



وزارة التعليم العالي والبحث العلمي

جامعة بابل

كلية العلوم الصرفة

قسم الرياضيات

# دمج الذكاء الاصطناعي ونظرية الرسوم البيانية لإيجاد الحلول المثلى باستخدام الخوارزميات الجينية

بإشراف

أ.م.د. إيناس حمود السعدي

إعداد الطالب

سيف حسين خضير

بِسْمِ اللّٰهِ الرَّحْمٰنِ الرَّحِیْمِ

((وَقَالَ الَّذِينَ أُوتُوا الْعِلْمَ وَالْإِيمَانَ

لَقَدْ لَبِثْنَا فِي كِتَابِ اللَّهِ))

صدق الله العلي العظيم

## الإهداء

الى من كانوا يضيئون لي الطريق ويساندوني  
ويتنازلون عن حقوقهم أرضا والعيش  
في هناء أمي وأبي وأخواني  
أحبكم حبا لو مر على الأرض قاحلة  
لتفجرت منها ينابيع المحبة

إلى

كل من علمني حرفا وأنار أمامي طريق المستقبل  
"أساتذتي الأفاضل"

اهدي ثمرة جهدي المتواضع حبا ووفاء لهم

## شكر وتقدير

كن عالماً فان لم تستطع فكن متعلماً. فان لم تستطع فأحب العلماء فان لم تستطع فلا تبغضهم. بعد رحلت بحث وجهد واجتهاد تكلفت بإنجاز هذا البحث نحمد الله العلي القدير الذي انعم على بنعمة العقل والدين، وأيضا وفاءً وتقديراً واعترافاً مني بالجميل أتقدم بجزيل الشكر لأولئك المخلصين الذين لم يألوا جهداً في مساعدتنا في مجال البحث واطح بالذكر الأستاذة الفاضلة (أ.م.د. إيناس حمود السعدي) فهي صاحبة الفضل في توجيهي ومساعدتي في تجميع المادة فجزاها الله خيراً

## ملخص البحث

يسعى هذا البحث إلى دراسة التكامل الفعال بين تقنيات الذكاء الاصطناعي ونظرية الرسوم البيانية كأداة متطورة لتحليل الشبكات الضخمة والمعقدة واكتشاف الأنماط المخفية فيها. ركزت الدراسة على معالجة التحديات الحسابية المرتبطة بمسألة مجموعة الهيمنة المثلى، والتي تعد من المسائل الصعبة حسابياً، عبر توظيف الخوارزميات الجينية كنهج ذكي للبحث عن حلول دقيقة. استعرض البحث البنية الأساسية للرسوم البيانية وتطبيقاتها الواسعة في مجالات الشبكات الاجتماعية والنقل والبيانات الحيوية، موضحة أهمية الذكاء الاصطناعي في تحسين التنبؤ واتخاذ القرارات. تم تفصيل آليات عمل الخوارزميات الجينية المعتمدة على محاكاة التطور الطبيعي عبر مراحل توليد الحلول العشوائية ثم تقييم كفاءتها واختيار الأفضل منها للتكاثر. ساهم استخدام مفاهيم التهجين والطفرات في تعزيز تنوع الحلول ومنع الركود، مما ساعد في الوصول إلى نتائج قريبة جداً من المثالية في زمن قياسي. أظهرت الدراسة أن دمج الشبكات العصبية للرسوم البيانية وتصنيف العقد يفتح آفاقاً واسعة لفهم ديناميكية الشبكات المعقدة وحماية المؤسسات من الاحتيال المالي. خلص البحث إلى أن الاعتماد على الخوارزميات الذكية يمثل اتجاهاً واعداً في نظرية الرسوم البيانية يقلل الخطأ البشري ويزيد من دقة التخطيط الاستراتيجي. تتيح هذه الأدوات المتقدمة معالجة البيانات البيولوجية وتفاعلات البروتينات بفعالية عالية تساهم في فهم الوظائف الحيوية واكتشاف الأنماط المعقدة. أكدت النتائج كفاءة الخوارزميات الجينية في التعامل مع مشاكل التحسين الكبيرة بمرونة عالية تسمح بدمجها مع تقنيات الذكاء الاصطناعي المختلفة. يمثل هذا الدمج وسيلة علمية ومنهجية لاستخراج معلومات قيمة من البيانات الكبيرة وتوظيفها بشكل عملي لتعزيز الفهم العلمي ودعم التطبيقات الميدانية.

## المحتويات

١	الفصل الاول .....
١	١,١ مقدمة عامة .....
٢	١,٢ مشكلة البحث .....
٣	١,٣ أهداف البحث .....
٤	١,٤ أهمية البحث .....
٥	الفصل الثاني .....
٥	( الرسوم البيانية والذكاء الصناعي ) .....
٥	٢,١ الرسوم البيانية (Graphs) .....
٥	٢,١,١ أنواع الرسوم البيانية: .....
٦	٢,٢ الذكاء الاصطناعي (Artificial Intelligence) .....
٧	٢,٢,١ مجالات الذكاء الاصطناعي الأساسية: .....
٨	٢,٢,٢ أهمية AI في تحليل البيانات : .....
٩	٢,٢,٣ تصنيف البيانات واكتشاف الأنماط المخفية : .....
٩	٢,٣ دمج الذكاء الاصطناعي مع الرسوم البيانية .....
١٠	٢,٣,١ الطرق المستخدمة في دمج الذكاء الاصطناعي مع الرسوم البيانية .....
١١	٢,٣,٢ تطبيقات الذكاء الاصطناعي على الخوارزميات البيانية .....
١٢	الفصل الثالث .....
١٢	استخدام الخوارزميات الجينية في تحليل الرسوم البيانية .....
١٢	٣,١ مقدمة .....
١٣	٣,٢ عمل الخوارزميات الجينية في تحليل الرسوم البيانية .....
١٣	٣,٤ استخدام الخوارزميات الجينية في تحليل الرسوم البيانية .....
١٤	٣,٥ الأساس النظري للخوارزميات الجينية .....
١٥	٣,٦ تطبيق الخوارزميات الجينية على الرسوم البيانية .....
١٦	٣,٧ مميزات استخدام الخوارزميات الجينية .....
١٧	الفصل الرابع .....
١٧	( الاستنتاجات ) .....
١٨	خاتمة البحث .....
١٩	المصادر

