



به نام خدا

و بگو :

پروردگارا مرا [در هر کاری] با درستی و راستی داخل کن
و با درستی و راستی خارج ساز
و از سوی خود تسلّتی یاری بخش قرار ده.

اسراء ۸۰



کاربرد تکنیک های محاسبات تکاملی در برنامه ریزی توسعه تولید

**Application of Evolutionary Computation Techniques
for Generation Expansion Planning**

مروری بر انواع روش‌های بهینه‌سازی

- هدف از طراحی بهینه

Minimize or Maximize : $f(x)$

در سیستم‌های قدرت سنتی تابع هدف بصورت تابع هزینه معرفی می‌شود که بایستی مینیمم شود در حالیکه در سیستم‌های قدرت تجدید ساختار یافته معمولاً به صورت تابع سود بازیگران بازار برق تعریف می‌شود که بایستی ماکزیمم گردد.

جواب بهینه مسئله : x_0

$$\text{برای مینیمم سازی} \quad f(x_0) \leq f(x)$$

$$\text{برای ماکزیمم سازی} \quad f(x) \leq f(x_0)$$

فرمول بندی مسئله GEP

• تابع هدف

$$\text{Min } C_j = \sum_{t=1}^T [I_{j,t} - S_{j,t} + M_{j,t} + O_{j,t}]$$

- Capital investment costs (I)
- Salvage value of investment costs (S)
- Maintenance costs (M)
- Cost of the energy not served (O)

• قیود

$$[K_t] = [K_{t-1}] + [A_t] - [R_t] + [U_t]$$

- $[K_t]$: Vector of committed additions of units in year t
- $[A_t]$: Vector of committed retirements of units in year t
- $[R_t]$: Vector of candidate generating units added to the system in year t
- $[U_t]$: the system configuration vector


$$0 \leq [U_t] \leq [U_{t,\max}]$$

$$R_{\min} \leq [K_{t,a}] \leq R_{\max}$$

$$FM_{\min} \leq [K_{t,a}] \leq FM_{\max}$$

$$LOLP(K_{t,a}) \leq \varepsilon$$

مروری بر انواع روش‌های بهینه‌سازی بر اساس جستجو



تاریخچه GA



- پیش زمینه بیولوژیکی ژن ها و کروموزوم ها :

✓ ایده اصلی الگوریتم های تکاملی (مانند ES و EP) توسط *Rechenberg* در سال ۱۹۶۰ مطرح گردید.


✓ **GA** منشعب از این نوع الگوریتم ها می باشد.

✓ **GA** روش جستجوی کامپیوتری بر پایه الگوریتم های بهینه سازی و بر اساس ساختار ژن ها و کروموزوم ها است که توسط پروفسور *John Holland* در دانشگاه میشیگان مطرح شد.

✓ مهمترین تفاوت های **GA** با سایر الگوریتم های بهینه سازی:


(۱) کد گذاری متغیرهای مسئله (**Encoding**)

(۲) اجرای عملیات بهینه سازی بر روی مجموعه ای از نقاط (**Population**)




فضای جستجو (Search Space)

Charles Darwin 1809 – 1882



- تعریف:

- فضای همه حالت های ممکن در حل یک مسئله را فضای جستجو می نامند.
- ✓ جستجو برای جواب یعنی بررسی برای پیدا نمودن اکسترمم (Min یا Max) در فضای جستجو.
- ✓ پیچیده و بزرگ بودن فضای جستجو و اینکه باید حل مسئله را از چه نقطه ای آغاز نمود ما را به استفاده از **GA** سوق می دهد.
- **GA** با الهام از تئوری ادامه حیات بهترین ها (**Survival of the fittest**) و تکثیر نوع برتر *Darwin* شکل گرفته است.



مدل سازی مسئله در GA

✓ به منظور مدل سازی مسئله بهینه سازی به صورت الگوریتم ژنتیک بایستی متغیرهای تابع هدف و قیود مسئله بر اساس مفاهیم GA کدگذاری شوند.

