Genetic Programming (GP)

این روش به تولید expression trees که در زبانهای برنامه نویسی مثل lisp مورد استفاده هستند میپردازد بدین ترتیب میتوان برنامه هائی ساخت که قابل اجرا باشند.



الگوریتم های ژنتیک

- روش متداول پیاده سازی الگوریتم ژنتیک بدین ترتیب است که:
- مجموعه ای از فرضیه ها که **population** نامیده میشود تولید و بطور متناوب با فرضیه های جدیدی جایگزین میگردد.
- در هر بار تکرار تمامی فرضیه ها با استفاده از یک تابع تناسب یا **Fitness** مورد ارزیابی قرار داده میشوند. آنگاه تعدادی از بهترین فرضیه ها با استفاده از یک تابع احتمال انتخاب شده و جمعیت جدید را تشکیل میدهند.
- تعدادی از این فرضیه های انتخاب شده به همان صورت مورد استفاده واقع شده و مابقی با استفاده از اپراتورهای ژنتیکی نظیر **Crossover** و **Mutation** برای تولید فرزندان بکار میروند.



پارامترهای GA

یک الگوریتم GA دارای پارامترهای زیر است:

$GA(\text{Fitness}, \text{Fitness_threshold}, p, r, m)$

- **Fitness**: تابعی برای ارزیابی یک فرضیه که مقداری عددی به هر فرضیه نسبت میدهد
- **Fitness_threshold**: مقدار آستانه که شرط پایان را معین میکند
- **p**: تعداد فرضیه هائی که باید در جمعیت در نظر گرفته شوند
- **r**: درصدی از جمعیت که در هر مرحله توسط الگوریتم crossover جایگزین میشوند
- **m**: نرخ mutation



- Initialize: جمعیت را با تعداد p فرضیه بطور تصادفی مقدار دهی اولیه کنید.
- Evaluate: برای هر فرضیه h در p مقدار تابع $Fitness(h)$ را محاسبه نمایید.
- تا زمانی که $[\max_h Fitness(h)] < Fitness_threshold$ یک جمعیت جدید ایجاد کنید.
- فرضیه ای که دارای بیشترین مقدار $Fitness$ است را برگردانید.



نحوه ایجاد جمعیت جدید

مراحل ایجاد یک جمعیت جدید بصورت زیر است:

۱. select: تعداد $(1-r)p$ فرضیه از میان P انتخاب و به P_s اضافه کنید. احتمال انتخاب یک فرضیه h_i از میان P عبارت است از:

$$P(h_i) = \text{Fitness}(h_i) / \sum_j \text{Fitness}(h_j)$$

هر چه تناسب فرضیه ای بیشتر باشد احتمال انتخاب آن بیشتر است. این احتمال همچنین با مقدار تناسب فرضیه های دیگر نسبت عکس دارد.

۲. Crossover: با استفاده از احتمال بدست آمده توسط رابطه فوق، تعداد $(rp)/2$ زوج فرضیه از میان P انتخاب و با استفاده از اپراتور Crossover دو فرزند از آنان ایجاد کنید. فرزندان را به P_s اضافه کنید.

۳. Mutate: تعداد m درصد از اعضا P_s را با احتمال یکنواخت انتخاب و یک بیت از هر یک آنها را بصورت تصادفی معکوس کنید

۴. Update: $P \leftarrow P_s$

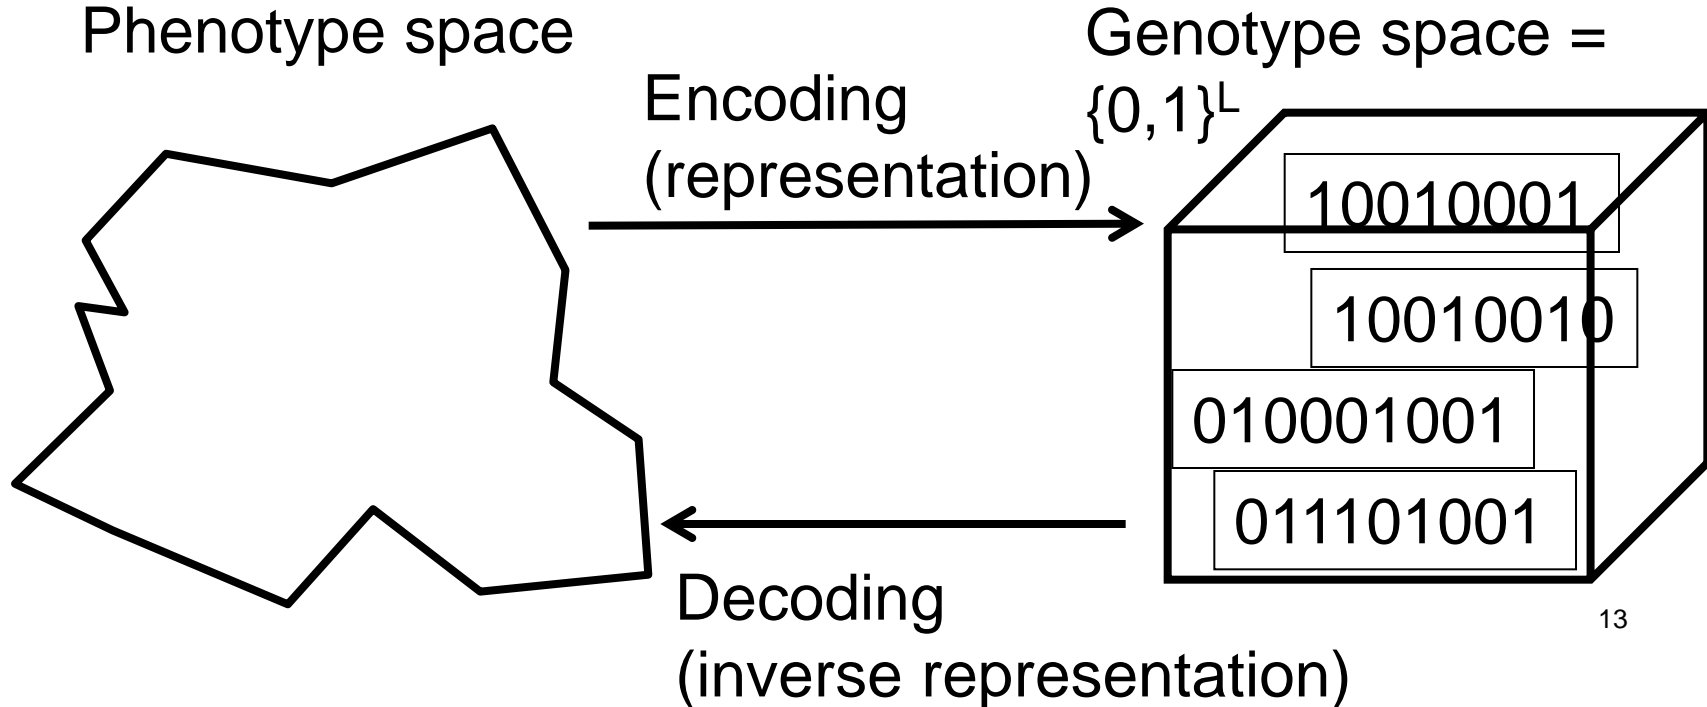
۵. برای هر فرضیه h در P مقدار تابع Fitness را محاسبه کنید