## الفصل الأول

### ١,١ مقدمة عامة

تعتبر الرسوم البيانية (Graphs) من الأدوات القوية لتمثيل العلاقات بين الكيانات المختلفة، وتستخدم على نطاق واسع في الشبكات الاجتماعية، شبكات النقل، شبكات الإنترنت والبيانات العلمية. ومع زيادة حجم البيانات وتعقيدها، أصبح من الصعب تحليل هذه البيانات باستخدام الطرق التقليدية، خاصة عند التعامل مع مشكلات الأمثلية المعقدة التي تتطلب حلول دقيقة وفعالة. (١)

يأتي الذكاء الاصطناعي (AI) ليحل هذه المشكلة من خلال قدرته على معالجة البيانات الكبيرة، اكتشاف الأنماط المخفية، والتنبؤ بالعلاقات المستقبلية بين الكيانات. دمج الذكاء الاصطناعي مع الرسوم البيانية يوفر أدوات تحليلية متقدمة يمكنها تحسين دقة التحليل، تسريع عملية اتخاذ القرار، والمساعدة في حل المشكلات التي يصعب حلها بالطرق التقليدية. من بين هذه المشكلات إيجاد مجموعة الهيمنة المثلى (Set Dominating Optimal). (٢)

في الرسوم البيانية يمثل تحديًا مهمًا، حيث تهدف هذه المجموعة إلى اختيار أقل عدد ممكن من العقد بحيث تضمن التغطية الكاملة لجميع العقد الأخرى في الرسم البياني. استخدام الخوارزميات الجينية كأحد تقنيات الذكاء الاصطناعي يوفر نهجًا فعالًا للبحث عن حلول تقريبية قريبة من المثالية، مع الحفاظ على الوقت والجهد، مما يجعل هذا الدمج أداة قوية لتحليل الرسوم البيانية المعقدة والتعامل مع البيانات الكبيرة بطريقة ذكية وعملية. (٣)

## ١,٢ مشكلة البحث

مع التوسع الكبير في حجم البيانات وتزايد تعقيد الشبكات في مختلف المجالات، أصبحت عملية تحليل الرسوم البيانية تمثل تحديًا بحثيًا مهمًا. إذ تحتوي الشبكات الحديثة على عدد كبير من العقد والعلاقات المتشابكة، مما يؤدي إلى ارتفاع التعقيد الحسابي لبعض المسائل مثل مسألة مجموعة الهيمنة المثلى، والتي تُعد من المسائل الصعبة حسابيًا (Complete-NP) كما أوضح. (٤) لذلك أصبح من الضروري البحث عن تقنيات متقدمة قادرة على معالجة هذا التعقيد بكفاءة أعلى من الأساليب التقليدية.

المشاكل المتعلقة بالخوارزميات الجينية:

١. صعوبة تحليل البيانات المعقدة والمتشابكة باستخدام الطرق التقليدية.
٢. عدم قدرة التحليل اليدوي على اكتشاف الأنماط المخفية في الشبكات.
٣. حاجة إلى تقنيات ذكاء اصطناعي متقدمة لتحسين التنبؤ واتخاذ القرارات بناء على البيانات البيانية. (٣)

### اولا / صعوبة تحليل البيانات المعقدة والمتشابكة باستخدام الطرق التقليدية:

الرسوم البيانية الكبيرة (Scale Networks-Large) تتميز بترابط عالي وتعقيد بنيوي، والطرق التقليدية في نظرية الرسوم أو التحليل الإحصائي تعاني عند زيادة عدد العقد والحواف، خصوصا في الشبكات الواقعية مثل شبكات التواصل. (٥)

### ثانيا / عدم قدرة التحليل اليدوي على اكتشاف الأنماط المخفية في الشبكات:

في الشبكات المعقدة، الأنماط مثل المجتمعات (Communities) أو العلاقات غير المباشرة تكون مخفية داخل كمية هائلة من البيانات، والتحليل اليدوي أو البسيط ما يكشفها بكفاءة. (٦)

### ثالثا / الحاجة إلى تقنيات ذكاء اصطناعي متقدمة لتحسين التنبؤ واتخاذ القرار:

مع ازدياد حجم البيانات البيانية، أصبح من الضروري استخدام تقنيات الذكاء الاصطناعي، مثل الخوارزميات الجينية، لتحسين التنبؤ واتخاذ القرارات المبنية على تحليل الشبكات. (٣)

### ١,٣ أهداف البحث

يهدف هذا البحث إلى توضيح العلاقة بين الرسوم البيانية وتقنيات الذكاء الاصطناعي، خصوصًا الخوارزميات الجينية، وكيف يمكن الاستفادة منها في تحليل الشبكات المعقدة وحل المشكلات المرتبطة بها. يسعى البحث إلى دمج الجانب النظري والتطبيقي لتقديم فهم شامل لآلية عمل الخوارزميات الجينية في تحليل البيانات البيانية. (٢)

#### ١. دراسة خصائص الرسوم البيانية وأنواعها:

الهدف هو التعرف على البنية الأساسية للرسوم البيانية، مثل العقد (Nodes) والحواف (Edges)، وأنواعها المختلفة مثل الرسوم الموجهة وغير الموجهة، والرسوم ذات الوزن، وكيف تؤثر هذه الخصائص على تحليل الشبكات. فهم هذه الخصائص يعد أساس لأي تحليل لاحق باستخدام أساليب الذكاء الاصطناعي. (٧)