Min $f(\mathbf{x})$

s. t.

$$\mathbf{X}_i^{(L)} \leq \mathbf{X}_i \leq \mathbf{X}_i^{(U)} \quad i = 1, 2, \dots, N$$

Max $f(\mathbf{x}) \equiv \text{Min} \{-f(\mathbf{x})\}$

Value Encoding ○

انواع روش های نمایش ژن ها :

String (۱)

Array (۲)

Tree (۳)

List (۴)

گذاری متغیرها در GA

(1) String :

1.1 Binary Coding

Chromosome A = 1 0 1 0 0 1 1 1

1.2 Permutation Encoding


Chromosome B = 5 3 2 ... n

1.3 Value Encoding

Chromosome C = 1.23 4.75 0.46

1.4 Tree Encoding

Chromosome D = $x / (5.y)$



تولید مثل (Reproduction)

- انواع روش های انتخاب (Selection)

Roulette Wheel (۱)

Tournament (۲)


Ranking (۳)

Roulette Wheel

No.	Population	F (fitness)	Probability	Mating Pool
1	0000 0000	1.5	0.15	0001 0101
2	0010 0001	2.6	0.26	0001 0101
3	0001 0101	5.4	0.54	0010 0001
4	1000 0011	0.5	0.05	0000 0000

$$\sum_{k=1}^N F_k = 10$$

$$P_i = \frac{F_i}{\sum_{k=1}^N F_k}$$



Tournament


No.	1	2	3	4
Fitness	1.5	2.6	5.4	0.5

انتخاب تصادفی	برنده	Mating Pool
(1,3)	3	0001 0101
(2,3)	3	0001 0101
(3,4)	3	0001 0101
(2,4)	2	0010 0001

Ranking

No.	Population	F (<i>fitness</i>)	رتبه بندی	احتمال	Mating Pool
1	0000 0000	1.5	(2)	2/10	0001 0101
2	0010 0001	2.6	(3)	3/10	0001 0101
3	0001 0101	5.4	(4)	4/10	0010 0001
4	1000 0011	0.5	(1)	1/10	0000 0000

$$\sum Rank = 10$$



دو رگه سازی (Crossover)

- عمل تولید مثل (Reproduction) یا انتخاب (Selection) در حقیقت فقط مجموعه‌ای از بهترین رشته‌ها (کروموزوم‌ها یا جواب‌های مسئله) را انتخاب می‌کند و هیچگونه رشته جدیدی را بوجود نمی‌آورد.
- به همین دلیل عملگر Crossover در مرحله بعد با هدف تولید رشته‌های بهتر بر روی Mating Pool اعمال می‌شود.
- مراحل اجرای Crossover :
 - (۱) انتخاب دو رشته تصادفی از Mating Pool
 - (۲) انتخاب تصادفی بخشی از طول هر رشته
 - (۳) جابجا نمودن مقدار دو رشته در بخش‌های منتخب مرحله قبل برای هر رشته

انواع روش های اعمال Crossover

1. Single Point
2. Two Point
3. Multi Point
4. Uniform (Binary Window)
5. Matrix

انواع روش های اعمال Crossover

1. Single Point
2. Two Point
3. Multi Point
4. Uniform (Binary Window)
5. Matrix

Parent 1	1	0	0	1	0	1	1
Parent 2	0	0	1	0	1	1	0

Child 1	1	0	0	1	1	1	0
Child 2	0	0	1	0	0	1	1

Crossover روش های اعمال

1. Single Point
2. Two Point
3. Multi Point
4. Uniform (Binary Window)
5. Matrix

Parent 1	1	0	0	1	0	1	1
Parent 2	0	0	1	0	1	1	0

Child 1	1	0	1	0	1	1	1
Child 2	0	0	0	1	0	1	0

انواع روش های اعمال Crossover

1. Single Point
2. Two Point
3. **Multi Point**
4. Uniform (Binary Window)
5. Matrix

Parent 1	1	0	0	1	0	1	1
Parent 2	0	0	1	0	1	1	0

Child 1	1	0	1	0	0	1	0
Child 2	0	0	0	1	1	1	1


انواع روش های اعمال Crossover

1. Single Point
2. Two Point
3. Multi Point
4. Uniform (Binary Window)
5. Matrix

Mask	1	0	1	1	0	1	0
Parent 1	1	0	0	1	0	1	1
Child 1	1	0	0	1	1	1	0
Parent 2	0	0	1	0	1	1	0
Child 2	0	0	1	0	0	1	1

