



الجمهورية العربية السورية  
وزارة التربية  
المركز الوطني للمتميزين

حلقة بحث بعنوان



الخوارزميات الجينية (Genetic Algorithm)



تقديم الطالب : بشار ديب  
بإشراف المدرس : علي جنيدي

للعام الدراسي

2016-2015 م

1437 هـ

## إشكالية البحث :

مع التقدم العلمي الهائل , والتسارع الأسّي (الدليلي) الذي تشهده التكنولوجيا في الوقت الراهن , ظهرت أنماط جديدة من الأنظمة , سميت بالأنظمة الذكية , وبالتالي فُتِح المجال أمام العالم نحو نوع جديد من التكنولوجيا , أُطلق عليه اسم (تكنولوجيا الذكاء الصناعي- Artificial Intelligence Technology) , التي سرعان ما طُوّرت واستخدمت في العديد من التطبيقات اليوم.

ومن هنا جاءت الخوارزميات الجينية (Genetic Algorithm[GA]) كآلية للتعامل مع كائن ما (Object) وجعله يتمتع بالذكاء الصناعي .

فما هي تلك الخوارزمية ؟ ومتى اخترعت ؟ وما هي آلية عملها ؟

في هذا البحث سندرس الخوارزميات الجينية من كل جوانبها , وسنحدد جدوى هذه الخوارزميات ومدى جودتها.

## المقدمة

إن اختراع تقنيات الذكاء الصناعي (Artificial Intelligence[AI]) فتح بوابات جديدة وشكل قفزة نوعية في علوم الحاسوب, ولكن كيف يمكننا تعريف الذكاء الصناعي, إن كنا حتى الآن لا نتفق على تعريف واضح للذكاء البشري؟

لذلك تتنوع تعريف الذكاء الصناعي وتتعدد, لكن مهما اختلفت تعريف الذكاء الصناعي, فإن مضمونه واحد, وجوهره هو الخبرة والمعرفة والذاكرة, فكل تطبيقاته تتمحور حول مفهوم الأمثلة (Optimization) ومعرفة الحل الأنسب للمشاكل المطروحة, بطريقة فعالة.

الأمثلة هي عملية معالجة مسألة ما بطريقة مضبوطة بهدف التوصل إلى أفضل النتائج الممكنة, وانطلاقاً من أهميتها في حل المشاكل, تعد الأمثلة من أهم فروع علم الحاسوب, والهندسة والعديد من الأنظمة الأخرى, والتي تعددت وسائل تطبيقها وتطورت مع الزمن, وصولاً إلى تقنيات التطور (Evolutionary Strategies) والخوارزميات الجينية (Genetic Algorithm) اللتان أصبحتا الآن معاً تشكلان ما يسمى الحوسبة التطورية (Evolutionary Computation).

في بدايات العقد السادس من القرن العشرين (1962 م) تم اختراع الخوارزميات الجينية من قبل جون هولاند (John Holland) في الولايات المتحدة الأمريكية, والتي تم تطويرها من قبل تلامذته في جامعة ميشيغان (Michigan) بين عامي 1960 و 1980.

تعد الخوارزميات الجينية تمثيل للمعتقد السائد بأن الذكاء البشري يُخلق مع الإنسان ويتم اكتسابه عن طريق الوراثة بشكل كبير, فهي محاكاة لعملية التزاوج بين الكائنات الحية من النوع نفسه, وقد استخدمت لها العديد من المصطلحات من علم الوراثة مثل: الجيل والوالدين والعبور والطفرة... الخ

تحاول الخوارزميات الجينية الوصول إلى الحل الأنسب لمشكلة ما, وذلك اعتماداً على مبدأ العالم داروين في الاصطفاء الطبيعي القائم على الاحتفاظ بالميزات والصفات الجيدة الموجودة في جيل الآباء ونقلها إلى جيل الأبناء بهدف الحصول على ذرية قوية تتمتع بأفضل صفات جيل السلف على أقل تقدير (البقاء للأقوى).

جميع الكائنات الحية تتألف من خلايا, وكل خلية تحتوي العدد نفسه من سلاسل ال DNA التي تسمى الكروموسومات (Chromosomes) مما يضيف طابعاً شخصياً للكائن.

كل كروموسوم يمكن تقسيمه إلى الجينات (Genes) المكونة له, والتي تعطي الكائن سمة محددة, مثل لون العين. فعندما يختلف ترتيب الجينات تختلف السمة التي تعطيها, مما يؤثر في الكائن ككل.

هناك ترابط وثيق بين المعلومات السابقة والخوارزميات الجينية التي تعمل بنفس مبدأ انقسام الخلية وتكاثر الخلايا الحية, حيث تشير الكروموسومات إلى الحل المحتمل للمسألة, والجينات هي عبارة عن بت (Bit) واحد أو مجموعة من البتات المتتالية التي ترمز إلى عنصر محدد من الحل المحتمل, بحيث تكون مجموعة احتمالات كل بت هي إما 0 أو 1, وبناء عليه يتم اتخاذ القرار فيما يتعلق بجينات الجيل التالي, وصولاً إلى الحل الأنسب.

وبعد أن تبلورت فكرة الخوارزميات الجينية, بدأت تطبيقاتها تتوسع في منتصف العقد الثامن من القرن العشرين, حيث شملت نطاق واسع من المواضيع, ففي عام 1992 استخدم العالم جون كوزا (John Koza) الخوارزميات الجينية لكي يطور برامج لتأدية مهام محددة, فانتقلت حينها الخوارزميات الجينية إلى حيز البرمجة, وأطلق عليها اسم البرمجة الجينية (Genetic Programming[GP]).

# الباب الأول

## الفصل الأول

### الخوارزميات الجينية وآلية عملها

### Genetic Algorithm and its mechanism

أولاً: ما هي الخوارزمية الجينية ؟

نعلم أن الخوارزمية هي عبارة عن مجموعة من التعليمات المتسلسلة التي تهدف لحل مسألة أو إنجاز هدف معين .

الخوارزمية الجينية هي طريقة من طرائق البحث العشوائي تُستخدم في الحوسبة وذلك بهدف معرفة الحل الصحيحة أو الأقرب للحل الأمثل من بين مجموعة الحلول الممكنة التي تشكل ما يسمى فضاء البحث (Search Space), وذلك عبر مجموعة من الخطوات التي تعتمد على المقارنة وإيجاد "المسافة" بين الحلول ومن ثم انتقاء الحل المناسب والاعتماد عليها في تشكيل حلول أخرى (الجيل الثاني) أكثر ملائمة وأقرب للحل الأمثل.

يتم في أثناء تطبيق الخوارزمية الجينية توصيف المشكلة المطروحة بتمثيل الصبغيات (Chromosomes) الممثلة للحلول بوحدة من طرائق الترميز. بعد ذلك تُطبق مجموعة من العمليات الرياضية المستنبطة من العمليات البيولوجية كالعبور (CrossOver) والانتخاب (Selection) والطفرة (Mutation) للحصول في نهاية المطاف على مجموعة من الصبغيات التي تمثل الجيل الأخير, وباختيار الصبغي الأفضل يتم الوصول إلى الحل الأمثل الذي نريد البحث عنه في المسألة المطروحة, فخوارزمية البحث هذه تبدأ من مجموعة من الحلول العشوائية وتنتهي باختيار واحد من مجموعة "أبناء" من الحلول<sup>1</sup>.

ثانياً : عناصر الخوارزميات الجينية GA Elements :

على الرغم من اختلاف الخوارزميات الجينية حسب فروع الحوسبة التطورية, إلا أنها تشترك على الأقل بالعناصر التالية :

- 1- تعداد سكاني من الصبغيات (Populations of chromosomes) :  
التي تمثل مجموعة البحث أو فضاء البحث (Search Space), وهي عبارة عن مجموعة حلول المسألة .
- 2- الانتقاء (Selection) :  
يتمثل باختيار الصبغيات المناسبة كـ "والدين" من أجل القيام بعملية التزاوج فيما بينها, ولكن عملية الاختيار هذه لا تكون عشوائية, وإنما تعتمد على كفاءة الصبغي (Fitness) .
- 3- الكفاءة (Fitness) : وهي معامل يعطي لكل صبغي قيمة معينة تدل على مدى كفاءة الصبغي (اقترابه من الحل), وبناءً عليه تتم عملية انتقاء الصبغيات .
- 4- العبور (Crossover) :  
بعد اختيار الصبغيات الملائمة من الجيل الأول, يحصل العبور الذي يتم من خلاله تكوين صبغيات جديدة (نسل جديد) اعتماداً على الصبغيات الأم .
- 5- الطفرة العشوائية (Random Mutation) :  
بعد تشكيل النسل الجديد, يتم إحداث طفرات (تغييرات في صبغياتها الصبغية), وهذا الأمر يساعد في الوصول للحل بشكل أسرع<sup>2</sup>.

