مجلة جامعة طرطوس للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (10) العدد (9) 2026
Tartous University Journal for Research and Scientific Studies - engineering Sciences Series Vol. (10) No. (9) 2026

استخدام ذكاء الأسراب لتحسين أداء الشبكات الخصومية التوالدية

د.م جعفر سلمان *

د. م راغب طعمه **

م. نور علي سليمان ***

(تاريخ الإيداع 2026/2/19 . قُبِل للنشر في 2026/5/13)

□ ملخّص □

تعدّ شبكات الخصومة التوالدية (GAN) واحدة من أبرز التقنيات الحديثة في مجال التعلم العميق والذكاء الاصطناعي، وتعتبر مكون أساسي في بنية أنظمة التطبيقات الحوارية Chat–gpt. تهدف هذه الشبكات إلى توليد نماذج جديدة

ومبتكرة مثل الصور والصوت والنصوص وغيره بناءً على بيانات تدريب متاحة.

تواجه شبكات الخصومة التوالدية تحديات عديدة تعيق العمل ومن أبرز هذه التحديات هي الدقة المرتبطة بحجم الفضاء الضخم للحلول الممكنة، مما يجعل عملية البحث عن الحل الأمثل تستغرق وقتًا طويلًا بالإضافة إلى الدقة المرتبطة بتوليد حلول ونماذج مطابقة للهدف المرغوب في التطبيقات الحوارية.

في بحثنا هذا قدمنا نموذجاً مقترحاً يستخدم خوارزميات ذكاء الأسراب لتعزيز أداء الشبكات الخصومية التوالدية في التطبيقات الحوارية من خلال تقليل فضاء الحلول الممكنة للوصول إلى حل أمثل أكثر مطابقة للهدف المرغوب وتقليل الوقت المستغرق. قدم هذا النموذج المقترح تحسيناً في دقة الإجابات الناتجة بنسبة 33% مقارنة باستخدام الشبكات الخصومية التوالدية دون استخدام ذكاء الأسراب.

الكلمات المفتاحية:

التطبيقات الحوارية– الشبكات الخصومية التوالدية GAN– ذكاء الأسراب – المولد – المميز

* أستاذ مساعد في كلية هندسة تكنولوجيا المعلومات والاتصالات – قسم هندسة تكنولوجيا المعلومات

** أستاذ مساعد في كلية هندسة تكنولوجيا المعلومات والاتصالات –قسم هندسة تكنولوجيا المعلومات

*** طالبة دكتوراه في كلية هندسة تكنولوجيا المعلومات والاتصالات– قسم هندسة تكنولوجيا المعلومات

مجلة جامعة طرطوس للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (10) العدد (9) 2026
Tartous University Journal for Research and Scientific Studies - engineering Sciences Series Vol. (10) No. (9) 2026

Using swarm intelligence to improve the performance of generative adversarial networks

Dr-Eng Jaafar Salman*
Dr-Eng Ragheb Tomeh**
Eng-Nour Souliman***

(Received 19/2/2026. Accepted 13/5/2026)

□ **ABSTRACT** □

Generative Adversarial Networks (GANs) are a key technology in deep learning and artificial intelligence, forming an essential part of systems like ChatGPT. They generate new content—including images, audio, and text—by learning from existing data. Despite their capabilities, GANs face challenges, particularly due to the vast solution space, which makes finding optimal outputs time-consuming and hinders accurate generation of desired results. This is especially critical in chat applications, where precision and relevance are essential.This research proposes a model that integrates swarm intelligence algorithms with GANs to improve performance in chat systems. By guiding the search and reducing the number of potential solutions, the model enhances the accuracy and efficiency of output generation. Implementing this approach resulted in a 33% increase in accuracy compared to traditional GANs, demonstrating its effectiveness in producing more precise, targeted, and timely responses in conversational AI applications.

key words: Dialogical applications - generative adversarial networks - swarm intelligence - generator – discriminator

***Assistant Professor, Faculty of Information and Communication Technology Engineering – Department of Information Technology Engineering
**** Assistant Professor, Faculty of Information and Communication Technology Engineering – Department of Information Technology Engineering
***** PhD Candidate, Faculty of Information and Communication Technology Engineering – Department of Information Technology Engineering

1-مقدمة:

في العقود الأخيرة، شهد حقل الذكاء الاصطناعي تطوراً متسارعاً تجسد في ظهور نماذج متقدمة للتعلم العميق، أبرزها الشبكات الخصومية التوليدية التي أسست لنمط ثوري في توليد البيانات التركيبية عبر آلية تنافسية بين شبكتين: مولّد يتمثل دوره في إنشاء بيانات محاكية للبيانات الأصلية، ومُمَيِّز يهدف إلى فرز البيانات الحقيقية عن التركيبية (De Souza et al., 2023)، وعلى الرغم من النجاحات الملفتة التي حققتها هذه الشبكات في مجالات توليد الوسائط المتعددة كالصور والفيديو، فإن تطبيقها في نطاق الأنظمة الحوارية ما يزال يواجه إشكاليات جوهرية، أبرزها عدم كفاية منهجيات التدريب التقليدية القائمة على مجموعات بيانات عامة واسعة النطاق، والتي قد لا تتماشى مع السياق الدقيق لاستفسار المستخدم، مما يؤدي إلى توليد ردودٍ قد تكون متماسكة نحويًا ولكنها تفتقر إلى الدلالة الصحيحة أو الملاءمة العملية (Saxena et al., 2021).