انواع روش های اعمال Crossover

1. Single Point
2. Two Point
3. Multi Point
4. Uniform (Binary Window)
5. **Matrix**



(Crossover Rate) P_c

- P_c احتمالی است که از نسبت تعداد کروموزومهای جدید (فرزندان) به جمعیت اعضای **Mating Pool** (N_p) بدست می آید ($0 \leq P_c \leq 1$).
- به عبارت دیگر $100 \times P_c$ درصد از رشته ها (والدین یا کروموزوم های قدیمی) در عملیات Crossover شرکت کرده اند و $100 \times (1 - P_c)$ درصد از جمعیت (N_p) باقی مانده است.
- هر چه مقدار P_c بیشتر باشد بدین معنی است که تعداد کروموزوم های جدید و زیادتری وارد **Mating Pool** شده اند.
- اگر مقدار P_c خیلی زیاد باشد باعث می شود تا فرصت تطابق در کروموزوم ها از دست برود و در واقع از جواب اولیه فاصله زیادی بگیریم و اگر مقدار P_c خیلی کم باشد مسلماً تعداد فرزندان تولید شده برای دسترسی به نسل بهتر کم خواهد بود.
- P_c برای جمعیت هایی با اندازه ۳۰ تا ۲۰۰ مورد در محدوده ۰/۵ تا ۱ خواهد بود.

جهش (Mutation)

- این عملگر به منظور جلوگیری از همگرایی سریع و کمک به الگوریتم جستجو برای فرار از به دام افتادن در Minimum های محلی تابع هدف استفاده می شود.
- این فرآیند همچنین برای حفظ متفاوت و متمایز بودن کروموزوم ها در یک جمعیت به کار می رود مثلاً :

0110

0011

0001

0111 $\xrightarrow{\text{Mutation}}$ 1111

- انواع عملگرهای جهش:

- 1's Complement
- Logic Operators (AND , OR , XOR)
- Shift Operators (Right (>>) , Left (<<))

(Mutation Rate) Pm

- **Pm** بیانگر احتمال جهش است که بر اساس تعداد بیت های جهش یافته محاسبه می شود.
- **Pm** مقدار کوچکی دارد که برای یک جمعیت با اندازه ۳۰ تا ۲۰۰ مورد، مقداری بین ۰/۰۰۱ تا ۰/۵ خواهد داشت.
- مراحل جهش :

(۱) عددی تصادفی بین ۰ تا ۱ انتخاب می شود ($Z: \text{random}, 0 \leq Z \leq 1$)


(۲) این عدد با مقدار احتمال جهش (**Pm**) مقایسه می شود :

if $Z < Pm$ then 'true' => Toggle

if $Z > Pm$ then 'false' => Freeze

✓ باید توجه داشت که بیت های یک رشته به صورت مستقل جهش می یابند و اثری بر یکدیگر ندارند.

چرخه GA



استراتژی تکاملی (Evolutionary Strategy)

Initialization (1)

جمعیت اولیه متغیرهای تصمیم گیری (N_p) بصورت تصادفی از یک مجموعه با توزیع یکنواخت تعیین می شود.

Fitness evaluation (2)

تعیین مقادیر f_{max} , f_{min} , f_{avg} , f_{sum} برای جمعیت مورد نظر.

Mutation (3)

$$Off_{i,j} = P_{i,j} + N(0, \beta \nabla)$$

Competition and Selection (4)

چون جهش روی تمامی خانواده ها اعمال می شود لذا تعداد کل اعضای حوضچه رقابت برابر $2N_p$ خواهد شد لذا در این مرحله این تعداد براساس تابع *Fitness*، خود به صورت نزولی مرتب شده و از میان آنها تعداد N_p عضو برای نسل بعد برگزیده می شوند.

Convergence (5)

$$\frac{f_{avg}}{f_{max}} \leq \Phi$$

مقدار Φ باید بسیار نزدیک به عدد یک باشد.

برنامه ریزی تکاملی (Evolutionary Programming)

Initialization (1)

مشابه ES

Fitness evaluation (2)

مشابه ES

Mutation (3)

$$Off_{i,j} = P_{i,j} + N(0, \sigma)$$

$$\sigma = \beta \times \frac{f_i}{f_{min}} \times (X_{max,j} - X_{min,j})$$

Competition and Selection (4)

چون جهش روی تمامی خانواده‌ها اعمال می‌شود لذا تعداد کل اعضای حوضچه رقابت برابر $2Np$ خواهد شد لذا m عضو از بهترین‌های آن برای شرکت در نسل بعد برگزیده شده و تعداد $2Np-m$ عضو باقی مانده وارد فرایند انتخاب براساس رقابت می‌شوند تا از میان آنها نیز k عضو برتر ($k=Np-m$) برای ورود به نسل بعد معرفی شوند.