<sup>1</sup> مجلة جامعة دمشق للعلوم الهندسية-المجلد الثالث والعشرون-العدد الثاني- 2007. أ.بيوح- ح. ريشة (ص 106).

<sup>2</sup> Melanie, M. "An introduction to genetic algorithms." (page 11)

ثالثاً : ترميز الصبغيات Chromosomes encoding :

إذا أردنا أن نحل المسألة بشكل برمجي ,لابد من ترميز كل صبغي بشكل يسهل التعامل معه من قبل الحاسوب وذلك حسب المسألة المطروحة .

إذا كانت المتحولات متقطعة (Discrete Variables) فهي ذات عدد محدود ومن ثم يمكننا استخدام التمثيل الثنائي لترميز جميع الحالات , أما إذا كانت المتحولات مستمرة (Continuous Variables) فهي ذات عدد غير منته وهذا يتطلب القيام بحل ما .

من الحلول المقترحة إيجاد درجة السماحية (Precision) ومن ثم نقوم بتقسيمها على عدد الخانات الثنائية من أجل الترميز, و يمكن أيضاً تحديد عدد الخانات الثنائية , ومن ثم تحديد حجم الخطوة بناءً عليها<sup>3</sup>.

رابعاً : طرائق الترميز Encoding types :

يتم ترميز الحلول كصبغيات تمثل سلاسل من الخانات التي تدعى الجينات (genes) في كل خانة يوجد رقم أو محرف يمثل قيم معينة أو معاملات لحل المسألة , وعادةً ما تُرمز الصبغيات كسلاسل من الأرقام (الثنائية – الحقيقية – الصحيحة – الثمانية – الست عشرية) , ولكل نوع من الأرقام فوائده تبعاً لنوع المسألة المطروحة<sup>4</sup>.

Chromosome 1	1 0 1 0 0 1 1
Chromosome 2	0 1 1 1 0 1 1 1

الشكل 1

الترميز الثنائي للصبغيات



الشكل 2

تغيرات الكفاءة بدلالة رقم الجيل

خامساً : دالة الكفاءة (Fitness function)

وهي عبارة عن تابع رياضي يستخدم في تحديد كفاءة الصبغي , وعادةً يكون الحل (الصبغي) الأفضل هو الذي تكون قيمة دالة الكفاءة عنده أكبرية أو أصغرية حسب نوع المسألة.

<sup>3</sup> مجلة جامعة دمشق للعلوم الهندسية-المجلد الثالث والعشرون-العدد الثاني- 2007 .أبيوح- ح. ريشة (ص 106).

<sup>4</sup> Nopiah, Z. M., Khairir, M. I., Abdullah, S., Baharin, M. N., & Arifin, A. (2010, February). Time complexity analysis of the genetic algorithm clustering method. In *Proceedings of the 9th WSEAS international conference on Signal processing, robotics and automation* (pp. 171-176). World Scientific and Engineering Academy and Society (WSEAS). (page 171).

سادساً : آلية عمل الخوارزميات الجينية GA working mechanism :

عندما نقوم بتحديد المسألة المراد حلها , تبدأ الخوارزمية عملها وفق المراحل التسلسلية التالية :

- 1-التعداد السكاني الابتدائي (Initial population) :  
تقوم الخوارزمية في هذه المرحلة بتشكيل مجموعة مكونة من  $n$  صبغي كل منها مكون من  $l$  جين (خانة) , إن هذه الصبغيات تمثل مجموعة من الحلول الابتدائية للمسألة.
  - 2-نقوم بتحديد دالة الكفاءة  $f(x)$  لكل صبغي  $x$  من التعداد , ومن ثم تقوم الخوارزمية بحساب كفاءة كل صبغي على حدة.
  - 3-تكرر الخوارزمية مجموعة من العمليات حتى يتم الوصول إلى  $n$  سلالة جديدة، هذه العمليات هي كالاتي:
    - a. تبدأ عملية الانتخاب (Selection) حيث يتم اختيار زوج (أو أزواج) من صبغيات التعداد السكاني الحالي , وذلك اعتماداً على قيمة الاحتمال الرياضي  $p_s$  (Probability of selection) , الذي يتناسب مع دالة الكفاءة طردياً - في حال كانت القيمة الأمتلية للحل هي الأكبرية في دالة الكفاءة - أو عكساً - في حال العكس - كما يمكن أن يتم اختيار الصبغي ذاته أكثر من مرة .
    - إن عملية تحديد قيمة  $p_s$  تتم باتباع إحدى خوارزميات الاختيار (سيتم شرحها في فصل لاحق).
    - b. يتم استدعاء إجرائية العبور (CrossOver) , حيث يتم تحديد نقطة ما من الصبغيين الوالدين وفق قيمة الاحتمال  $p_c$  (Probability of crossover) , وبعد ذلك يحصل العبور اعتماداً على تلك النقطة) , إذا لم تتمكن الخوارزمية من تحديد نقطة عبور , فإن الصبغيين الولدين يكونان مطابقان تماماً للوالدين.
    - من الممكن أن يتم اختيار أكثر من نقطة عبور واحدة (multi-point crossover) في بعض الحالات.
    - c. يحصل التطافر (Mutation) على كل جين من الصبغيين الجديدين باحتمال (probability of mutation)  $p_m$  وذلك بتغيير قيمة الجين إلى قيمة جديدة مختلفة لزيادة فرصة الاقتراب من الحل الأمثل , ومن ثم يتم وضع الصبغيين الجديدين في التعداد الجديد.
  - بعد تنفيذ هذه العمليات عدد من التكرارات , يتشكل لدينا  $n$  صبغي جديد , وهنا في حال كان  $n$  فردياً يتم التخلص من صبغي عشوائياً من التعداد.
  - 4-بعد تنفيذ إجرائيات الخوارزمية الجينية , يتم استبدال التعداد السابق بالتعداد الحالي .
  - 5-وأخيراً يتم تكرار العمليات بدءاً من العملية 2 .
- إن كل تكرار لهذه العملية يدعى الجيل (generation) , كما يطلق على مجموعة كل الأجيال اسم التشغيل (run) , حيث أن في نهاية كل تشغيل يوجد غالباً صبغي واحد أو أكثر يكون ذو كفاءة عالية مقارنة مع أبناء جيله<sup>5</sup> .

<sup>5</sup> Melanie, M. "An introduction to genetic algorithms." (page 8)



الشكل 3

المخطط التدفقي لألية عمل الخوارزمية الجينية GA algorithm process flowChart

## معايير الاختيار والعبور والطفرة في الخوارزميات الجينية

### GA's Selection, crossover, mutation standards

كنا قد تطرقنا إلى آلية عمل الخوارزمية الجينية, وعلمنا أن هذه الخوارزمية هي خوارزمية للبحث ,تبدأ بعشوائية (فوضوية) وتنسق تدريجياً ,وصولاً إلى النظام (الحل) الأمثل الذي يرضي المستخدم .

ومن أجل أن يتم الانتقال من العشوائية إلى الاتساق ,لابد من ضبط عمل الخوارزمية وفق عدة معايير تضمن للخوارزمية اتخاذ القرار السليم في أثناء عملها .

هذه المعايير تتحكم في الاختيار والعبور والطفرة ,من أجل الوصول إلى الهدف.

أولاً: معايير الاختيار Selection standards :

وهي عبارة عن خوارزميات معينة ,تسهم في جعل الخوارزمية تتخذ قرارها باختيار زوج الصبغيات الأفضل , وفيما يأتي بعض منها :

#### 1- الاختيار وفق مبدأ العجلة المتدرجة Roulette Wheel Selection :

لنفترض أن لدينا عجلة مقسمة إلى قطاعات مختلفة المساحة (بعضها صغير وبعضها كبير نسبياً) ,إذا قمنا بإدارة العجلة عشوائياً ,فإنها سوف تستقر بحيث يكون مؤشر دال على أحد القطاعات . في هذه الخوارزمية ,يتم الاختيار بالاعتماد على القطاع المشار إليه من قبل المؤشر ,بحيث أن مساحة كل قطاع تتناسب طردياً مع قيمة  $p_s$  للفرد المُمثل بهذا القطاع. يتم حساب  $p_s$  اعتماداً على العلاقة الرياضية التالية :

$$p_s(x) = \frac{f(x)}{\sum_{j=1}^n f(j)}$$

حيث :

$p_s(x)$  احتمالية انتخاب الفرد  $x$  .