#### ٢. التعرف على دور الذكاء الاصطناعي في تحليل البيانات البيانية:

الهدف هو إبراز أهمية تقنيات الذكاء الاصطناعي، مثل التعلم الآلي والخوارزميات التطورية، في معالجة الرسوم البيانية الكبيرة والمعقدة، واكتشاف الأنماط المخفية، وتحسين التنبؤ واتخاذ القرار المبني على البيانات البيانية. (٨)

#### ٣. توضيح كيفية استخدام الخوارزميات الجينية في حل مشاكل الرسم البياني:

الهدف هو إبراز أهمية تقنيات الذكاء الاصطناعي، مثل التعلم الآلي والخوارزميات التطورية، في معالجة الرسوم البيانية الكبيرة والمعقدة، واكتشاف الأنماط المخفية، وتحسين التنبؤ واتخاذ القرار المبني على البيانات البيانية. (٣)

## ١,٤ أهمية البحث

يسعى البحث إلى تسليط الضوء على دور الخوارزميات الجينية والذكاء الاصطناعي في تحليل الرسوم البيانية، مع إبراز كيف يمكن لهذه الأدوات تعزيز الفهم العلمي للبيانات المعقدة ودعم التطبيقات العملية في مختلف المجالات. (٢)

### ١. تمكين الباحثين من فهم البيانات المعقدة وتحليلها بطريقة علمية:

الرسوم البيانية الكبيرة والمعقدة تحتوي على علاقات مترابطة وأنماط مخفية يصعب كشفها بالطرق التقليدية. استخدام تقنيات الذكاء الاصطناعي والخوارزميات الجينية يمكّن الباحثين من تحليل هذه البيانات بطريقة منهجية وعلمية، ما يساعد على الوصول إلى استنتاجات دقيقة وموثوقة. (٥)

### ٢. تطوير تطبيقات ذكية في مجالات مختلفة مثل الشبكات الاجتماعية، النقل، والبيانات البيولوجية:

تحليل الرسوم البيانية باستخدام الخوارزميات الجينية يفتح المجال لتطوير تطبيقات ذكية مثل تحسين شبكات النقل، كشف المجتمعات في الشبكات الاجتماعية، وتحليل التفاعلات في البيانات البيولوجية، مما يزيد من كفاءة هذه الأنظمة ويساعد على استغلال البيانات الكبيرة بشكل عملي. (٥)

### ٣. تعزيز القدرة على اتخاذ القرار المستند إلى تحليل متقدم للبيانات:

باستخدام التحليل البياني المتقدم وتقنيات الذكاء الاصطناعي، يمكن اتخاذ قرارات مبنية على أنماط وعلاقات دقيقة في البيانات، مما يقلل من الخطأ البشري ويزيد من دقة التخطيط الاستراتيجي في المؤسسات والمشاريع. (٩)

## الفصل الثاني

### (الرسوم البيانية والذكاء الصناعي)

#### ٢,١ الرسوم البيانية (Graphs)

الرسوم البيانية هي هيكل بيانات يتكون من عقد (Nodes) وحواف (Edges) تمثل العلاقات بينها. كل عقدة تمثل عنصرًا محددًا، بينما تمثل الحواف العلاقة أو الاتصال بين هذه العقد. تُستخدم الرسوم البيانية في علوم الكمبيوتر، الرياضيات، والشبكات لتحليل البيانات المعقدة وفهم التفاعلات بين العناصر بطريقة منظمة ومرئية. هذا الهيكل يسهل التعرف على الأنماط والارتباطات داخل البيانات الكبيرة والمعقدة وتُستخدم هذه البنية في علوم الكمبيوتر والرياضيات لتحليل الشبكات والبيانات المعقدة. وتسهل فهم التفاعلات والاتصالات بين العناصر بطريقة مرئية وواضحة. (٧)

#### ٢,١,١ أنواع الرسوم البيانية:

##### أولاً / الرسوم البيانية غير الموجهة (Undirected Graphs):

في هذه الرسوم، الحواف لا تحتوي على اتجاه أي أن العلاقة بين أي نقطتين متبادلة. مثل أصدقاء على الفيس بوك، حيث العلاقة بين أي شخصين متبادلة. (٧)

##### ثانياً / الرسوم البيانية الموجهة (Directed Graphs):

في هذه الرسوم، الحواف تحتوي على سهم تحدد اتجاه العلاقة، أي أن العلاقة قد لا تكون متبادلة. مثل متابعة على منصة X، حيث الشخص أ يتابع الشخص ب، لكن ب قد لا يتابع أ. (٧)

##### ثالثاً / الرسوم البيانية الوزنية (Weighted Graphs):

في هذه الرسوم، لكل حافة قيمة أو وزن يمثل شيئاً محددًا مثل المسافة أو التكلفة. مثل الخرائط، حيث تمثل الحواف المسافة بين المدن أو التكلفة اللازمة للانتقال من نقطة إلى أخرى. (٧)

## ٢,١,٢ تطبيقات الرسوم البيانية

تُستخدم في مجالات متعددة لتحليل العلاقات المعقدة وفهم الأنماط بين العناصر، ومن أهم تطبيقاتها:

### أولاً / الشبكات الاجتماعية (Social Networks):

تُستخدم الرسوم البيانية لتمثيل العلاقات بين الأفراد أو المجموعات، مثل الأصدقاء على فيسبوك أو المتابعين على تويتر، وتحليل المجتمعات، التفاعل، وتأثير الأعضاء في الشبكة. (٥)

### ثانياً / شبكات النقل (Transportation Networks):

تُستخدم لتخطيط الطرق، تحسين حركة المرور، حساب أقصر المسارات بين المدن، وتقييم تكلفة الانتقال باستخدام الرسوم البيانية الوزنية. (١٠)

### ثالثاً / شبكات الإنترنت (Internet Networks):

تمثل العقد الأجهزة أو الخوادم، والحواف تمثل الاتصالات بينها، لتحليل أداء الشبكة، اكتشاف الاختناقات، وحماية الشبكة من الهجمات. (١١)