Convergence (5)

مشابه ES

$$W_i = \sum_{t=1}^N w_{i,t}$$

$$F_{i,t} = U - \frac{f_r}{f_r + f_i} \quad w_{i,t} = \begin{cases} 1 & \text{if } F_{i,t} < 0 \\ 0 & \text{o.w.} \end{cases}$$

بهبود روش های تکاملی (ES, EP, GA)

1. Domain Mapping Procedure
2. Penalty Function Approach
3. Random Mutation

بهبود روش های تکاملی (ES, EP, GA)

1. Domain Mapping Procedure

2. Penalty Function Approach

3. Random Mutation

✓ در این روش چندین متغیر مسئله به یک متغیر ساختگی و منفرد نگاشت می شوند تا سرعت پردازش و کارایی الگوریتم افزایش یابد.

✓ مثال: فرض کنید سیستم قدرتی دارای $2 \times 1000 \text{ MW}$ و $2 \times 700 \text{ MW}$ باشد بنابراین

X1 (1000 MW)	X2 (700 MW)	MW کل	Y1 (متغیر ساختگی)
0	0	0	0
0	1	700	1
1	0	1000	2
0	2	1400	3
1	1	1700	4
2	0	2000	5
1	2	2400	6
2	1	2700	7
	2	3400	8

بهبود روش های تکاملی (ES, EP, GA)

1. Domain Mapping Procedure

2. Penalty Function Approach

3. Random Mutation

✓ این روش در واقع به اصلاح **Fitness Function** می پردازد بدین صورت که برای هر کروموزوم موجود در جمعیت یکبار مقدار تابع هدف را محاسبه و تمامی قیود مسئله را بررسی می نماید (قیود این مسئله عبارتند از **fuel mix rate** ، **reserve rate** و **LOLP**). چنانچه قیدی نقض شده باشد ضریب جریمه ای متناسب به مقدار تابع هدف مسئله افزوده می شود.

✓ **Fitness Function** اصلاح شده توسط روش فوق :

$$f_j = [C_j + \alpha_1 \cdot \psi_1 + \alpha_2 \cdot \psi_2 + \alpha_3 \cdot \psi_3]$$

f_j : the fitness function value of j th individual

C_j : the objective function value of j th individual

α_1 : the penalty factor of reserve margin constraint

Ψ_1 : the amount of reserve margin constraint violation

α_2 : the penalty factor for fuel mix ratio constraint

Ψ_2 : the amount of fuel mix ratio constraint violation

α_3 : the penalty factor for LOLP constraint

Ψ_3 : the amount of LOLP constraint violation

بهبود روش های تکاملی (ES, EP, GA)

1. Domain Mapping Procedure

2. Penalty Function Approach

3. Random Mutation

✓ همانطور که گفته شد جهش به منظور تغییر ژن یک کروموزوم یا تمامی کروموزوم های موجود در یک جمعیت استفاده می شود.

✓ در IES و IEP جهش بر روی تمامی کروموزوم ها صورت می گیرد که در روابط تعریف شده برای آنها مقدار β را عددی تصادفی بین ۰/۰۵ تا ۰/۱ انتخاب می نمایند اما در IGA عمل جهش بر روی تمامی کروموزوم ها اعمال نمی شود بلکه فقط بر روی کروموزوم های خاصی که بصورت تصادفی تعیین شده اند (Pm) و آنهم فقط بر روی برخی از ژن های منتخب این کروموزوم ها اعمال می گردد.

❑ IGA=Improved Genetic Algorithm

❑ IEP=Improved Evolutionary Programming

❑ IES=Improved Evolutionary Strategy

Test Results

- روش های IES، IEP و IGA بر روی یک شبکه نمونه به منظور بهینه سازی مسئله GEP مورد نظر و برای سه افق برنامه ریزی ۴، ۶ و ۱۴ ساله پیاده سازی شد و با توجه به فرضیات مسئله، نتایج زیر بدست آمد.

• فرضیات مسئله :

(۱) بار پیش بینی شده

Stage	0	1	2	3	4	5	6	7
سال	2002	2004	2006	2008	2010	2012	2014	2016
پیک بار (MW)	5000	7000	9000	10000	12000	13000	14000	15000

(۲) حدود رزرو: بین ۲۰٪ تا ۴۰٪

(۳) هزینه انرژی تأمین نشده (LOEE): \$/KWh ۰/۰۵

(۴) هزینه سرمایه گذاری فرض شده است که از ابتدای سال محاسبه می شود.