نمایش فرضیه ها

در الگوریتم ژنتیک معمولاً فرضیه ها بصورت رشته ای از بیت ها نشان داده میشوند تا اعمال اپراتورهای ژنتیکی بر روی آنها ساده تر باشد.

- Phenotype: به مقادیر یا راه حل‌های واقعی گفته میشود.
- Genotype: به مقادیر انکد شده یا کروموزم ها گفته میشود که مورد استفاده GA قرار میگیرند.
- باید راهی برای تبدیل این دو نحوه نمایش به یکدیگر بدست آورده شود.





مثال: نمایش قوانین If-then rules

- برای نمایش مقادیر یک ویژگی نظیر Outlook که دارای سه مقدار Sunny, Overcast, Rain است میتوان از رشته ای با طول 3 بیت استفاده نمود

100 -> *Outlook = Sunny*

011-> *Outlook = Overcast ∨ Rain*

برای نمایش ترکیب ویژگی ها رشته بیت های هر یک را پشت سر هم قرار میدهیم:

<i>Outlook</i>	<i>Wind</i>
011	10

به همین ترتیب کل یک قانون if- then را میتوان با پشت سر هم قرار دادن بیت های قسمت های شرط و نتیجه ایجاد نمود:

IF *Wind = Strong* THEN *PlayTennis = No*

<i>Outlook</i>	<i>Wind</i>	<i>PlayTennis</i>
111	10	0

⇒ bit string: 111100



نمایش فرضیه ها :ملاحظات

- ممکن است ترکیب بعضی از بیت ها منجر به فرضیه های بی معنی گردد . برای پرهیز از چنین وضعیتی:
- میتوان از روش انکدینگ دیگری استفاده نمود.
- اپراتورهای ژنتیکی را طوری تعیین نمود که چنین حالت‌هایی را حذف نمایند
- میتوان به این فرضیه ها مقدار fitness خیلی کمی نسبت داد.



اپراتورهای ژنتیکی: Crossover

- اپراتور Crossover با استفاده از دو رشته والد دو رشته فرزند بوجود میآورد .
- برای اینکار قسمتی از بیت‌های والدین در بیت‌های فرزندان کپی میشود .
- انتخاب بیت هائی که باید از هر یک از والدین کپی شوند به روشهای مختلف انجام میشود
- single-point crossover
- Two-point crossover
- Uniform crossover
- برای تعیین محل بیت‌های کپی شونده از یک رشته به نام Crossover Mask استفاده میشود.



Single-point crossover

- یک نقطه تصادفی در طول رشته انتخاب میشود .
- والدین در این نقطه به دو قسمت میشوند .
- هر فرزند با انتخاب تکه اول از یکی از والدین و تکه دوم از والد دیگر بوجود میآید .

Parents

1 1 1 0 1 0 0 1 0 0 0

0 0 0 0 1 0 1 0 1 0 1

Crossover Mask: 11111000000

Children


1 1 1 0 1 0 1 0 1 0 1

0 0 0 0 1 0 0 1 0 0 0




روشهای دیگر Crossover

Two-point crossover ●



Uniform crossover ●





اپراتورهای ژنتیکی : Mutation

- اپراتور mutation برای بوجود آوردن فرزند فقط از یک والد استفاده میکند. اینکار با انجام تغییرات کوچکی در رشته اولیه بوقوع میپیوندد.
- با استفاده از یک توزیع یکنواخت یک بیت بصورت تصادفی انتخاب و مقدار آن تغییر پیدا میکند.
- معمولا mutation بعد از انجام crossover اعمال میشود.

Parent

1	1	1	0	1	0	0	1	0	0	0
---	---	---	---	---	---	---	---	---	---	---

Child

1	1	1	0	1	1	0	1	0	0	0
---	---	---	---	---	---	---	---	---	---	---



Crossover OR mutation?

- این سوال ها سالها مطرح بوده است:
کدامیک بهتر است؟ کدامیک لازم است؟ کدامیک اصلی است؟
- پاسخی که تاکنون بیشتر از بقیه پاسخها مورد قبول بوده:
 - بستگی به صورت مسئله دارد
 - در حالت کلی بهتر است از هر دو استفاده شود
 - هر کدام نقش مخصوص خود را دارد
 - میتوان الگوریتمی داشت که فقط از mutation استفاده کند ولی الگوریتمی که فقط از crossover استفاده کند کار نخواهد کرد



Crossover OR mutation?