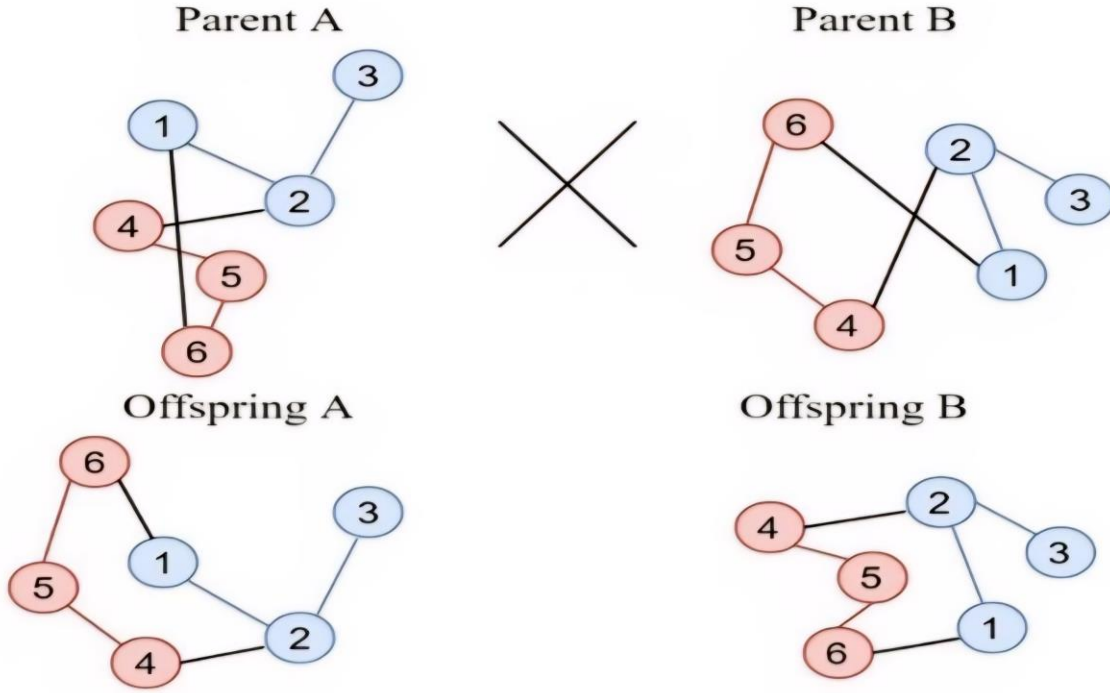
### رابعاً / تحليل البروتينات والبيانات البيولوجية (Proteins and Biological Data)

### : (Analysis)

تُستخدم الرسوم البيانية لتمثيل التفاعلات بين البروتينات والجينات، ودراسة الشبكات الحيوية لفهم الوظائف البيولوجية والتنبؤ بالعلاقات المحتملة بين الجزيئات. (١٢)

## ٢,٢ الذكاء الاصطناعي (Artificial Intelligence)

هو تقنية تحويلية تمكن الآلات من أداء مهام وحل المشكلات بطريقة تشبه البشر. من التعرف على الصور وإنشاء محتوى إبداعي إلى وضع تنبؤات تعتمد على البيانات، يعمل الذكاء الاصطناعي على تمكين الشركات من اتخاذ قرارات أكثر ذكاءً على نطاق واسع. (٢)



### الذكاء الاصطناعي (الشكل ١, ٢)

توضيح عملية التزاوج (Crossover) في الخوارزميات الجينية يتحدث عن الذكاء الاصطناعي (Artificial Intelligence)، ويشرح إن الخوارزميات والتقنيات تمكن الحاسوب من محاكاة السلوك البشري واتخاذ القرار وحل المشكلات.

## ٢, ٢, ١ مجالات الذكاء الاصطناعي الأساسية:

### ١- التعلم الآلي (Machine Learning):

هو مجال يركز على تعليم الحاسوب التعلم من البيانات وتحسين أدائه مع مرور الوقت دون الحاجة لبرمجة صريحة لكل مهمة. يُستخدم في التنبؤ، التصنيف، واكتشاف الأنماط في البيانات الكبيرة. (٨)

### ٢- معالجة اللغة الطبيعية (Language Processing Natural):

تمكّن هذه التقنية الحاسوب من فهم اللغة البشرية والتفاعل معها، مثل الترجمة الآلية، تحليل النصوص، والتعرف على الكلام. (١٣)

### ٣- الرؤية الحاسوبية (Computer Vision):

الرؤية الحاسوبية هي فرع من الذكاء الاصطناعي يهدف إلى تمكين الحاسوب من رؤية العالم وفهمه بطريقة مشابهة للعين البشرية أي أنها تتيح للحاسوب التعرف على الصور والفيديوهات وتحليل محتواها، مثل التعرف على الوجه، اكتشاف الأشياء، والمراقبة الآلية. (١٤)

### ٤- التعلم العميق (Deep Learning):

هو فرع من التعلم الآلي يستخدم شبكات عصبية متعددة الطبقات لتمكين الحاسوب من التعرف على الصور، الصوت، والنصوص بطريقة مشابهة لدماغ الإنسان، ويعد أساس العديد من التطبيقات الحديثة في الذكاء الاصطناعي. (١٥)

## ٢,٢,٢ أهمية الـ AI في تحليل البيانات:

لقد أصبح أداة أساسية لمعالجة البيانات الكبيرة والمعقدة، لما يوفره من قدرات عالية على التعلم، التنبؤ، واتخاذ القرارات المبنية على البيانات.