$f(x)$  قيمة الكفاءة للفرد  $x$  .

$n$  عدد أفراد الجيل .

بعد تشكيل التعداد الابتدائي ,تقوم الخوارزمية الجينية بحساب قيمة كفاءة كل صبغي على حدة ,ومن ثم قيمة احتمالية اختيار كل فرد من العلاقة السابقة.

الآن نحتاج إلى تدوير العجلة واختيار الفرد الذي أشار المؤشر على القطاع الخاص به, ونلاحظ أنه كلما زادت كفاءة (ملائمة) الفرد ,زادت مساحة القطاع المعبر عنه ,وزادت إمكانية اختياره من أجل التزاوج.

ولكن كيف يمكننا (تدوير العجلة) باستخدام الحاسوب ؟  
 لمحاكاة عملية العجلة المتدرجة حاسوبياً، نحتاج إلى دالة  $C_s(x)$  (دالة الاحتمال التراكمي)، حيث تعطي هذه الدالة لكل فرد  $x$  الاحتمال التراكمي له (مجموع الاحتمالات من احتمال الفرد الأول حتى احتمال الفرد  $x$ ) وذلك وفق العلاقة الرياضية :

$$C(x) = \sum_{i=1}^x p_s(i)$$

بعد ذلك يتم توليد رقم عشوائي ضمن المجال  $[1,100]$  واختيار أول فرد تكون قيمة الاحتمال التراكمي له أكبر أو يساوي هذا الرقم العشوائي<sup>6</sup>.

### عجلة احتمالات أفراد الجيل



■ 1st chromosome ■ 2nd chromosome ■ 3rd chromosome  
 ■ 4th chromosome ■ 5th chromosome ■ 6th chromosome

الشكل 5

التمثيل الاحتمالي الزاوي لاحتمالات اختيار الأفراد

الأفراد	قيمة الكفاءة $f$	قيمة الاحتمال $p_s$	قيمة الاحتمال التراكمي $C$
1	13	0.12	12 %
2	12	0.11	23 %
3	17	0.16	39 %
4	9	0.1	49 %
5	22	0.21	70 %
6	30	0.3	100 %
المجموع	103	1.00	

الشكل 4

جدول الانتخاب وفق العجلة المتدرجة

<sup>6</sup> مجلة جامعة دمشق للعلوم الهندسية-المجلد الثالث والعشرون-العدد الثاني- 2007. أ.بجوح- ح. ريشة (ص 108).

## 2- الاختيار وفق مبدأ حكم النخبة Elitism :

في بعض الحالات الخاصة، قد ينتج عن الاختيار العشوائي للعجلة المتدرجة فرد ذو كفاءة قليلة، وبالتالي يتم استخدامه على حساب فرد آخر أكثر ملائمة .  
من هذا المبدأ تم استخدام طريقة حكم النخبة، التي تعتمد على نسخ الأفراد الذين يتمتعون بكفاءة عالية من الجيل السلف إلى الجيل الخلف، وذلك لضمان الاستفادة منهم في الجيل الثاني، أما بقية الأفراد فيتم اختيارهم بالطرق العادية .

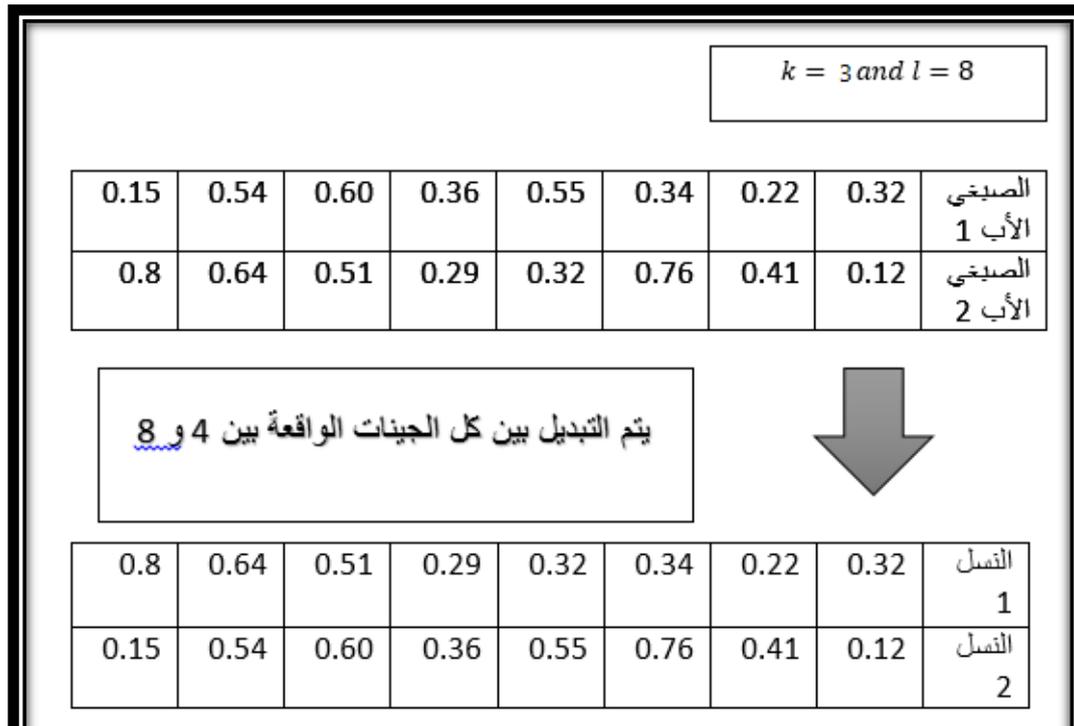
## ثانياً: معايير العبور Crossover standards :

بعد الاختيار، تلجأ الخوارزمية الجينية لإحدى الطرق الآتية من أجل تحديد نقطة العبور بين كل زوج من الصبغيات الآباء :

## 1- العبور البسيط Simple crossover :

بعد اختيار مجموعة الصبغيات، يتم تطبيق هذا النوع من العبور وفق مرحلتين :

- يتم انتقاء صبغيات عشوائية من العينة المختارة .
- كل زوج من الصبغيات يختبر العبور، حيث يتم توليد رقم عشوائي  $k \in [1, l]$  حيث  $l$  يعبر عن طول الصبغي (عدد الجينات لكل صبغي)، ومن ثم يتم خلق صبغيين جديدين عن طريق تبادل الجينات الواقعة بين الموقعين  $k + 1$  و  $l$  كما في الشكل الآتي<sup>7</sup> .



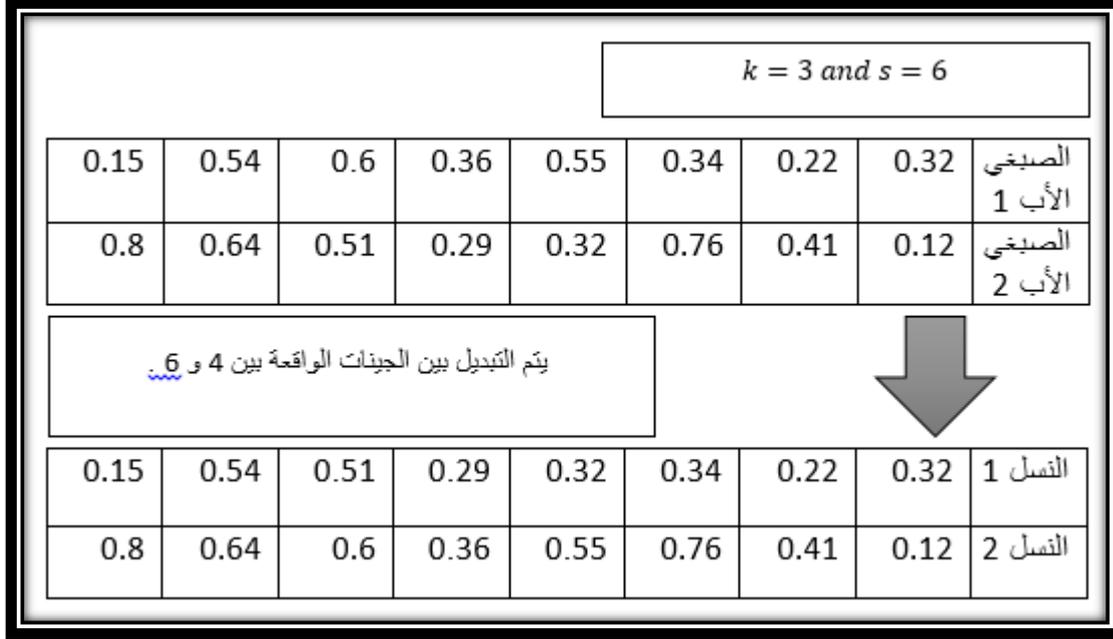
الشكل 6

آلية عمل العبور البسيط

<sup>7</sup> Magalhães-Mendes, J. (2013). A comparative study of crossover operators for genetic algorithms to solve the job shop scheduling problem. *WSEAS transactions on computers*, 12(4), 164-173. (page167).