- Crossover خاصیت جستجوگرانه و یا explorative دارد. میتواند با انجام پرشهای بزرگ به محل هائی در بین والدین رفته و نواحی جدیدی را کشف نماید.
- Mutation خاصیت گسترشی و یا exploitive دارد. میتواند با انجام تغییرات کوچک تصادفی به نواحی کشف شده وسعت ببخشد.
- Crossover اطلاعات والدین را ترکیب میکند درحالیکه mutation میتواند اطلاعات جدیدی اضافه نماید.
- برای رسیدن به یک پاسخ بهینه یک خوش شانسی در mutation لازم است.


تابع تناسب



- تابع fitness معیاری برای رتبه بندی فرضیه هاست که کمک میکند تا فرضیه های برتر برای نسل بعدی جمعیت انتخاب شوند. نحوه انتخاب این تابع بسته به کاربرد مورد نظر دارد:
- **classification**: در این نوع مسایل تابع تناسب معمولاً برابر است با دقت قانون در دسته بندی مثالهای آموزشی.



انتخاب فرضیه ها



$$\text{fitness}(A) = 3$$

$$\text{fitness}(B) = 1$$

$$\text{fitness}(C) = 2$$

Roulette Wheel selection

در روش معرفی شده در الگوریتم ساده GA احتمال انتخاب یک فرضیه برای استفاده در جمعیت بعدی بستگی به نسبت fitness آن به fitness بقیه اعضا دارد. این روش Roulette Wheel selection نامیده میشود.

$$P(h_i) = \text{Fitness}(h_i) / \sum_j \text{Fitness}(h_j)$$

روشهای دیگر:

tournament selection

rank selection




نحوه جستجو در فضای فرضیه

- روش جستجوی GA با روشهای دیگر مثل شبکه های عصبی تفاوت دارد:
- در شبکه عصبی روش Gradient descent بصورت هموار از فرضیه ای به فرضیه مشابه دیگری حرکت میکند در حالیکه GA ممکن است بصورت ناگهانی فرضیه والد را با فرزندی جایگزین نماید که تفاوت اساسی با والد آن داشته باشد. از اینرو احتمال گیر افتادن GA در مینیمم محلی کاهش می یابد.
- با این وجود GA با مشکل دیگری روبروست که crowding نامیده میشود.



Crowding

- crowding پدیده ای است که در آن عضوی که سازگاری بسیار بیشتری از بقیه افراد جمعیت دارد بطور مرتب تولید نسل کرده و با تولید اعضای مشابه درصد عمده ای از جمعیت را اشغال میکند.
- اینکار باعث کاهش پراکندگی جمعیت شده و سرعت GA را کم میکند.





راه حل رفع مشکل Crowding

- استفاده از ranking برای انتخاب نمونه ها: با اختصاص رتبه به فرضیه ای که بسیار بهتر از بقیه عمل میکند مقدار این برتری نشان داده نخواهد شد.
- Fitness sharing : مقدار Fitness یک عضو در صورتیکه اعضا مشابهی در جمعیت وجود داشته باشند کاهش می یابد.



چرا GA کار میکند؟

- سئوآلی که ممکن است برای تازه واردین به روشهای ژنتیکی ایجاد شود این است که آیا این روش واقعا میتواند کار مفیدی انجام دهد؟



ارزیابی جمعیت و قضیه Schema

- آیا میتوان تکامل در جمعیت در طی زمان را بصورت ریاضی مدل نمود؟
- قضیه Schema میتواند مشخصه پدیده تکامل در GA را بیان نماید.
- یک Schema مجموعه ای از رشته بیت ها را توصیف میکند. یک Schema هر رشته ای از 0 و 1 و * است. مثل 0^*10 که * حالت dont care است.
- یک رشته بیت را میتوان نماینده هر یک از Schema های متفاوتی دانست که با آن تطابق دارند. مثلا 0010 را میتوان نماینده 24 Schema مختلف دانست: 00^* , 0^*10 , $****$ و غیره



قضیه Schema

- قضیه Schema بیان میکند که چگونه یک Schema در طول زمان در جمعیت تکامل پیدا خواهد کرد.
- فرض کنید که در لحظه t تعداد نمونه هائی که نماینده یک Schema مثل s هستند برابر با $m(s,t)$ باشد. این قضیه مقدار مورد انتظار $m(s,t+1)$ را مشخص میکند.
- قبلا دیدیم که احتمال انتخاب یک فرضیه برابر بود با:
$$P(h_i) = \text{Fitness}(h_i) / \sum_j \text{Fitness}(h_j)$$
- این مقدار احتمال را میتوان بصورت زیر نیز نشان داد:
$$P(h_i) = f(h_i) / n f'(t_i)$$



قضیه Schema

- اگر عضوی از این جمعیت انتخاب شود احتمال اینکه این عضو نماینده S باشد برابر است با:

$$p(h \in s) = \sum_{h \in s \cap p_s} \frac{f(h)}{n f(t)} = \frac{u(s,t)}{n f(t)} m(s,t)$$

- که در آن مقدار $u(s,t)$ برابر است با مقدار میانگین fitness اعضای s

$$u(s,t) = \frac{\sum_{h \in s \cap p_s} f(h)}{m(s,t)}$$

- از اینرو مقدار مورد انتظار برای نمونه هائی از s که از n مرحله انتخاب مستقل حاصل خواهند شد برابر است با:

$$E[m(s,t+1)] = \frac{u(s,t)}{f(t)} m(s,t)$$



قضیه Schema

- رابطه فوق به این معناست که تعداد Schema های مورد انتظار در لحظه $t+1$ متناسب با مقدار میانگین $u(s,t)$ بوده و با مقدار fitness سایر اعضا نسبت عکس دارد.
- برای بدست آوردن رابطه فوق فقط اثر مرحله انتخاب نمونه ها در نظر گرفته شده است. با در نظر گرفتن اثر crossover و Mutation به رابطه زیر خواهیم رسید:

$$E[m(s, t+1)] \geq \frac{u(s, t)}{\bar{f}(t)} m(s, t) \left(1 - p_c \frac{d(s)}{l-1}\right) (1 - p_m)^{p(s)}$$