### أولاً / القدرة على التنبؤ (Prediction):

الذكاء الاصطناعي يمكنه تحليل البيانات التاريخية واستنتاج الاتجاهات المستقبلية، مثل التنبؤ بمبيعات المنتجات، التغيرات في سوق الأسهم، أو تطور الأمراض في البيانات البيولوجية. هذا يمكن المؤسسات من التخطيط واتخاذ القرارات الاستراتيجية بشكل أفضل. (٢)

### ثانياً / تصنيف البيانات (Classification):

تصنيف البيانات إلى فئات محددة بدقة عالية، سواء كانت نصوصاً، صوراً، أو أرقامًا. مثال: تصنيف البريد الإلكتروني كرسائل مهمة أو سبام، أو تصنيف المرضى حسب حالة مرضية محددة. (٨)

### ثالثاً / اكتشاف الأنماط المخفية (Pattern Recognition):

القدرة على كشف الأنماط المخفية والمعقدة التي يصعب على البشر اكتشافها، مثل العلاقات بين المتغيرات في شبكات التواصل الاجتماعي، أو التفاعلات بين البروتينات والجينات في البيانات البيولوجية. (١٢)

### ٢,٢,٣ تصنيف البيانات واكتشاف الأنماط المخفية:

الذكاء الاصطناعي مهم جداً في تحليل البيانات لأنه لا يقتصر على قراءة المعلومات فقط، بل يفهمها ويستخلص منها النتائج بسرعة ودقة.

يستطيع التنبؤ بالاتجاهات المستقبلية، يصنف البيانات بأنواع مختلفة، ويكشف عن الأنماط المخفية التي قد لا يتمكن البشر من كشفها بهذا الشكل، يساعد الشركات والباحثين على اتخاذ قرارات أفضل، تحسين الأداء، وتوفير الوقت والجهد في معالجة كميات كبيرة من البيانات. (٨)

### ٢,٣ دمج الذكاء الاصطناعي مع الرسوم البيانية

يهدف دمج الذكاء الاصطناعي مع الرسوم البيانية إلى تحسين قدرة الحاسوب على فهم البيانات المرتبطة ببعضها واكتشاف الأنماط المخفية والعلاقات المعقدة التي قد يصعب على الإنسان ملاحظتها. من خلال هذا الدمج يمكن:

١. التنبؤ بالاتجاهات المستقبلية في الشبكات الكبيرة والمعقدة.
٢. تحسين اتخاذ القرار بناءً على تحليل دقيق للعلاقات بين العقد.
٣. استخراج معلومات قيمة من البيانات البيانية الكبيرة، مثل شبكات التواصل الاجتماعي، شبكات النقل، أو التفاعلات البيولوجية.

هذا الدمج يوفر أداة قوية لمعالجة البيانات المعقدة بطريقة علمية وسريعة، ويزيد من قدرة الباحثين والشركات على الاستفادة من البيانات الكبيرة بشكل فعال. (١٦)

## ٢,٣,١ الطرق المستخدمة في دمج الذكاء الاصطناعي مع الرسوم البيانية

### ١. الشبكات العصبية للرسوم البيانية (GNNs-Neural Network Graph)

هي نوع من الشبكات العصبية المصممة خصيصًا للتعامل مع البيانات على شكل رسوم بيانية، حيث يمكن للحاسوب فهم العلاقة بين العقد والحواف واستخلاص الأنماط المخفية. تُستخدم هذه الشبكات في التعلم واتخاذ القرار على بيانات مترابطة ومعقدة. (١٧)

### ٢. تصنيف العقد (Node Classification):

عملية تصنيف كل نقطة في الرسم البياني بناءً على خصائصها وعلاقتها مع العقد الأخرى. مثل معرفة إذا كان شخص معين في شبكة اجتماعية مؤثر أو عادي. تساعد هذه الطريقة في فهم دور كل عنصر في الشبكة وتحليل هيكل العلاقات. (١٨)

### ٣. التنبؤ بالعلاقات (Link Prediction):

تهدف إلى توقع العلاقات الجديدة التي قد تظهر بين العقد في المستقبل. مثل التنبؤ بمن قد يصبح صديقًا لشخص معين في شبكة اجتماعية. تستخدم هذه الطريقة لتحليل ديناميكية الشبكات والتوقع بالمستقبل بناءً على الأنماط الحالية. (١٩)

### ٤. تمثيل البيانات البيانية (Graph Embedding):

يُعد تقنية أساسية في تحليل الشبكات، وتتلخص فكرتها في الآتي:  
هي عملية تحويل العقد (Nodes) والحواف (Edges) المكونة للرسم البياني إلى أرقام أو تمثيلات رقمية (متجهات)، وذلك لكي يتمكن الحاسوب والذكاء الاصطناعي من التعامل معها بسهولة.

#### أهم خصائص ومميزات هذه العملية:

- **سهولة المعالجة:** تحويل البنية البيانية المعقدة إلى صيغة رقمية يسمح للخوارزميات بمعالجتها وتحليلها تقنياً.
- **الحفاظ على البنية:** يتم هذا التحويل مع الحرص على الحفاظ على العلاقات الأساسية والأنماط الهيكلية الموجودة أصلاً في الشبكة.
- **مثال توضيحي:** يمكن من خلال هذه التقنية تحويل شبكة معقدة من الأصدقاء في موقع تواصل اجتماعي إلى مجموعة من الأرقام، مما يسهل على الحاسوب التعرف على الأنماط والعلاقات الخفية بين هؤلاء الأشخاص. (٢٠)

## ٢,٣,٢ تطبيقات الذكاء الاصطناعي على الخوارزميات البيانية

### ١. تحليل الشبكات الاجتماعية والتنبؤ بالعلاقات المستقبلية:

يتم دراسة العلاقات بين الأفراد في الشبكات الاجتماعية (مثل فيسبوك أو تويتر) وتحليل التفاعلات الحالية، للتنبؤ بمن قد يتواصل مع من في المستقبل. تساعد هذه الطريقة في فهم التأثير الاجتماعي، تحديد الأشخاص المؤثرين، وتحليل المجتمعات داخل الشبكة. (٢١)