(۵) هزینه Salvage در انتهای دوره برنامه ریزی اعمال می شود.

Test Results

- تنظیم پارامترهای مربوط به انواع تکنیک‌های EC :

پارامتر	IES	IEP	IGA
اندازه جمعیت	50	50	50
بیشترین زاد و ولد	200	200	200
طول رشته	8	8	8
احتمال جهش	$\beta=0.05$ to 0.1	$\beta=0.05$ to 0.1	$P_m=0.01$
احتمال دو رگه سازی	-	-	$P_c=0.6$
تعداد نخبه‌ها	-	10 ~ 20 %	2
متد انتخاب	-	انتخاب بر مبنای رقابت	Roulette Wheel
متد دو رگه سازی	-	-	Binary Window
قیود	Reserve margin, Fuel Mix Ratio, LOLP		

Test Results

نتایج بدست آمده برای افق های برنامه ریزی کوتاه و میان مدت

دوره برنامه ریزی ۴ ساله				دوره برنامه ریزی ۶ ساله			
روش حل	زمان اجرا (دقیقه)	هزینه تجمعی ($\times 10^9$)	خطا (%)	زمان اجرا (دقیقه)	هزینه تجمعی ($\times 10^9$)	خطا (%)	
DP	1	5.0058	0	28	7.359	0	
IGA	5	5.0058	0	8	7.539	0	
IES	4.9	5.0058	0	8	7.539	0	
IEP	4.5	5.0058	0	8	7.539	0	

DP = Dynamic Programming

IGA = Improved Genetic Algorithm


IEP = Improved Evolutionary Programming

IES = Improved Evolutionary Strategy

Test Results

نتایج بدست آمده برای افق برنامه ریزی بلند مدت (۱۴ سال)

متد	IES	IEP	IGA
هزینه (\$)	1.4483×10^{10}	1.4555×10^{10}	1.4431×10^{10}
زمان اجرا (دقیقه)	38	41	26



نتیجه گیری :

- متدهای IES، IEP و IGA برای مسئله کمینه نمودن هزینه‌های GEP مورد بررسی قرار گرفت و نتایج آن با روش برنامه‌ریزی پویا (DP) به ازای افق‌های برنامه‌ریزی ۴ و ۶ ساله مقایسه شد که در نهایت می‌توان چنین نتیجه گرفت:

۱. تکنیک‌های EC یک روش یا چاره دیگری نسبت به روش DP برای مسائل بهینه‌سازی پیچیده می‌باشند چرا که پیدا نمودن جواب بهینه برای افق‌های بلندمدت برنامه‌ریزی تولید به کمک روش DP به علت افزایش نمایی زمان اجرای برنامه بسیار مشکل خواهد بود.
۲. نتایج مسئله برای افق‌های برنامه‌ریزی ۴ و ۶ ساله نشان می‌دهد که روش‌های IES، IEP و IGA می‌توانند جواب‌های بهینه عمومی یا جوابی نزدیک به آن را برای این نوع مسائل با کمترین زمان اجرا تولید کنند.
۳. برای این نوع مسائل روش IGA نسبت به دو روش IES و IEP جوابی بهتر و در زمانی کمتر پیدا می‌کند.
۴. شاید با تنظیم بهتر پارامترهای روش‌های IES و IEP به صورت سعی و خطا بتوان تقریباً به همان جواب IGA دست یافت که مسلماً موجب افزایش زمان اجرای برنامه خواهد شد.

- S. Kannan , et al. “*Application of Evolutionary Computation Techniques for Generation Expansion Planning*” ,IEEE 2003
- *Introduction to the WASP IV model* , User’s manual. International Atomic Energy Agency , Vienna , Austria . Nov 2001
- M. Alireza , “*Genetic Algorithms for all Specialists and Researchers*”
- سید هادی حسینی و دیگران، “ارزیابی نقش تلفات در برنامه ریزی توسعه شبکه انتقال در محیطهای با عدم قطعیت به کمک الگوریتم ژنتیک بهبود یافته”، بیست و سومین کنفرانس بین المللی برق PSC 2008
- Genetic Algorithm Toolbox of *MATLAB 2008*

”ای انسان، تو با تلاش و رنج به سوی پروردگارت می‌روی و او را ملاقات خواهی کرد.“

انشقاق ۶