2- العبور ثنائي النقطة Two-point crossover :

هذا النوع من العبور مشابه للعبور البسيط, ولكن مع اختلاف هو أنه يتم اختيار نقطتي عبور بدلاً من واحدة, فإذا تم تحديد نقطتي العبور  $k, s \in [1, l] : k < s$  فإنه يتم تبادل الجينات الواقعة ضمن المجال  $[k + 1, s]$  وذلك كما في الشكل الآتي :



الشكل 7

آلية العبور ثنائي النقطة

3- العبور المنتق Uniform crossover :

في هذا النمط من العبور, نحتاج أولاً إلى قيمة  $p_c$  (probability of crossover) يحددها المستخدم قبل تنفيذ الخوارزمية .

إذا كان لدينا  $l$  خانة (جين) في كل من الصبغيين الوالدين, تقوم الخوارزمية بمقارنة قيمة كل جين في الصبغي الأول مع القيمة  $p_c$ , فإذا كانت لدينا قيمة ترتيبها  $i : i \leq l$  وقيمتها أكبر أو تساوي  $p_c$  نقوم بتبديل الجين  $i$  من الصبغي الأول مع نظيره من الصبغي الثاني, وإلا يبقى جين الصبغي الأول في موضعه في النسل الأول, وكذلك الأمر بالنسبة لجين الصبغي الثاني<sup>8</sup>.

<sup>8</sup> Magalhães-Mendes, J. "A comparative study of crossover operators for genetic algorithms to solve the job shop scheduling problem."(page 168).

0.15	0.54	0.6	0.36	0.55	0.34	0.22	0.32	الصبغي الأب 1
0.8	0.64	0.51	0.29	0.32	0.76	0.41	0.12	الصبغي الأب 2
0.15	0.54	0.51	0.29	0.32	0.34	0.22	0.32	أرقام عشوائية
$< p_c$	$> p$	$> p$	$< p_c$	$> p$	$> p$	$< p_c$	$> p_c$	$p_c$ = 0.3
0.15	0.64	0.51	0.36	0.32	0.76	0.22	0.12	النسل 1
0.8	0.54	0.6	0.29	0.55	0.34	0.41	0.32	النسل 2

الشكل 8

طريقة العبور الرسمي

#### 4- العبور السطحي Flat crossover :

على فرض لدينا الوالدين الآتيين :

الصبغي الأب 1  $(x_{1,1}, \dots, x_{1,n})$ .

الصبغي الأب 2  $(x_{2,1}, \dots, x_{2,n})$ .

ومجموعة العناصر العشوائية الآتية :

$$r = (r_1, \dots, r_n)$$

بالتالي يكون النسل 1  $(x_1^1, \dots, x_n^1)$  حيث كل قيمة  $x_i$  تحسب بالطريقة الآتية :

$$x_i^1 = r_i x_{1,i} + (1 - r_i) x_{2,i} : i = 1, \dots, n$$

والأمر مشابه بالنسبة إلى النسل 2.

#### ثالثاً: معايير الطفرة Mutation standards :

تفيدنا الطفرة في تأمين التنوع خلال عملية البحث، فإذا نتج كل جيل عن سابقه دون أي اختلاف في بعض القيم، هذا قد يجعل البحث يأخذ منحى ثابت، مما يزيد من وقت البحث اللازم للوصول للهدف، أما بإجراء الطفرات في كل صبغي جديد، هذا يتيح المجال لقيم جديدة قد تكون أفضل من القيم العشوائية الأولى التي ولدتها الخوارزمية، لذلك نلجأ إلى إحداث طفرات في صبغيات الجيل الجديد.

نقوم بتحديد احتمالية حدوث الطفرة  $p_m$  قبل تنفيذ الخوارزمية، وبعد تشكيل الجيل الجديد بأكمله، يتم عشوائياً اختيار جين من كل صبغي (وفق احتمال الطفرة) وبتعديل قيمته إلى قيمة عشوائية أخرى ضمن مجال مناسب للحل، فإذا كانت الجينات تأخذ قيمة ثنائية 0 أو 1، فإن الطفرة ستكون بعكس حالة الجين. كما يجب أن يكون احتمال حدوث الطفرات صغير نسبياً، وقد وُجد أن أفضل قيمة لهذا الاحتمال هي :

$$p_m \in [0.1, 0.9]$$

## الباب الثاني الفصل الأول

### تحليل التعقيد الزمني للخوارزميات الجينية

#### GA time Complexity analysis

نعلم من تعريف الخوارزمية أن لكل منها مجموعة منتهية من العمليات (operations) وأن لكل عملية زمن تنفيذ محدد (running time), لذلك كان من الضروري القيام بدراسة حول الخوارزمية نستطيع من خلالها تحديد زمن تنفيذها وحجم الذاكرة التي ستشغلها, وذلك بهدف معرفة فعالية الخوارزمية ومدى قدرتها على العمل بكفاءة في المسائل الواقعية الأصعب, وأطلق على هذه الدراسة (نظرية التعقيد الحسابي).

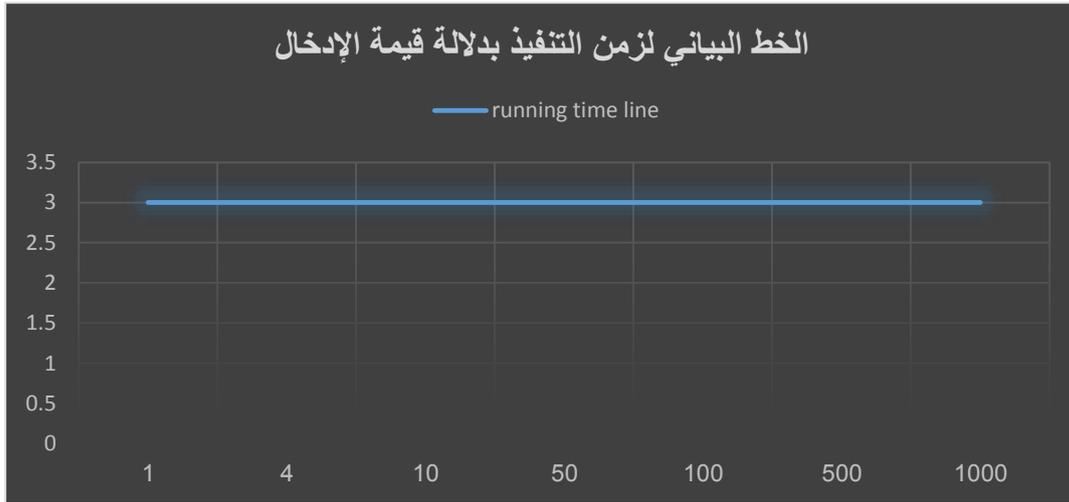
أولاً: التعقيد الزمني لخوارزمية Algorithm's time complexity :

إن التعقيد الزمني هو فرع من فروع نظرية التعقيد الحسابي التي تستخدم من أجل وصف مدى استخدام الخوارزمية للمصادر الحاسوبية (ذاكرة, معالجة, زمن) .

في حالة التعقيد الزمني , فإن ما يهمنا هو معرفة الوقت اللازم لتنفيذ أسوأ حالة قد تعالجها الخوارزمية (Worst case running time) وذلك لمعرفة معدل النمو الزمني للخوارزمية (time growth rate) . إذن فإن ما يهمنا في التعقيد الزمني هو معدل النمو, الذي يتأثر بعامل واحد هو المدخلات (inputs) .

نفترض أن لدينا دالة  $g(n)$  تعبر عن الخط البياني لزمن التنفيذ تبعاً للمدخلات  $n$ , هذه الدالة قد تكون ثابتة, أو خطية أو تربيعية .... الخ.