Schema Theorem




- Theorem

$$E[m(s, t+1)] \geq \frac{\hat{u}(s, t)}{\bar{f}(t)} \cdot m(s, t) \cdot \left(1 - p_c \frac{d_s}{l-1}\right) \cdot (1 - p_m)^{o(s)}$$

- $m(s, t)$ \equiv number of instances of schema s in population at time t
- $\bar{f}(t)$ \equiv average fitness of population at time t
- $\hat{u}(s, t)$ \equiv average fitness of instances of schema s at time t
- p_c \equiv probability of single point crossover operator
- p_m \equiv probability of mutation operator
- l \equiv length of individual bit strings
- $o(s)$ \equiv number of defined (non “*”) bits in s
- $d(s)$ \equiv distance between rightmost, leftmost defined bits in s

- Intuitive Meaning

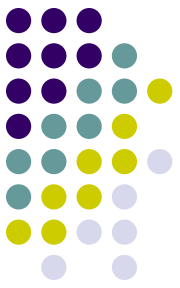
- “The expected number of instances of a schema in the population tends toward its relative fitness”



خلاصه

- یک Schema اطلاعات مفید و امید بخش موجود در جمعیت را کد میکند.
- از آنجائیکه همواره رشته هائی که سازگارترند شانس بیشتری برای انتخاب شدن دارند، بتدریج مثالهای بیشتری به بهترین Schema ها اختصاص می یابند.
- عمل crossover باعث قطع رشته ها در نقاط تصادفی میشود. با این وجود در صورتیکه اینکار باعث قطع Schema نشده باشد آنرا تغییر نخواهد داد. در حالت کلی Schema های با طول کوتاه کمتر تغییر میکنند.
- عمل mutaion در حالت کلی باعث تغییرات موثر در Schema نمیگردد.

Highly-fit, short-defining-length schema (called *building blocks*) are propagated generation to generation by giving exponentially increasing samples to the observed best




تفاوت GA با سایر روشهای جستجو

- GA بجای کد کردن پارامترها مجموعه آنها را کد میکند
- GA بجای جستجو برای یک نقطه بدنبال جمعیتی از نقاط میگردد.
- GA بجای استفاده از مشتق و یا سایر اطلاعات کمکی مستقیماً از اطلاعات موجود در نتیجه بهره میگیرد.
- GA بجای قوانین قطعی از قوانین احتمال برای تغییر استفاده میکند.

مثالی از کاربرد الگوریتم ژنتیک

بهینه‌سازی چینش حروف فارسی بر روی
صفحه کلید با استفاده از الگوریتم‌های ژنتیکی





مقدمه

- بدست آوردن چینش بهینه حروف فارسی بر روی صفحه‌کلید در از مدت برای کسانی که با تایپ کردن متون فارسی درگیر هستند، بسیار مفید خواهد بود.
- یک الگوریتم تکاملی می‌تواند با توجه به یک تابع تناسب که میزان راحتی تایپ کردن متون فارسی را برای یک چینش ارائه می‌دهد، در فضای چینش‌های حروف فارسی بر روی صفحه‌کلید جستجو کرده و چینش بهینه را بدست آورد.

چینش کنونی حروف فارسی بر روی صفحه‌کلید





مساله

- در این مساله هندسه صفحه کلید ثابت است و ما می خواهیم که تعداد ۳۳ نشانه که متشکل از ۳۲ حرف الفبای فارسی بعلاوه حرف همزه "ء" است را بر روی سه ردیف صفحه کلید که به ترتیب دارای ۱۲, ۱۱, و ۱۰ کلید هستند, قرار دهیم.
- هدف این مساله بدست آوردن چینشی از این نشانه ها بر روی این کلیدها است, به طوری که این چینش طوری باشد که کاربر هنگام استفاده از صفحه کلید برای تایپ حروف فارسی, احساس راحتی بیشتری نسبت به کار با بقیه چینش ها داشته باشد.



الگوریتم ژنتیک

- برای حل مساله از یک الگوریتم ژنتیک استفاده شده است.
- تابع تناسب موجود در این الگوریتم ژنتیک, میزان راحتی یا سختی استفاده از یک چینش را محاسبه می‌کند.
- در هر نسل, عملگرهای ژنتیکی بر روی جمعیت موجود که چینش‌های مختلفی از حروف فارسی بر روی صفحه‌کلید هستند, اعمال می‌شوند و جامعه به سمتی سوق داده می‌شود که مقدار تابع تناسب به ازای اعضای آن به کمینه مقدار خود برسند.
- میزان تناسب هر عضو از جامعه که در واقع یک چینش حروف فارسی بر روی صفحه‌کلید هستند, با اعمال تابع تناسب بر متنی که از مطالب چند سایت خبری فارسی زبان تهیه شده است, به دست می‌آید.



جمعیت

- اعضای جمعیت جایگشت‌های مختلف حروف فارسی روی صفحه‌کلید هستند. هر عضو جمعیت را می‌توان به صورت برداری از حروف فارسی در نظر گرفت که هر اندیس آن متناظر با یک کلید از صفحه‌کلید است.
- مثلاً هر بردار با طول ۳۳ که شامل حروف فارسی به‌علاوه حرف همزه "ء" باشد را می‌توان به عنوان یک کروموزوم (یک عضو از جمعیت) در نظر گرفت که حرف i ام از این بردار، متناظر با کلیدی از صفحه‌کلید است که برچسب شماره i بر روی آن زده شده است.

1	2	3	4	5	6	...	33
ض	ص	ث	ق	ف	غ	...	ب



تعداد چینش‌های مختلف ۳۳!

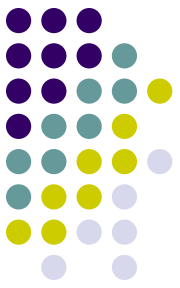


تابع تناسب

● تعیین راحتی و سختی کار کردن با چینش حروف بر روی صفحه کلید یک مساله پیچیده ارگونومیک است.