### ٢. اكتشاف الشبكات الاحتمالية في المعاملات المالية:

يُستخدم تحليل البيانات البيانية لكشف الأنماط الغريبة في معاملات البنوك أو البطاقات الائتمانية، مما يساعد في اكتشاف عمليات الاحتيال قبل حدوثها، وحماية المؤسسات والعملاء من المخاطر المالية. (٢٢)

### ٣. تحسين شبكات النقل والتنبؤ بحركة المرور:

يُستخدم تحليل الرسوم البيانية لفهم الطرق، حركة السيارات، وتحديد نقاط الزحام، مما يساعد على:

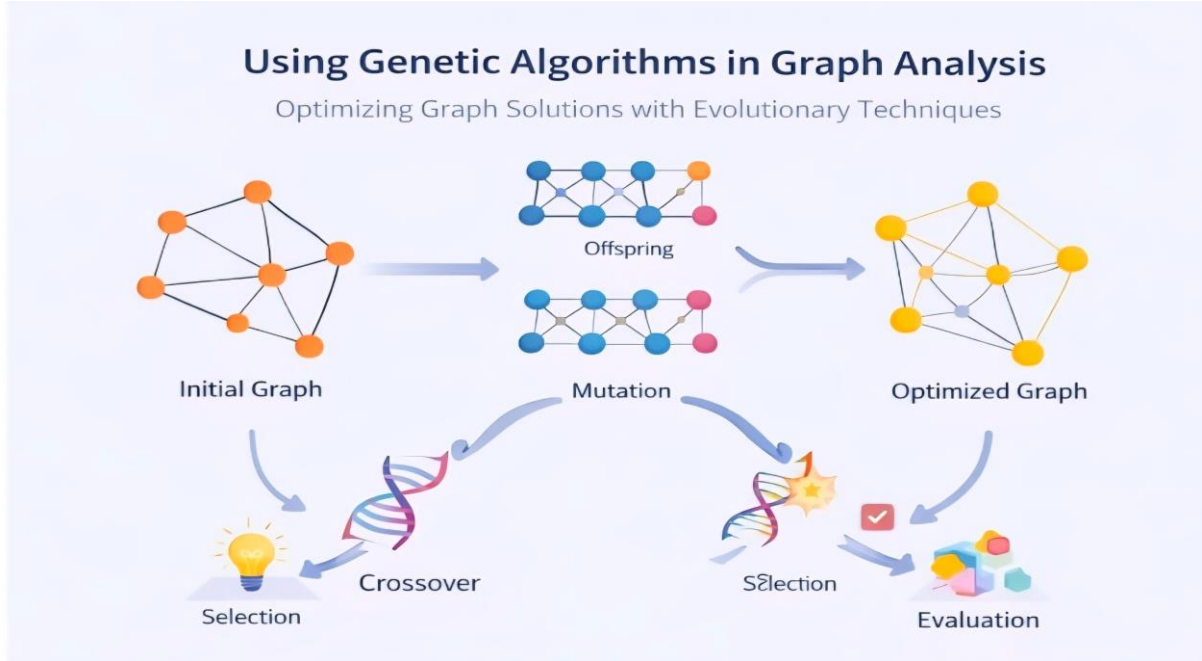
- تخطيط طرق جديدة.
  - تحسين توقيت الإشارات المرورية.
  - تقليل وقت الانتظار والزحام.
  - تحليل البيانات البيولوجية والجزئية. (٢٣)
- تُستخدم الرسوم البيانية لتمثيل العلاقات بين الجينات والبروتينات، مما يساعد على:
- فهم التفاعلات الحيوية المعقدة.
  - اكتشاف الأنماط المخفية في البيانات البيولوجية.
  - تطوير أدوية جديدة بسرعة أكبر وبفعالية أعلى. (٢٤)

## الفصل الثالث

### استخدام الخوارزميات الجينية في تحليل الرسوم البيانية

#### ٣,١ مقدمة

الخوارزميات الجينية (GAs - Genetic Algorithms) هي أسلوب من أساليب الذكاء الاصطناعي يحاكي طريقة التطور الطبيعي عند الكائنات الحية. تعمل من خلال توليد مجموعة من الحلول المحتملة، ثم اختيار الأفضل منها وتطويرها تدريجيًا باستخدام عمليات مثل التهجين والطفرات. تُستخدم هذه الخوارزميات لحل المشكلات المعقدة، خصوصًا مسائل التحسين التوافقي (Combinatorial Optimization)، حيث يكون عدد الحلول كبيرًا جدًا ويصعب الوصول إلى الحل الأمثل بالطرق التقليدية، مثل جدولة المهام أو اختيار أفضل مسار أو توزيع الموارد (٣)



استخدام الخوارزميات الجينية في تحسين الرسوم البيانية (الشكل ٣,٢)

توضح الصورة استخدام الخوارزميات الجينية لتحسين الرسوم البيانية من خلال إنشاء حلول متعددة، ثم تطويرها عبر التهجين والطفرات واختيار الأفضل منها. تتكرر العملية حتى يتم الوصول إلى أفضل حل ممكن ستخدم هذه الطريقة في تحسين الشبكات وإيجاد حلول فعالة للمشكلات المعقدة

## ٣,٢ عمل الخوارزميات الجينية في تحليل الرسوم البيانية

١. توليد مجموعة من الحلول المحتملة (Population):

تبدأ الخوارزمية بمجموعة من الحلول العشوائية للمشكلة.

٢. تقييم الحلول (Fitness Evaluation):

يُقيم كل حل وفق معيار محدد لقياس مدى كفاءته أو ملاءمته للمشكلة.

٣. الاختيار (Selection):

يتم اختيار أفضل الحلول للتكاثر، مستنداً إلى درجة الكفاءة.