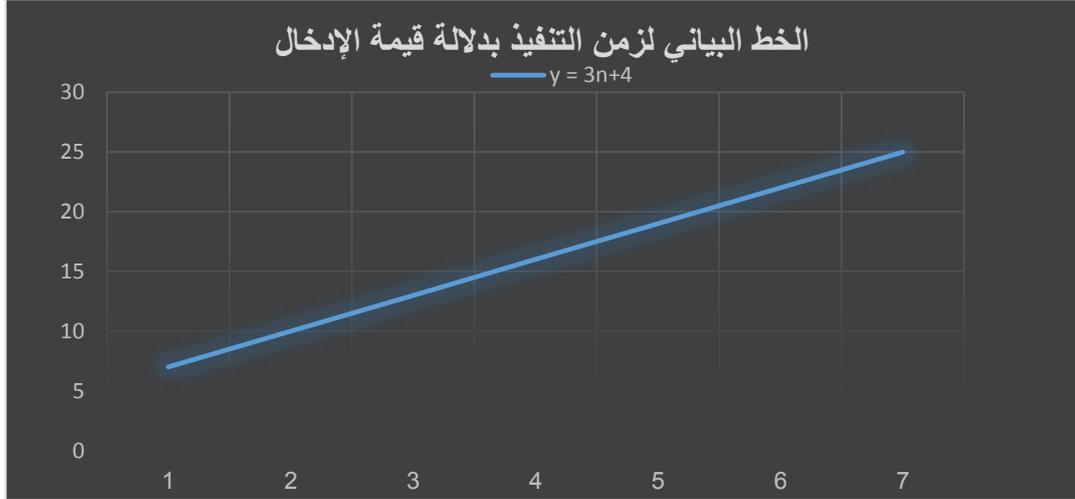
إذن فإن معدل النمو الزمني لخوارزمية يتم من خلال معرفة معادلة الدالة  $g(n)$ , فإذا كانت الدالة ثابتة  $g(n) = 3$ , فهذا يعني أنه من أجل أي إدخال, سوف يكون الوقت اللازم للتنفيذ ثابت  $k$  أي لا يوجد نمو زمني ويكون خطه البياني مستقيم يوازي محور الفواصل [الشكل 9] .



الشكل 9

التمثيل البياني لدالة التنفيذ الثابتة

وإذا كانت الدالة تتبع معادلة مستقيم  $g(n) = 3n + 4$  فإن معدل النمو الزمني سوف يكون ثابتاً، والخط البياني مستقيم ميله  $m = 3$  [ الشكل 10 ] .



الشكل 10

التمثيل البياني لدالة التنفيذ الخطية

بما أننا نهتم بدراسة النمو، لذلك لا نفرق بين التغيرات الصغيرة للدالة  $g(n)$ ، ومن أجل ذلك ظهر الكائن الرياضي (Big-O notation) الذي يستخدم لوصف الحد الأعلى لنمو دالة ما، ويستخدم غالباً ليصف الدوال ذات التصرفات المتشابهة.

يُعرّف (Big-O notation) لدالة ما كالآتي :

$$O(g(n)) = \{f | \exists c > 0, \exists n_0 > 0, \forall n > n_0 : 0 \leq f \leq c \cdot g(n)\}$$

بمعنى آخر، نقول أن الدالة  $f$  تنتمي إلى  $O(g(n))$  ونكتب  $f \in O(g(n))$  إذا وفقط إذا وُجد ثابتان موجبان  $c, n_0$  بحيث أنه من أجل كل قيمة مُدخلة  $n \geq n_0$  تتحقق المتراجحة  $0 \leq f \leq c \cdot g(n)$ .<sup>9</sup>

نستخدم عند دراسة التعقيد الزمني الرمز  $T(n) \in O(g(n))$  وهو يعني أن الزمن اللازم لمعالجة مشكلة حجمها  $n$  هو أحد دوال المجموعة  $O(g(n))$ .

على سبيل المثال، إذا كانت  $g(n) = n$  عندئذٍ تكون :

$$O(g(n)) = O(n) = \{an + b : a \in N, b \in R^+\}$$

<sup>9</sup> Nopiah, Z. M., Khairir, M. I., Abdullah, S., Baharin, M. N., & Arifin, A. (2010, February). Time complexity analysis of the genetic algorithm clustering method. In *Proceedings of the 9th WSEAS international conference on Signal processing, robotics and automation* (pp. 171-176). World Scientific and Engineering Academy and Society (WSEAS)..(page 172).

ثانياً: تحليل التعقيد الزمني للخوارزميات الجينية GA time complexity analysis :

إن التعقيد الزمني للخوارزمية الجينية يختلف حسب اختلاف معايير الخوارزمية , حيث لكل نوع من الخوارزميات الجينية , تعقيد زمني معين .

لو فرضنا أنه في أسوأ الأحوال سوف يتم اختيار التعداد بأكمله في أثناء عملية الاختيار , هذا يعني أن  $P_0$  عدد من الحلول سوف يختبر عملية العبور , فإذا كانت قيمة احتمالية العبور  $0 \leq p_c \leq 1$  فإن عدد الحلول (الصبيغات) الإضافية سوف يكون  $P_0 \cdot p_c$  , مما يجعل عدد الحلول الكلية حتى الآن هو  $P_0 + P_0 \cdot p_c$  . بعد ذلك تأتي عملية إحداث الطفرات , حيث يتم اختيار مجموعة من الحلول من أجل إحداث طفرات عليها . فلتكن  $0 \leq p_m \leq 1$  احتمالية حدوث الطفرة , بالتالي فإن عدد الحلول الإضافية للتعداد سوف يكون  $(P_0 + P_0 \cdot p_c) \cdot p_m$  , وبالتالي يكون التعداد السكاني بعد إجراء عملية تكرار وحيدة هو :

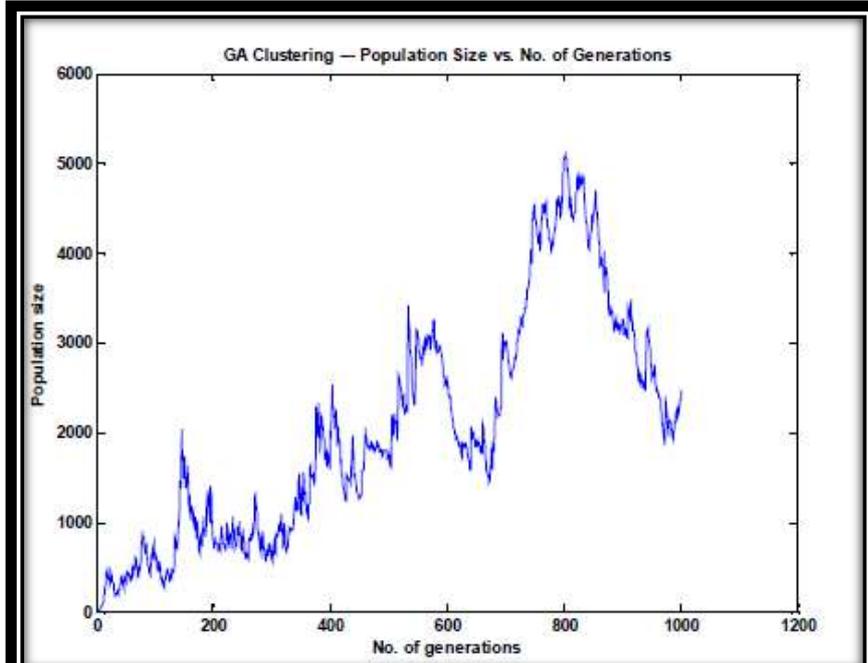
$$\begin{aligned} & P_0 + P_0 \cdot p_c + (P_0 + P_0 \cdot p_c) \cdot p_m \\ & = P_0(1 + p_c + (1 + p_c) \cdot p_m) \\ & = p_0(1 + p_c)(1 + p_m) \end{aligned}$$

ولكي يتمكن المستخدم من التحكم بعض الشيء بالتعداد النهائي , يتم ضرب التعداد النهائي بمعامل التعداد  $C_p$  (Coefficient Of population) الذي يحدده المستخدم , وبالنهاية نحصل على التعداد السكاني الأعظمي :

$$(1) \quad P_{max} = C_p p_0 (1 + p_c)(1 + p_m)$$

1- الخوارزميات الجينية التجميعية (العادية) Clustering Genetic Algorithm :

في هذا النوع يجري تراكم عدد الأجيال , حيث لا تتخلص الخوارزمية من كل صبيغات الجيل الأسبق , وإنما تبقى بعضها للجيل التالي , مما يؤدي لتراكم عدد الصبيغات في كل تكرار للخوارزمية , مما يجعل الزمن اللازم