● نورمن و رومل هارت چهار هدف را برای طراحی کارای یک صفحه کلید ارائه کرده اند:

۱. برابری کاری که دو دست انجام می دهند؛
۲. بیشترین تایپ حروف به صورت متناوب با دو دست؛
۳. کمترین تکرار تایپ دو حرف متوالی با یک انگشت؛ و
۴. بیشترین تایپ حروف بر روی کلیدهای پایه ای (کلیدهای ردیف وسط).



تابع تناسب

- برای دو هدف اول می توان فاکتور اندازه گیری زیر را معرفی کرد:
- C_{hand} : هزینه مربوط به استفاده از یک دست برای تایپ کردن دو حرف پشت سر هم.
- برای هدف سوم, فاکتور اندازه گیری زیر معرفی می شود:
- C_{finger} : هزینه مربوط به استفاده از یک انگشت برای تایپ کردن دو حرف پشت سر هم.
- $C_{ergonomic}$: هزینه مربوط به تایپ کردن یک حرف با توجه به موقعیت آن حرف بر روی صفحه کلید.





تابع تناسب

- تابع تناسب برای هر کروموزوم از مجموع این سه فاکتور برای تمامی حروفی که در متن مورد استفاده برای آزمایش وجود دارند، بدست می‌آید:

$$\text{Fitness (layout)} = \sum_{w_i \in W} \sum_{l_j \in w_i} [C_{\text{hand}}(l_j, l_{j-1}) + C_{\text{finger}}(l_j, l_{j-1}) + C_{\text{ergonomic}}(l_j)]$$

W مجموعه تمامی کلمات موجود در متن مورد استفاده برای آزمایش است؛

- w_i کلمه i ام از مجموعه W است؛
- l_j حرف j ام از کلمه w_i است؛



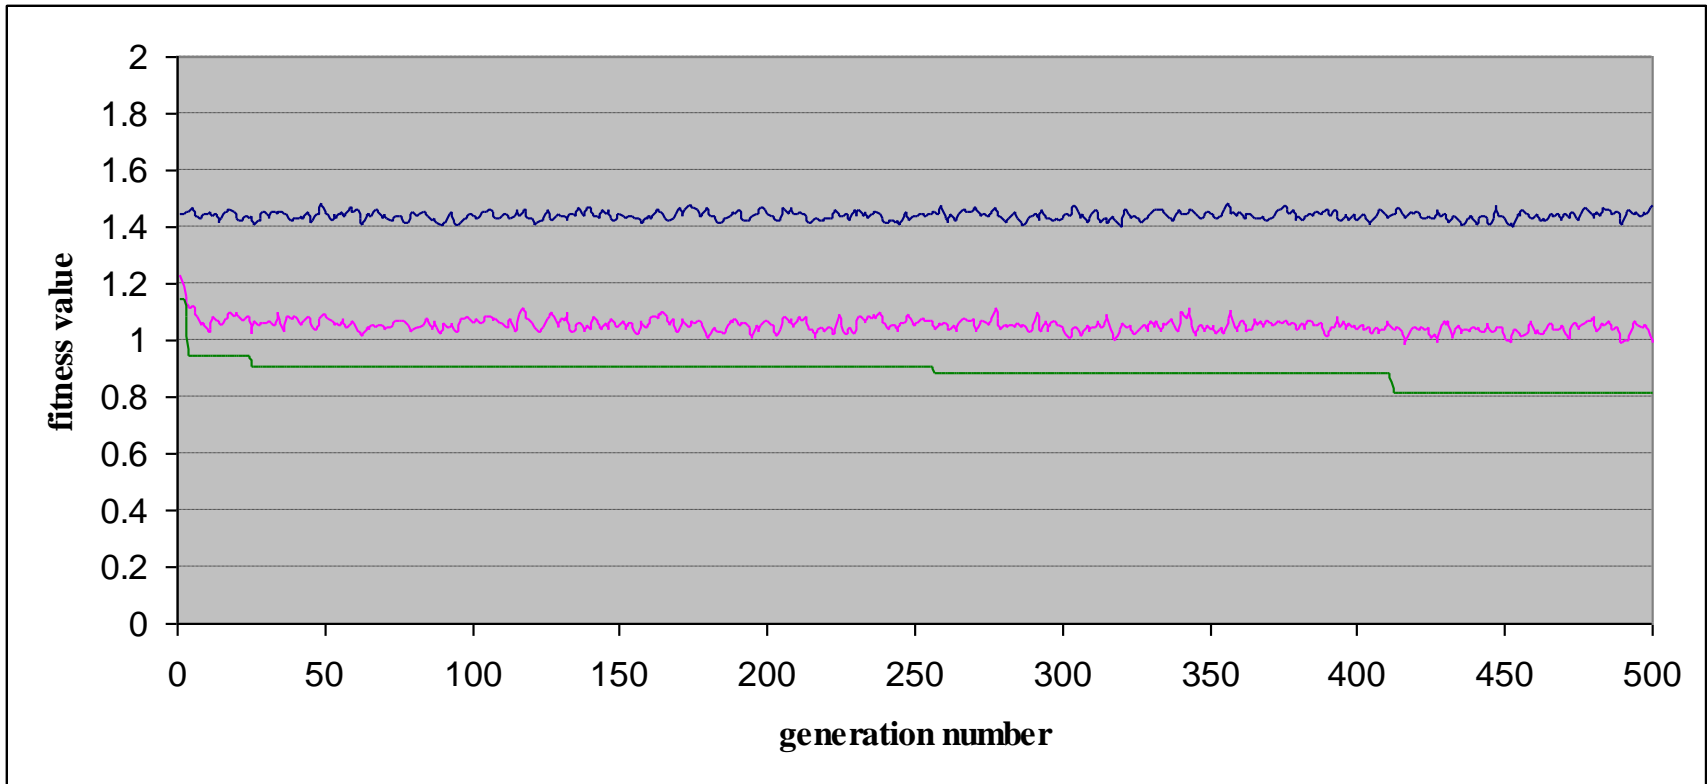
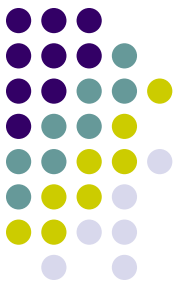
عملگرهای ژنتیکی