٤. التهجين والطفرات (Crossover & Mutation):

تُدمج بعض الحلول لإنشاء حلول جديدة (تهجين) أو تُعدّل جزئياً لتوليد تنوع إضافي (طفرات)، بهدف تحسين الحلول تدريجياً. (٣)

## ٣,٤ استخدام الخوارزميات الجينية في تحليل الرسوم البيانية

تُستخدم الخوارزميات الجينية لحل المشكلات المعقدة، خاصة مسائل التحسين التوافقي (Combinatorial Optimization)، حيث يكون عدد الحلول كبيراً جداً ويصعب الوصول للحل الأمثل بالطرق التقليدية، مثل:

١. جدولة المهام (Scheduling Task).

٢. اختيار أفضل مسار (Shortest Path).

٣. توزيع الموارد بشكل مثالي. (٢٥)

## ٣,٥ الأساس النظري للخوارزميات الجينية

المبدأ الأساسي: تعتمد الخوارزميات الجينية على تمثيل الحلول المحتملة على شكل كروموسومات، ثم تطويرها تدريجياً باستخدام عمليات أساسية تهدف للوصول للحل الأمثل، وهذه العمليات هي:

### ١. الاختيار (Selection):

هي مرحلة يتم فيها اختيار أفضل الحلول من بين مجموعة من الحلول المتاحة، اعتماداً على مدى قربها من تحقيق الهدف المطلوب تمنح الحلول ذات الأداء الأفضل فرصة أكبر للاستمرار والتكاثر في الجيل التالي.

### ٢. التزاوج (Crossover):

تعتمد هذه العملية على دمج أجزاء من حلين أو أكثر من الحلول المختارة، بهدف إنتاج حلول جديدة تجمع خصائص جيدة من الحلول الأصلية، مما يساعد على تحسين جودة الحلول في الأجيال اللاحقة.

### ٣. الطفرة (Mutation):

هي عملية إدخال تغييرات عشوائية وبسيطة على بعض الحلول، وذلك للحفاظ على التنوع داخل المجتمع ومنع الخوارزمية من الوقوع في حالة الركود أو التكرار.

### ٤. دالة التقييم (Fitness Function):

هي معيار يُستخدم لقياس جودة كل حل، حيث تحدد مدى ملاءمته لتحقيق الهدف المحدد. كلما كانت قيمة دالة التقييم أعلى، دلّ ذلك على أن الحل أفضل وأكثر كفاءة. (٣)

## ٣,٦ تطبيق الخوارزميات الجينية على الرسوم البيانية

الخوارزميات الجينية تُستخدم لحل المشكلات المعقدة المتعلقة بالرسوم البيانية، خاصة عندما يكون عدد الحلول المحتملة كبيراً جداً ولا يمكن معالجتها بالطرق التقليدية. الهدف الأساسي هو تحسين الأداء واكتشاف الحلول المثلى أو القريبة من المثالية لمشاكل مثل:

### ١- تحسين المسارات (Graph Path Optimization):

- إيجاد أقصر طريق بين العقد.
- تطبيق في شبكات النقل لتقليل وقت الرحلة، وشبكات الإنترنت لتحديد أسرع مسار لنقل البيانات.

### ٢- تلوين الرسوم البيانية (Graph Coloring):

- تعيين ألوان لكل عقدة بحيث لا تتشارك العقد المرتبطة نفس اللون.
- يستخدم في جداول الحصص الدراسية، تخصيص الموارد، أو توزيع الترددات في الشبكات اللاسلكية.

### ٣- تجميع العقد (Graph Clustering):

- تقسيم العقد إلى مجموعات متجانسة بحيث تكون العقد داخل كل مجموعة متقاربة في العلاقات.
- يستخدم في تحليل الشبكات الاجتماعية لتحديد المجتمعات، تحسين استراتيجيات التسويق، أو دراسة التفاعلات داخل الشبكة.

### ٤- تحديد العقد المهمة (Node Ranking/Selection):

- اختيار العقد الأكثر تأثيراً في الشبكة بناءً على معايير معينة.
- مفيد في شبكات التواصل الاجتماعي لتحديد المؤثرين ومكافحة انتشار المعلومات الخاطئة أو تحسين توزيع الموارد. (٣)

## ٣,٧ مميزات استخدام الخوارزميات الجينية

الخوارزميات الجينية تتميز بقدرتها على حل المشكلات المعقدة بشكل فعال، حيث تجمع بين القوة الحسابية والذكاء الاصطناعي المستوحى من الطبيعة. تتيح هذه الخوارزميات البحث عن الحلول الأمثل أو القريبة منها بطريقة تدريجية ومرنة، مما يجعلها مناسبة لمجموعة واسعة من التطبيقات في الرسوم البيانية، شبكات النقل، الشبكات الاجتماعية، وغيرها. تتكامل الخوارزميات الجينية بسهولة مع تقنيات أخرى، مثل الشبكات العصبية أو خوارزميات التحسين الحديثة، مما يزيد من كفاءتها ودقتها. كما أنها تقلل الوقت والجهد المطلوبين للوصول إلى الحلول مقارنة بالطرق التقليدية، وتتعامل بكفاءة مع المشكلات التي تحتوي على عدد كبير من المتغيرات والحلول الممكنة. باختصار، مميزات الخوارزميات الجينية تجعلها أداة قوية وموثوقة للباحثين والمهندسين لمعالجة المشكلات المعقدة وتحقيق أفضل النتائج الممكنة.