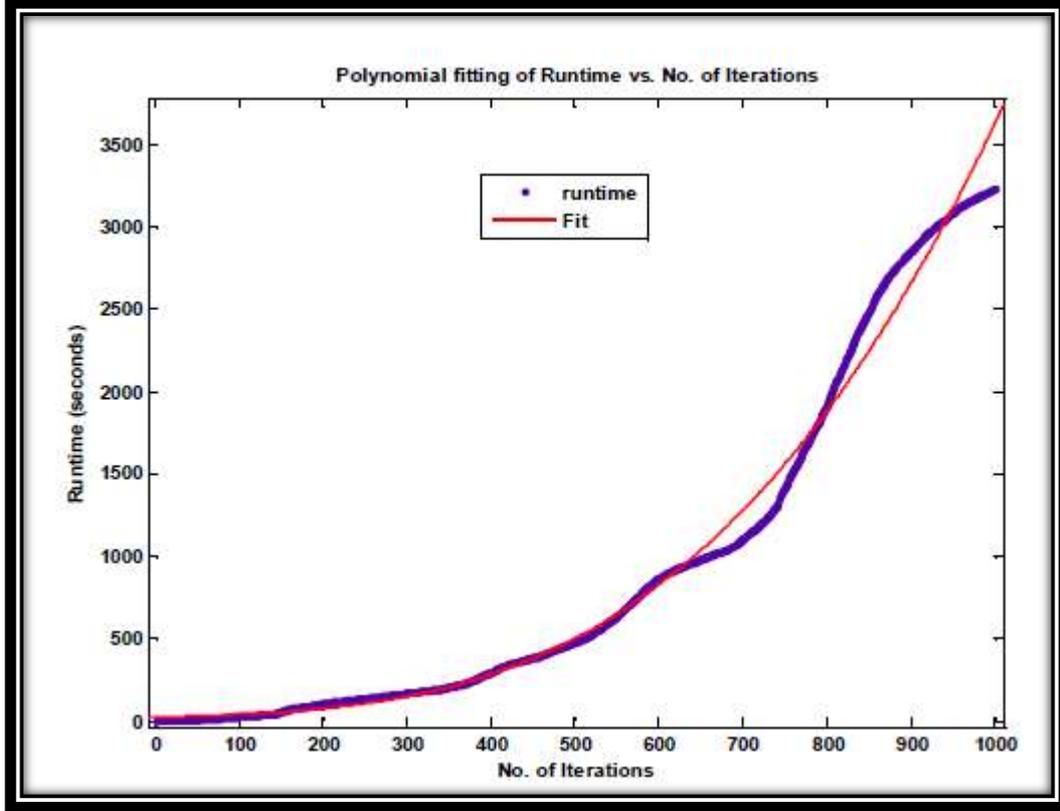


الشكل 11

للمعالج ينمو بشكل متزايد كلما زاد عدد الأجيال , حيث أنه في التعداد الابتدائي , يكون حجم التعداد عدد موجب صحيح  $P_0$  .

تغيرات حجم التعداد بدلالة عدد الأجيال في الخوارزمية الجينية التجميعية

نلاحظ في [الشكل 11] أن التعداد السكاني ينمو مع ازدياد عدد الأجيال (التكرارات) للخوارزمية الجينية التجميعية, حيث أنه على الرغم من أن التعداد السكاني يتزايد أحياناً ويتناقص أحياناً, إلا أنه وبشكل عام يتزايد التعداد السكاني بعد مرور عدد كبير كفاية من الأجيال, الأمر الذي يؤدي إلى زيادة في حجم المسألة المطروحة وبالتالي زيادة التعقيد الزمني للمسألة .



الشكل 12

تغيرات زمن التنفيذ وخط الكفاءة بدلالة عدد الأجيال

من [الشكل 12] نجد أن الخوارزمية تُنفَّذ بوقت تابعه من الشكل  $T(n) = an^3 + bn^2 + cn + d$  (تابع صحيح من الدرجة الثالثة), وبالتالي يكون التعقيد الزمني له هو  $O(n^3)$ , أي إذا ضاعفنا قيمة الدخل الابتدائي, سوف يتضاعف الزمن 3 مرات .

ولكن قيمة هذا التعقيد ليست ثابتة, فأحياناً تكون من الدرجة الثالثة وأحياناً من الدرجة الخامسة.... إلخ.

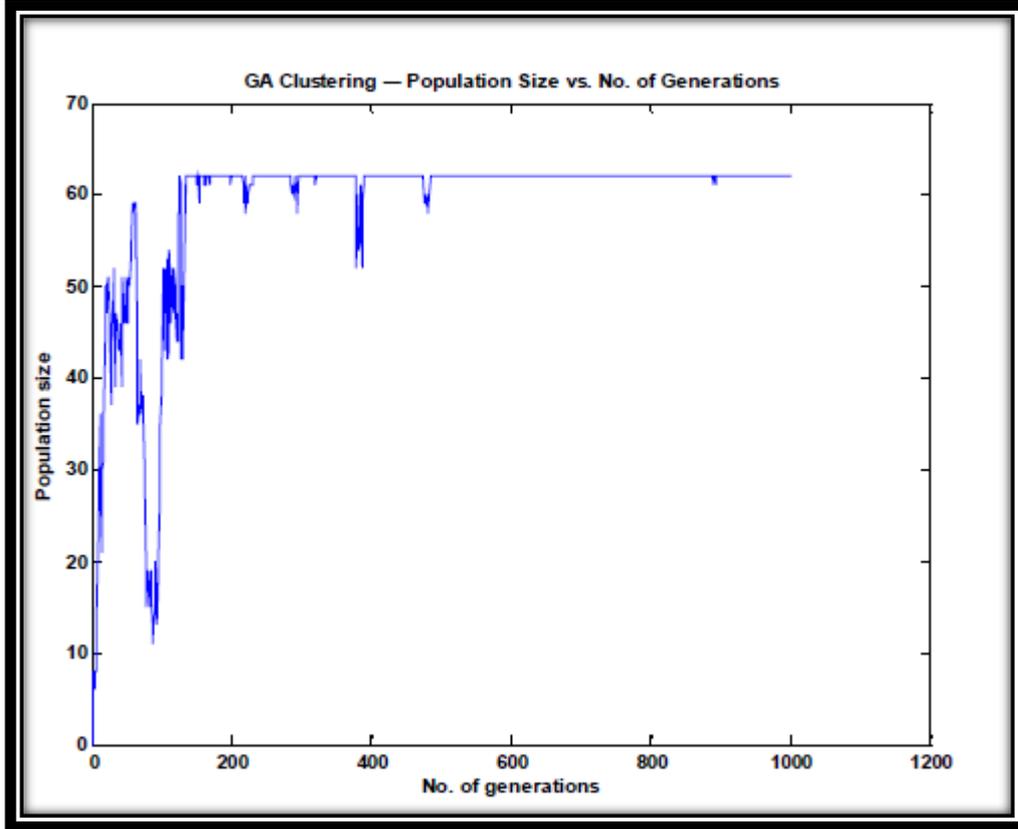
بالنتيجة نجد أنه بما أن التعداد السكاني ينمو بشكل غير محدود, وبالتالي كذلك الأمر بالنسبة إلى حجم المسألة, وإلى الوقت اللازم لإيجاد الحل الأمثل .

إن هذه القيم للتعقيد الزمني تعد قيم كبيرة جداً وفي كثير من الأحيان ليست فعالة, فهي بالتالي تحتاج إلى معالجات ضخمة وذاكرة كبيرة من أجل معالجة وتخزين كل هذه النتائج والحلول<sup>10</sup>.

<sup>10</sup>Nopiah, Z. M., Khairir, M. I., Abdullah, S., Baharin, M. N., & Arifin, A. (2010, February). Time complexity analysis of the genetic algorithm clustering method. In *Proceedings of the 9th WSEAS international conference on Signal processing, robotics and automation* (pp. 171-176). World Scientific and Engineering Academy and Society (WSEAS). (page 173).