- در اینجا تنها از عملگر جهش استفاده شده است.
- دلیل عدم استفاده از عملگر دورگه این است که ساختار اعضای جمعیت طوری است که ترکیب کردن دو کروموزوم والد هزینه زمانی بالایی دارد.
- عملگر جهش را به دو صورت برای اعضای مختلف جامعه به کار می‌بریم. در این مساله یک جامعه نخبگان انتخاب می‌کنیم که اعضای آن $\alpha\%$ تراز اول جمعیت از دید تابع تناسب را تشکیل می‌دهند.
- عملگر جهش برای هر عضو از جامعه نخبگان، تنها محتویات چهار زوج ژن را به صورت تصادفی جابه‌جا می‌کند. در حالیکه برای افراد عادی جامعه این تعداد به ۱۲ جابه‌جایی افزایش می‌یابد.



کارایی

- الگوریتم ژنتیک با پارامترهای زیر اجرا کردیم:
- تعداد اعضای جمعیت ۱۰۰ کروموزوم که در نسل اول به صورت تصادفی تولید شده‌اند؛
- درصد تشکیل‌دهنده جامعه نخبگان است، ۱۰٪ کل جمعیت؛
- تعداد اعضایی که به صورت مستقیم و بدون اینکه عمگرهای ژنتیکی بر روی آن اعمال شود، به نسل بعدی می‌روند، ۳ عضو؛
- و تعداد کل نسل‌ها ۵۰۰ نسل.



نمودارهای تناسب اعضای جامعه در طی نسل‌های مختلف. منحنی‌های نشان داده شده به ترتیب از بالا به پایین، متوسط مقادیر تناسب همه اعضای جامعه، متوسط مقادیر تناسب جامعه نخبگان، و بهترین تناسب هستند.



بهترین چینش

- بهترین چینشی که در نهایت این الگوریتم ژنتیک برای حروف فارسی ارائه داد، هزینه‌اش با توجه به تابع تناسب، ۸۱۵/۰ هزینه چینش کنونی حروف فارسی است.





مدلهای تکامل

- در سیستمهای طبیعی هر موجود زنده در طول زندگی خود یاد میگیرد که با شرایط سازگاری نماید. به همین ترتیب نسل های مختلف یک نمونه در طول زمان سازگاری های مختلفی را کسب میکنند:

- سوال:

رابطه بین یادگیری یک موجود در طول زندگی شخصی و یادگیری نسل های یک نمونه در طول زمان چیست؟



Lamarckian evolution

- Lamarck دانشمند قرن نوزدهم فرضیه ای ارائه کرده که طبق آن تجربیات یک موجود زنده در ترکیب ژنتیکی فرزندان آن تاثیر میگذارد.
 - برای مثال موجودی که یاد گرفته از غذای سمی پرهیز کند این ویژگی را بصورت ژنتیکی به فرزندان خود منتقل مینماید تا آنها دیگر مجبور به یادگیری این پدیده نباشند.
 - اما شواهد تجربی این نظر را تائید نمیکنند :
- یعنی تجربیات فردی هیچ تاثیری در ترکیب ژنتیکی فرزندان ندارد.



Baldwin Effect

نظریه دیگری وجود دارد که تاثیر یادگیری را بر تکامل توضیح میدهد. این نظریه که اثر Baldwin نامیده میشود بر مبنای مشاهدات زیر استوار است:

- اگر موجودی از طرف محیط متغیری تحت فشار قرار گرفته باشد، افرادی که توانایی یادگیری نحوه برخورد با شرایط را داشته باشند شانس بیشتری برای بقا دارند.
- موجوداتی که تحت شرایط جدید باقی میمانند جمعیتی با توانایی یادگیری را تشکیل میدهند که فرایندهای تکاملی در آنها سریعتر رخ میدهد و باعث میشود تا نسلی بوجود بیاید که نیازی به یادگیری مواجهه با شرایط جدید را نداشته باشند.



اجرای موازی الگوریتم های ژنتیک

- الگوریتم های ژنتیک از قابلیت خوبی برای پیاده سازی بصورت موازی برخوردار هستند.
- در یک روش پیاده سازی موازی، جمعیت به گروه های کوچکتری با نام demes تقسیم شده و هر کدام در یک گره محاسباتی مورد پردازش قرار میگیرند .
- در هر گره یک الگوریتم استاندارد GA بر روی deme اجرا میشود .
- انتقال بین گره ها از طریق پدیده migration صورت میپذیرد .



Evolving Neural Networks

از GA برای تکامل جنبه های مختلف NN استفاده زیادی بعمل آمده است. از جمله : وزنها، ساختار و تابع یادگیری.

- استفاده از GA برای یادگیری وزنهاى یک شبکه عصبی میتواند بسیار سریعتر از روش استاندارد back propagation عمل نماید.
- استفاده از GA برای یادگیری ساختار شبکه عصبی مشکلتر میباشد . برای شبکه های کوچک با استفاده از یک ماتریس مشخص میشود که چه نرونی به چه نرونهاى دیگری متصل است. آنگاه این ماتریس به ژن های الگوریتم ژنتیک تبدیل و ترکیبات مختلف آن بررسی میگردد.
- برای بدست آوردن تابع یادگیری یک شبکه عصبی راه حلهائی نظیر استفاده از GP مورد استفاده قرار گرفته اما عموماً این روشها بسیار کند عمل کرده اند.