وباختصار يمكن ذكر مميزات الاستخدام كالتالي:

- ١- القدرة على التعامل مع مشاكل التحسين الكبيرة والمعقدة تتميز الخوارزميات الجينية بقدرتها على معالجة المشاكل التي تحتوي على عدد كبير من المتغيرات والحلول الممكنة، والتي يصعب أو يستحيل حلها باستخدام الطرق التقليدية. فهي تبحث عن الحلول بشكل تدريجي وذكي دون الحاجة إلى تجربة جميع الاحتمالات.
- ٢- المرونة العالية وإمكانية دمجها مع تقنيات أخرى تتمتع الخوارزميات الجينية بمرونة كبيرة، حيث يمكن دمجها مع تقنيات أخرى مثل الشبكات العصبية أو الخوارزميات الذكية المختلفة، مما يساعد على تحسين الأداء والحصول على نتائج أكثر كفاءة ودقة.
- ٣- تحسين الكفاءة والدقة مقارنة بالطرق التقليدية تسهم الخوارزميات الجينية في الوصول إلى حلول جيدة خلال وقت أقل، مع تقليل الجهد الحسابي مقارنة بالطرق التقليدية، كما أنها تساعد في الوصول إلى حلول قريبة جدا من الحل الأمثل حتى في الحالات المعقدة. (٢٦)

## الفصل الرابع

### (الاستنتاجات)

من خلال هذا البحث الذي تناول استخدام الخوارزميات الجينية لإيجاد مجموعة الهيمنة المثلى ودمج تقنيات الذكاء الاصطناعي مع نظرية الرسوم البيانية، تم التوصل إلى مجموعة من الاستنتاجات المهمة، أبرزها:

١. أثبتت الخوارزميات الجينية كفاءتها العالية في معالجة مشكلة مجموعة الهيمنة الدنيا، لاسيما في الرسوم البيانية الكبيرة والمعقدة، مقارنة بالطرق التقليدية.

٢. أظهر دمج الذكاء الاصطناعي مع نظرية الرسوم البيانية قدرة واضحة على تحسين جودة الحلول والوصول إلى نتائج قريبة جداً من الحل الأمثل خلال وقت أقل.

٣. ساهم استخدام مفاهيم مثل الاختيار، التزاوج، والطفرة في تعزيز تنوع الحلول وتقليل احتمالية الوقوع في الحلول المحلية غير المثلى.

٤. يبين البحث أن الخوارزميات الجينية توفر مرونة عالية تسمح بتكييفها مع أنواع مختلفة من الرسوم البيانية، مما يجعلها أداة فعالة في مسائل التحسين.

٥. أكد البحث أن الاعتماد على الخوارزميات الذكية يمثل اتجاهاً واعداً في حل المسائل المعقدة في نظرية الرسوم البيانية، ويفتح المجال لأبحاث مستقبلية أكثر تطوراً في هذا المجال.

## خاتمة البحث

بهذا نكون قد استعرضنا أهمية الرسوم البيانية ودور الذكاء الاصطناعي في تحليل البيانات، وبيّنا كيفية استخدام الخوارزميات الجينية لحل المشكلات المعقدة وتحسين الأداء. يوضح هذا البحث كيف أن دمج الأساليب الذكية مع البنية البيانية يوفر أدوات قوية لاتخاذ قرارات دقيقة وفعالة في مجالات متنوعة، من الشبكات الاجتماعية إلى النقل والبيانات البيولوجية، مما يمكن الباحثين والممارسين من الاستفادة القصوى من البيانات الكبيرة والمعقدة.

## المصادر

1. **Shuo Wang**, Application of Graph Theory in Social Network Analysis, 2025.
2. **Stuart Russell & Peter Norvig**, Artificial Intelligence A Modern Approach, 2010.
3. **David E. Goldberg**, Genetic Algorithms in Search Optimization and Machine Learning, 1989.
4. **Michael R Grey & David S. Johnson**, Computers and Intractability A Guide to the Theory of NP-Completeness, 1979.
5. **Mark Newman**, Networks: An Introduction, 2010.
6. **Santo Fortunato**, Community Detection in Graphs, 2010.
7. **Douglas B. West**, Introduction to Graph Theory, 2001.
8. **Christopher M. Bishop**, Pattern Recognition and Machine Learning, 2006.
9. **Efraim Turban**, Decision Support and Business Intelligence Systems, 2011.
10. **Jay Yellen & Jonathan L. Gross**, Graph Theory and Its Applications, 2005.
11. **Keith W. Ross & James F. Kurose**, Computer Networking: A Top-Down Approach, 2013.
12. **Albert-László Barabási**, Network Biology: Methods and Applications, 2016.
13. **Daniel Jurafsky & James H. Martin**, Speech and Language Processing, 2020.
14. **Richard Seliski**, Computer Vision: Algorithms and Applications, 2010.
15. **Ian Goodfellow & Yoshua Bengio & Aaron Courville**, Deep Learning, 2016.

16. **Nasrin Shabani**, A Comprehensive Survey on Graph Summarization with Graph Neural Networks, 2023.
17. **Xingyu Liu & Juan Chen**, A Survey on Graph Classification and Link Prediction based on GNN, 2023.
18. **Asmaa M. Mahmoud, Abeer S. Desuky & Heba F. Eid**, An Overview and Evaluation on Graph Neural Networks for Node Classification, 2024.
19. **Xiaolong Deng, Jufeng Sun & Junwen Lu**, Graph Neural Network-Based Efficient Subgraph Embedding Method for Link Prediction, 2023.
20. S. Khoshraftar, A Survey on Graph Representation Learning Methods, 2024.
21. **Muhammad Ali Khan**, GRAPH THEORY APPLICATIONS IN AI FOR SOCIAL NETWORK ANALYSIS, 2025.
22. **Sri Sai Krishna Mukkamala**, I. Powered Based Fraud Detection Using Graph Neural Network for Mobile Payment System, 2026.
23. **Ruonan Wang**, Network Traffic Analysis Based on Graph Neural Network, 2025.
24. W. Wang & H. Zhou, Graph Neural Network for Protein-Protein Interaction Prediction: A Comparative Study, 2022.
25. **Melanie Mitchell**, An Introduction to Genetic Algorithms, 1998.
26. **Deep et al.**, Hybrid Genetic Algorithms for Optimization, 2019.

"ختامًا، نرجو أن يكون هذا البحث قد حقق أهدافه وساهم في فهم الموضوع بشكل أفضل."