## 2- الخوارزميات الجينية (محدودة التعداد) GA limited population :

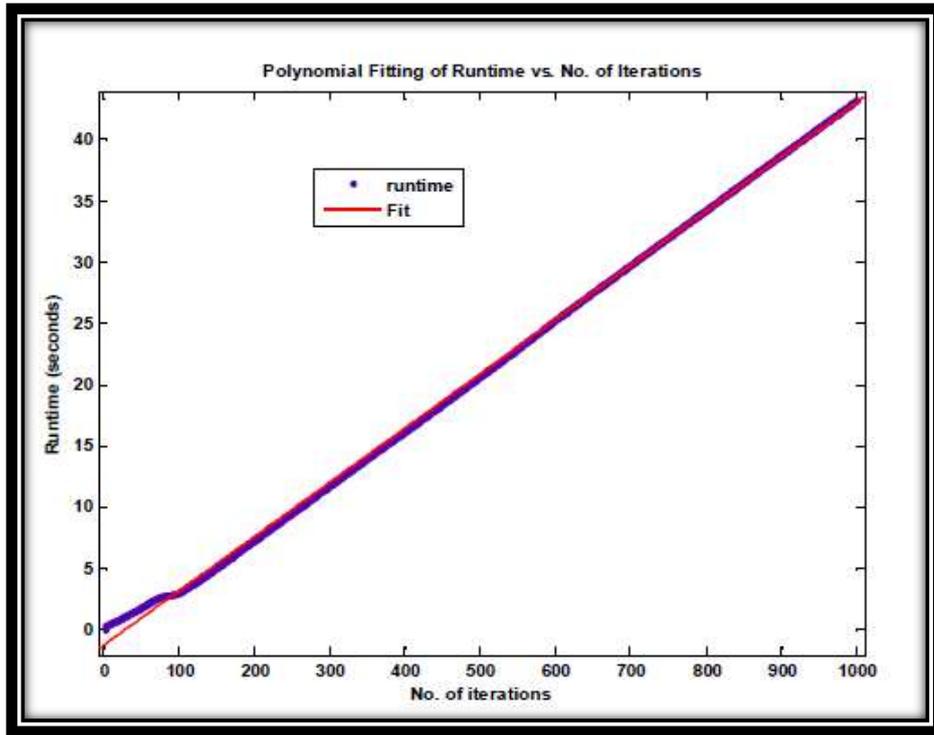
في هذا النوع من الخوارزميات ,يتم تحديد الحد الأقصى من عدد الصبغيات الموجودة في الجيل  $P_{max}$  بحيث تبدأ عملية الاختيار بما لا يتجاوز هذا الحد. عندما يزداد عدد الأجيال المتولدة عن الخوارزمية , يزداد معها تعداد الجيل ,حتى يصل هذا التعداد إلى الحد الأقصى  $P_{max}$  وعندها يبقى ثابتاً على هذا الحد مهما ازداد عدد التكرارات ,مع إمكانية انخفاضه بشكل بسيط .



الشكل 13

تغيرات التعداد بدلالة عدد التكرارات في الخوارزمية محدودة التعداد

نلاحظ في [ الشكل 13 ] أنه على الرغم أن التعداد يزداد بازدياد عدد الأجيال , إلا أن هناك قيمة عظمى لم يتخطاها حجم التعداد هي الحد الأقصى للتعداد  $P_{max}$  الذي يمكن حسابه من العلاقة (1) . بما أن قيمة التعداد في هذه الحالة يبلغ حداً أقصى ثابت , فإن حجم المسألة كذلك سوف يتحدد ويصبح ثابتاً , الأمر الذي يؤدي إلى ثبات عدد عمليات المعالجة , فيصبح الوقت اللازم لتنفيذ كل تكرار (جيل) في الخوارزمية ثابتاً .



الشكل 14

تغيرات وقت التنفيذ وخط الكفاءة بدلالة عدد الأجيال في الخوارزمية الجينية المحدودة التعداد

[ الشكل 14 ] يوضح وقت التنفيذ الحقيقي (بالثواني) بدلالة عدد تكرارات تنفيذ الخوارزمية الجينية المحدودة، ومن الواضح أن الخط البياني للزمن يأخذ شكلاً خطياً (معادلة مستقيم) أي أن الخوارزمية تعمل بتعقيد زمني خطي، أي أن النمو الزمني للخوارزمية ثابت ومتناسب طردياً مع عدد الأجيال المتولدة من الخوارزمية.

بما أن الزمن يأخذ شكل تابع خطي، فإن معادلته من الشكل  $T(n) = an + b$ ، وبالتالي فإن تعقيد الزماني سوف ينتمي إلى المجموعة  $O(n)$  أي أنه إذا تضاعف حجم التعداد الابتدائي، سيقابله تضاعف في زمن التنفيذ بشكل متقابل. الجدول الآتي يبين مقارنة بين الخوارزمية الجينية المحدودة وغير المحدودة من حيث تابع زمن التنفيذ و التعقيد :

التعقيد $O(g(n))$	تابع زمن التنفيذ $T(n)$	رقم المسألة	نوع الخوارزمية
$O(n^3)$	$an^3 + bn^2 + cn + d$	1	الخوارزمية غير محدودة التعداد
$O(n^4)$	$an^4 + bn^3 + cn^2 + dn + e$	2	
$O(n^5)$	$an^5 + bn^4 + cn^3 + dn^2 + en + f$	3	
$O(n)$	$an + b$	1	الخوارزمية محدودة التعداد
		2	
		3	

الشكل 15

جدول يبين الفرق بين الخوارزمية الجينية المحدودة وغير المحدودة

## الفصل الثاني

### بعض تطبيقات الخوارزميات الجينية

### Genetic Algorithm application

بعد أن تعرفنا على الخوارزمية الجينية وآلية عملها ومراحلها المتسلسلة, بقي لنا أن نتعرف على مجالات عملها, وأين يمكننا استخدام هذه الخوارزمية في حياتنا العملية .

أولاً: مثال بسيط عن الخوارزمية الجينية simple GA example :

لنفترض أن لدينا المعادلة الرياضية الآتية :

$$a + 2b + 3c + 4d = 30$$

سنقوم باستخدام الخوارزمية الجينية من أجل إيجاد قيمة كل من  $a, b, c, d$ , في البداية علينا تحديد دالة الكفاءة كالاتي :

$$f(x) = \frac{1}{1 + a + 2b + 3c + 4d - 30}$$

والهدف هو جعل قيمة الدالة  $f(x)$  أكبر ما يمكن, ثم نقوم بتهيئة التعداد الابتدائي المكون من مجموعة صبغيات (6 صبغيات مثلاً) لكل صبغي 4 جينات هي متغيرات المعادلة الرياضية.

بعد ذلك نقوم بتقييم كل صبغي بوساطة دالة الكفاءة ونخزن كفاءة كل صبغي على حدة, ومن ثم ننتقل الآن إلى إجرائية الاختيار, حيث نعلم على مبدأ العجلة المتدرجة (Roulette wheel) في اختيار الصبغيات بالإضافة إلى معامل احتمالية الاختيار  $p_s$ .

بعد ذلك يتم اختيار الصبغيات الأكفأ من بين المجموعة الابتدائية, ونقلها إلى الجيل الثاني .

ومن ثم يتم تطبيق إجرائية العبور (CrossOver) على الصبغيات بالاعتماد على العبور أحادي النقطة (البسيط), حيث نختار عشوائياً موقع في الصبغي الأب ثم نبادل الجينات بعده, ويتم التحكم بمعدل العبور باستخدام قيمة  $p_c$ .

بعد العبور وتكوين صبغيات "معدلة وراثياً", ننتقل الآن إلى إحداث الطفرات, حيث يتم ذلك باعتماد قيمة احتمالية طفرة  $p_m$  صغير .

تعتمد الطفرة على تغيير جين ما في موقع عشوائي بقيمة أخرى عشوائية, حيث نقوم بالبداية بحساب عدد الجينات الكلي في الجيل وهو حاصل ضرب عدد الجينات بكل صبغي مع عدد الصبغيات في الجيل, وفي حالتنا سوف يكون الناتج هو  $4 * 6 = 24$

حيث يتم توليد رقم عشوائي بين 0 و 1 وذلك 24 مرة, فإذا كان الرقم أصغر من احتمالية الطفرة في المرة  $n$ , يتم إحداث طفرة في الجين رقم  $n$  (بعد معرفة الصبغي الذي ينتمي إليه وموقعه ضمن هذا الصبغي).

وبهذا نحصل على جيل جديد, ونلاحظ بتكرار الخطوات السابقة أن قيمة دالة الكفاءة سوف تزداد تدريجياً (لأن مقامها يقل تدريجياً) حتى تصل إلى أعلى قيمة لها وهي الواحد, وعندها تتوقف الخوارزمية وتعلمنا أنها وجدت الحل المناسب للمعادلة .

ثانياً: الروبوتات التطورية Evolutionary Robotics :

إن الهدف الأساسي من هذه الروبوتات هو تطوير طريقة تحكم ذكي لأنظمة روبوتية مستقلة, وقد أصبح ذلك ممكناً الآن بوجود تقنيات الحوسبة التطورية (evolutionary computing techniques) ومنها الخوارزميات الجينية, حيث يتم تطبيقها من أجل تطوير نظام تحكم قادر على إنتاج مجموعة من التصرفات المرغوبة والتفاعل على أساسها.