- [١] D. E. Glover, *Genetic Algorithm and Simulated Annealing*, page 12-31, Morgan Kaufmann, Los Altos, CA, 1987.
- [٢] Lissa W. Light and Peter G. Anderson, "Typewriter keyboards via simulated annealing", *AI Expert*, September 1993.
- [٣] Peter Klausler, www.visi.com/~pmk/evovled.html, September 2005.
- [٤] M. O. Wagner, B Yannou, S. Kehl, D. Feillet, and J. Eggers, Ergonomic Modeling and optimization of keyboard arrangement with an ant colony algorithm", *European Journal of Operation research*, 2003.
- [٥] P. S. Deshwall and K. Deb, Design of an Optimal Hindi Keyboard for Convenient and Efficient Use. Technical Report on KanGAL Report No. 2003005, Indian Institute of Technology, Kanpur, 2003.
- [٦] D. A. Norman and D. E. Rumelhart, *Cognitive Aspects of Skilled Typing*, Springer-Verlag, New York, 1983.
- [٧] J. S. Goetti, A.W. Brugh, and B. A. Julstrom, "Arranging the Keyboard with a Permutaion-Coded Genetic Algorithm", *Proc. of the 2005 SCM Symposium on Applied Computing*, Volume 2, pp. 947-951, 2005.



Genetic Programming

- GP تکنیکی است که کامپیوترها را قادر میسازد تا به حل مسائل بپردازند بدون آنکه بطور صریح برای آن برنامه ریزی شده باشند.
- GP روشی از الگوریتمهای تکاملی است که در آن هر عضو جمعیت یک برنامه کامپیوتری است.
- برنامه ها اغلب بتوسط یک درخت نمایش داده شده و اجرای برنامه برابر است با pars کردن درخت.