ولكن بالطبع ليس مستقلة تماماً عن الإنسان, فهي – كما نعلم- بحاجة إلى دالة الكفاءة التي هي معيار عملها, ولكن باختيار دالة الكفاءة المناسبة, أمكننا إنتاج روبوتات تتصف بالذكاء والقدرة على مواجهة المواقف<sup>11</sup>.

---

<sup>11</sup> Bashir, L. Z. and R. S. M. Hasan "Intelligent Robotic Behaviour Based On Bucket Brigade Algorithm."(page 96).

## الخاتمة

وبهذا البحث نكون قد تعرفنا على نوع جديد من الخوارزميات هي الخوارزميات الجينية, والتي هي من تطبيقات الذكاء الصناعي, فهي خوارزمية تبحث عن الحل الأنسب لمسائل متنوعة, ولا حدود لتطبيقاتها, من الهندسة والميكانيك إلى الروبوتيك والبرامج وألعاب الفيديو والكائنات الافتراضية الذكية.....إلخ.

وقد تطرقنا في هذا البحث إلى مجموعة من الأفكار الشاملة نسبياً لكل ما يتعلق بالخوارزميات الجينية, هي:

- تاريخ الخوارزميات الجينية ومراحل تطورها, وبداياتها التي اعتمدت على نظرية التطور للعالم دارون.
- الفكرة للعامّة لخوارزمية البحث الجينية وما يميزها عن غيرها من خوارزميات البحث.
- معاملات الخوارزمية الجينية (الاختيار والعبور والطفرة) إضافة إلى دالة الكفاءة.
- آلية عمل الخوارزميات الجينية من التعداد السكاني الابتدائي وحتى الانتهاء من توليد الجيل النهائي.
- معايير الاختيار والعبور والطفرة للخوارزمية الجينية.
- مفهوم التعقيد الزمني للخوارزمية.
- تحليل التعقيد الزمني للخوارزمية الجينية والمقارنة بين تعقيد نوعيها الأساسيين (محدود وغير محدود).
- وبالنهاية تطرقنا إلى بعض تطبيقات الخوارزمية الجينية وقمنا بتطبيق مثال بسيط يبين آلية عملها.

وبذلك نكون قد أعطينا فكرة عامة عن هذه الخوارزمية التي يكثر استخدامها تدريجياً في شتى المجالات, حيث نعلم أن البحث هو من أهم العمليات التي يقوم بها الدماغ البشري للوصول إلى حل مسألة ما, فعندما نواجه مسألة نبدأ بالتفكير في الحل اعتماداً على قدراتنا الدماغية, حيث نبحث عن معلومة ما من مجموعة ضخمة جداً من المعلومات المتراكمة عبر السنين, وبعد ذلك نجد الحل المناسب للمشكلة, أي أنه لحل المشكلة لا بد من وجود ما هو متعلق بهذه المشكلة في ذاكرتنا.

يمكننا أن نقرن هذا الشيء بدالة الكفاءة التي نقدمها لخوارزمتنا الجينية بهدف تقييم الحلول العشوائية التي تنتجها وعليه تقرر الإكثار من حلول والتقليل من غيرها بما يضمن الاقتراب من الحل الأنسب للمسألة المطروحة.

إن للخوارزمية الجينية علاقة وثيقة بنظرية التطور لدارون التي تقول بأن الذكاء يتطور وينتقل بالوراثة, وأن (البقاء للأقوى), حيث أن الخوارزمية الجينية تعتمد على إبقاء الأكفأ من مجموعة الحلول وجعله خلفاً لما بعده من أجيال, بالتالي سوف يتمتع أفراد الجيل بكفاءة تساوي على الأقل كفاءة والديها, وبتكرار تلك العملية تنشأ لدينا أجيال متطورة جداً حتى يصبح حل المسألة بالنسبة لها سهل جداً.

كما أنه من المهم جداً تحديد متى يجب أن تتوقف الخوارزمية الجينية عن عملها, إما اعتماداً على الوصول إلى نتيجة مرضية, وإما بالاعتماد على عدم تجاوز التنفيذ وقت محدد, وذلك يختلف حسب ما هو مطلوب في المسألة المطروحة, ففي بعض المسائل, لا يهمننا الحصول على الجواب الدقيق, وإنما الاقتراب من الحل, لذلك نطلب من الخوارزمية التوقف إذا حققت نسبة مئوية معينة من الحل.

وفي مسائل أخرى تهمننا الدقة, لذلك نجعل الخوارزمية تتابع تكرار نفسها لأطول مدة زمنية ممكنة لضمان الوصول إلى الحل الصحيح.

في عالم تتسارع فيه المعارف والعلوم, وبدأت فيه التكنولوجيا تأخذ منحى جديد, يستقل عن البشر بعض الشيء, ظهرت إحدى الخوارزميات التي هي وليدة جيل جديد من الآلات الذكية..... الخوارزميات الجينية (Genetic Algorithm).

## المصادر والمراجع

- Magalhães-Mendes, J. (2013). A comparative study of crossover operators for genetic algorithms to solve the job shop scheduling problem. *WSEAS transactions on computers*, 12(4), 164-173.
- Sudholt, D. (2008). *Computational complexity of evolutionary algorithms, hybridizations, and swarm intelligence* (Doctoral dissertation).
- Dreier, F. (2002). Genetic Algorithm Tutorial..
- Whitley, D. (1994). A genetic algorithm tutorial. *Statistics and computing*, 4(2), 65-85.
- Melanie, M. (1999). An introduction to genetic algorithms. *Cambridge, Massachusetts London, England, Fifth printing*, 3.
- Nopiah, Z. M., Khairir, M. I., Abdullah, S., Baharin, M. N., & Arifin, A. (2010, February). Time complexity analysis of the genetic algorithm clustering method. In *Proceedings of the 9th WSEAS international conference on Signal processing, robotics and automation* (pp. 171-176). World Scientific and Engineering Academy and Society (WSEAS).
- Bashir, L. Z., & Hasan, R. S. M. Intelligent Robotic Behaviour Based On Bucket Brigade Algorithm.
- Hermawanto, D. (2013). Genetic Algorithm for Solving Simple Mathematical Equality Problem. *arXiv preprint arXiv:1308.4675*.
- مجلة جامعة دمشق للعلوم الهندسية-المجلد الثالث والعشرون-العدد الثاني- (2007) - أ.أ.بجوح-  
ح. ريشة - "تأثير متغيرات الخوارزمية الجينية في مسألة إيجاد الحل الأمثل".

## فهرس الصور

رقم الصفحة	المحتوى	رقم الشكل
- 5 -	الترميز الثنائي للصبغيات	1
- 5 -	تغيرات الكفاءة بدلالة رقم الجيل	2
- 7 -	المخطط التدفقي لآلية عمل الخوارزمية الجينية	3
- 9 -	جدول يبين الانتخاب وفق مبدأ العجلة المتدرجة	4
- 9 -	التمثيل الاحتمالي الزاوي لاحتمالات اختيار الأفراد	5
- 10 -	آلية عمل العبور البسيط	6
- 11 -	آلية عمل العبور ثنائي النقطة	7
- 12 -	طريقة العبور الرسمي	8
- 13 -	التمثيل البياني لدالة التنفيذ الثابتة	9
- 14 -	التمثيل البياني لدالة التنفيذ الخطية	10
- 15 -	تغيرات حجم التعداد بدلالة عدد الأجيال في الخوارزمية الجينية التجميعية	11
- 16 -	تغيرات زمن التنفيذ وخط الكفاءة بدلالة عدد الأجيال في الخوارزمية التجميعية	12
- 17 -	تغيرات التعداد بدلالة عدد التكرارات في الخوارزمية الجينية محدودة التعداد	13
- 18 -	تغيرات وقت التنفيذ وخط الكفاءة بدلالة عدد الأجيال في الخوارزمية محدودة التعداد	14
- 18 -	جدول يبين الفرق بين الخوارزمية الجينية المحدودة وغير محدودة التعداد	15

## فهرس المحتويات

### Table of Contents

1	إشكالية البحث :
2	المقدمة
3	الباب الأول
3	الفصل الأول (الخوارزميات الجينية وآلية عملها)
7	الفصل الثاني (معايير الاختيار والعبور والطفرة في الخوارزمية الجينية)
12	الباب الثاني
12	الفصل الأول (تحليل التعقيد الزمني للخوارزميات الجينية)
18	الفصل الثاني (بعض تطبيقات الخوارزميات الجينية)
20	الخاتمة
21	المصادر والمراجع
22	فهرس الصور
23	فهرس المحتويات