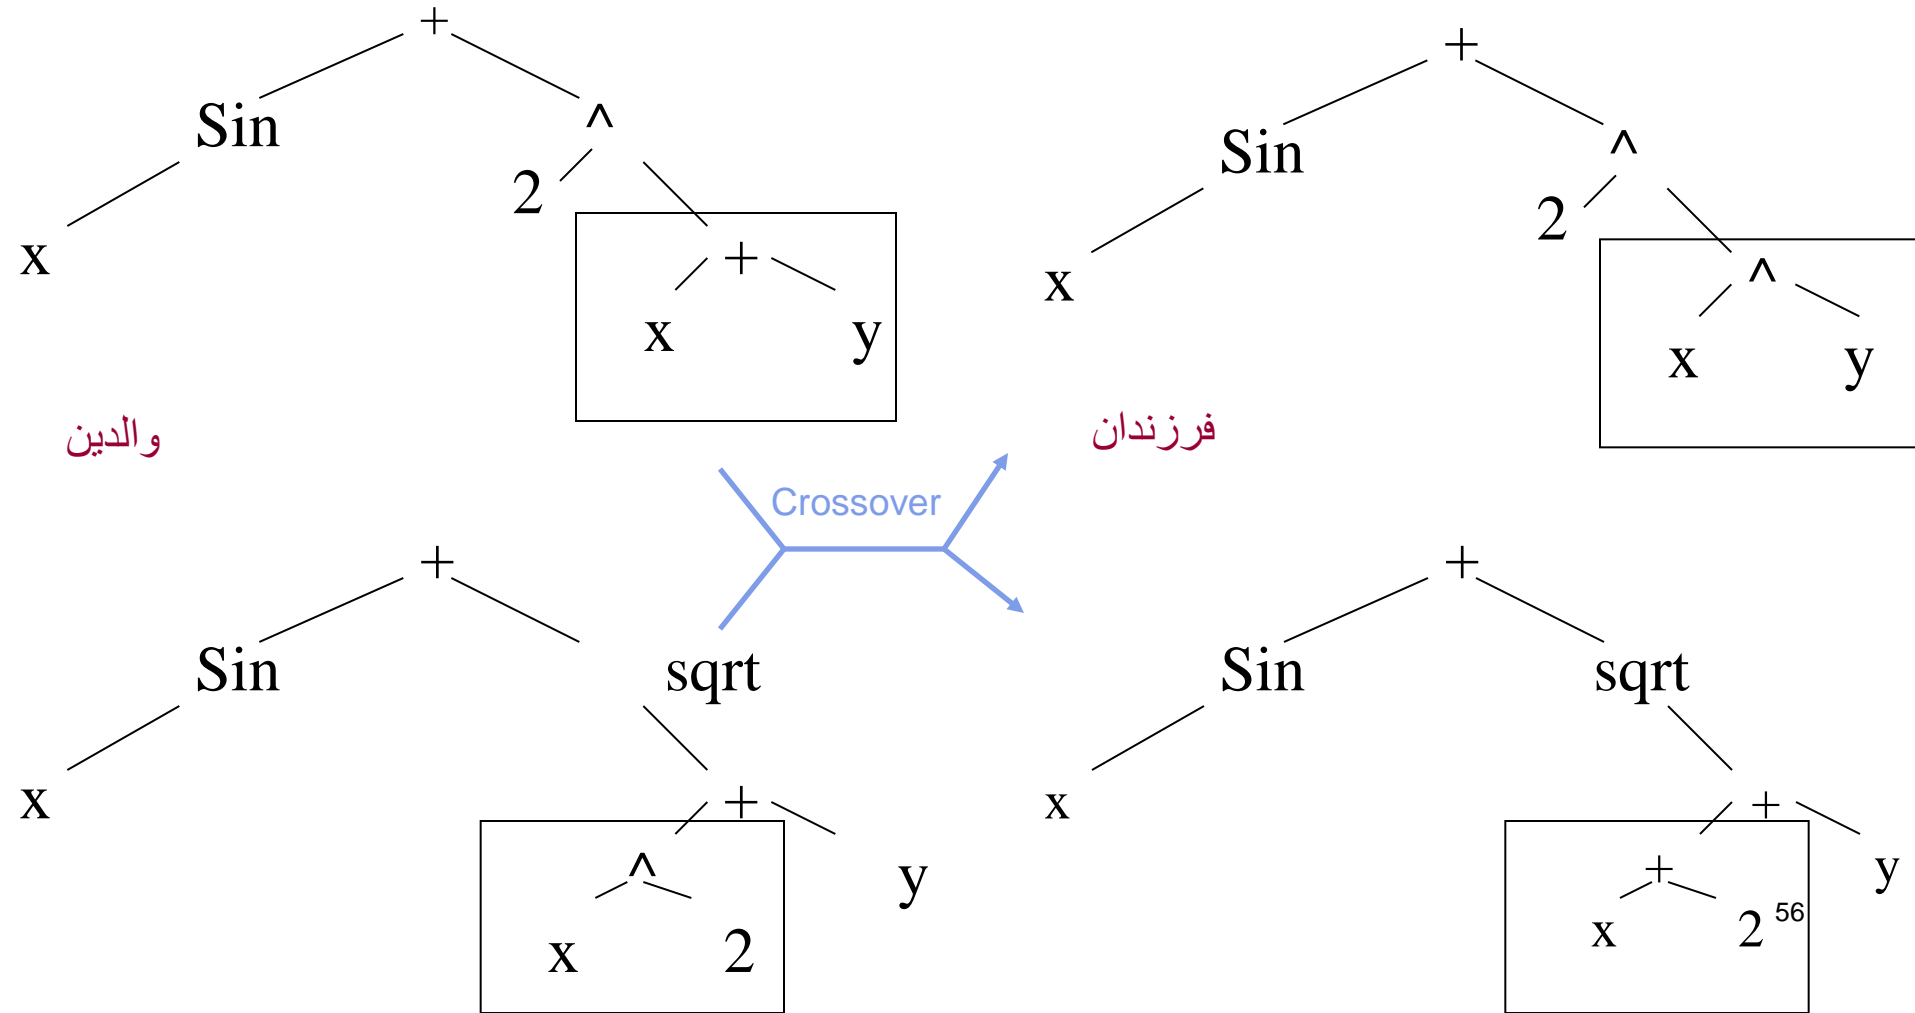
نمایش برنامه ها

- برای استفاده از GP در یک زمینه خاص،
- میبایست توابع پایه ای که در آن زمینه مورد نیاز هستند نظیر \sin , \cos , $\sqrt{\quad}$, $+$, $-$, etc توسط کاربر تعریف شوند
- همچنین ترمینالها نظیر متغیرها و ثوابت نیز باید مشخص شوند
- آنگاه الگوریتم GP در فضای بسیار بزرگ برنامه هائی که توسط این مقادیر اولیه قابل بیان هستند یک عمل جستجوی تکاملی را انجام خواهد داد.

اپراتور crossover برای GP



اپراتور crossover : شاخه هائی از یک درخت والد با شاخه هائی از درخت والد دیگر بطور تصادفی عوض میشوند






مثال

- در کتاب مثالی از Koza مطرح شده که در آن الگوریتمی یاد گرفته میشود که بتواند بلوک ها را در یک ستون روی هم بچیند

- هدف مسئله این است که بلوک ها طوری روی هم چیده شوند که کلمه universal را بسازند





مثال

- محدودیت: در هر مرحله فقط میتوان یک بلوک را جابجا نمود. در نتیجه تنها حرکت های ممکن عبارتند از:
 - بلوک آخر ستون را میتوان روی میز قرار داد و یا اینکه
 - یک بلوک را از میز به انتهای ستون منتقل نمود.
- توابع اولیه:
 - CS (current stack): نام بلوک موجود در انتهای ستون را بر میگردداند (F برای حالتی که بلوکی وجود ندارد)
 - TP (top correct block): نام آخرین بلوکی را که همراه با بلوک های زیرینش ترتیب صحیح مورد نظر را دارند، برمیگرداند
 - NN (next necessary): نام بلوکی که باید در بالای TP قرار گیرد تا ترتیب universal درست دربیاید.



مثال

سایر توابع اولیه:

● **(MS x) move block x to stack** اگر بلوک x روی میز باشد این اپراتور آنرا به بالای ستون منتقل میکند. در غیر اینصورت مقدار F برمیگرداند.

● **(MT x) move block x to table** اگر بلوک x جایی روی ستون باشد این اپراتور بلوک بالای ستون را به میز منتقل میکند. در غیر اینصورت مقدار F برمیگرداند.

● **(EQ x y)** returns true if $x = y$.

● **(NOT x)** returns the complement of x .

● **DU(x y)** do x until expression y is true



مثال

مقدار تابع fitness

- در این آزمایش تعداد 166 مثال که هر یک در برگیرنده آرایش اولیه متفاوتی برای بلوک ها بودند تدارک دیده شده بود.
 - تابع fitness یک برنامه برابر است با تعداد مثالهایی که برنامه قادر به حل آن است.
 - برنامه با جمعیت اولیه ای برابر با 300 برنامه تصادفی شروع بکار نموده و پس از تولید 10 نسل قادر میشود تا برنامه ای پیدا نماید که تمامی 166 مثال را حل نماید:
- (EQ (DU (MT CS)(NOT CS)) (DU (MS NN)(NOT NN)))



مثال : طراحی فیلتر

صورت مسئله : برنامه ای که یک مدار ساده اولیه را به مدار پیچیده مورد نیاز تبدیل نماید.

- توابع اولیه:

- تابعی برای اضافه کردن قطعات و سیم بندی های مدار
- تابعی برای حذف کردن قطعات و سیم بندی های مدار

- تابع fitness شبیه سازی مدار بدست آمده توسط نرم افزار SPICE برای مشخص نمودن میزان تطبیق آن با طرح مورد نظر. خطای مدار برای 101 فرکانس مختلف مورد بررسی قرار میگرفت.

- جمعیت اولیه : 640000

- نرخ crossover : 89 درصد

- نرخ mutation : 1 درصد



مثال : طراحی فیلتر

- سیستم بر روی یک کامپیوتر موازی با 64 گره مورد آزمایش قرار گرفت.
- برای نسل اولیه ای که بصورت تصادفی ایجاد شدند در 98% مواقع حتی امکان شبیه سازی وجود نداشت.
- این نرخ بتدریج کاهش یافته و پس از تولید 137 نسل مداری حاصل شد که با مشخصات مورد نظر صدق میکرد.

در اغلب موارد کارائی الگوریتم GP بستگی به نحوه نمایش و همچنین تابع fitness دارد.