لمواجهة تحدي دقة النماذج الحوارية، يقدم هذا البحث منهجية تقوم على تحسين المدخلات الأولية للمولد في الشبكات الخصومية التوليدية. تعتمد المنهجية على توظيف خوارزميات ذكاء الأسراب والجينية والنمل والنحل لاستخلاص مدخلات محسّنة من فضاء حلول مبني حول استفسار المستخدم، بدلاً من العينات العشوائية. ما يميز هذا التوجه أيضًا هو أنه يضع المستخدم في قلب العملية التدريبية. فبدلًا من أن تتدرب الشبكة على بيانات عامة أو غير مخصصة، فإنها تبدأ من سؤال المستخدم نفسه باعتباره "المجتمع الأولي" للحلول.

1-1 الدراسات المرجعية:

عالجت الدراسة التي أجراها (Chen et al., 2021) تحدي تدريب GANs بندرة البيانات عبر منهجية ابتكارية تستخدم مفهوم "تذكرة اليانصيب". تقوم الآلية على تقليم أوزان المولد والمميز وإعادة تدريب البنية الفرعية من نقطة مبكرة، وليس من الصفر. أظهرت النتائج تفوق هذه الطريقة على أساليب زيادة البيانات التقليدية، محققة أداءً مكافئاً بنماذج أخف. خلصت الدراسة إلى أن تحسين البنية الداخلية أكثر فعالية من توسيع البيانات لتدريب مستقر في بيئات البيانات المحدودة.

تناول (Li et al., 2022) نموذج EID-GAN لتوليد عينات صناعية عالية الجودة للفئة الأقلية في بيانات شديدة الاختلال. يعتمد النموذج على إطار شبه خاضع للإشراف يدمج GAN شرطية مع مُعرِّف تلقائي تفاضلي، عبر مرحلتين: توليد عينات جديدة بناءً على سمات مستخلصة، ثم إعادة بنائها لضمان واقعيتها. أظهرت النتائج على بيانات المحركات والأعطال تفوق EID-GAN على النماذج الأخرى، محسناً دقة واستدعاء خوارزميات التصنيف. خلصت الدراسة إلى أن هذا النموذج يقدم حلاً فعالاً لاختلال البيانات الصناعية، معززاً موثوقية أنظمة التشخيص الذكية.

قدم (Rout et al., 2021) إطارًا جديدًا لتوليد البيانات يعتمد على خرائط النقل الأمثل، ويختلف جوهريًا عن GANs. تعتمد الآلية على تعلم خريطة برينر، وهي تحويل حتمي ينقل عينات من توزيع بسيط إلى التوزيع المستهدف عبر شبكات عصبية قابلة للتفاضل، دون تدريب خصومي. أظهرت النتائج على MNIST قدرة الطريقة على توليد عينات واقعية ومتنوعة مع استقرار تدريب متفوق وتجنب الانهيار النمطي. خلصت

الدراسة إلى أن النمذجة القائمة على النقل الأمثل تقدم بديلاً نظيفًا وفعالاً، مع إمكانيات للتوسع لأبعاد عالية وتطبيقات قابلة للتفسير.

قدم (Ahmad et al., 2022) إطارًا تكيفيًا لتعلم دوال الخسارة ديناميكيًا لكل مهمة تدريبية، بدلاً من الدوال الثابتة. تدمج الآلية بين التعلم المعزز (RL) والتعلم الفوقي (Meta-Learning)، حيث يستكشف وكيل RL دوال خسارة متنوعة، ويتكيف النموذج معها بسرعة عبر التعلم الفوقي. أظهرت النتائج على بيانات صورية وتتابعية تسريع التقارب، وتحسين استقرار التدريب، ورفع جودة المخرجات مقارنة بالطرق القياسية. خلصت الدراسة إلى أن جعل دالة الخسارة قابلة للتعلم يمثل نقلة نوعية لتدريب النماذج التوليدية، مع أداء قوي وقابل للتعميم.

نلاحظ أن معظم الدراسات السابقة اعتمدت على توظيف خوارزميات الذكاء الاصطناعي لتحسين معلمات التدريب أو معالجة مشكلة التوازن في البيانات، حيث انصب تركيزها على تطوير آليات داخلية للنموذج فقط. أما في بحثنا، فقد اتخذنا منحى مغايرًا يقوم على إشراك المستخدم نفسه في عملية التدريب، إذ ننطلق من سؤاله ليكون نقطة البداية التي تُوجه الخوارزميات نحو بناء المجتمع المحلي للحلول واستخلاص الحل الأمثل استنادًا إلى مدخله. ومن ثم يتم تزويد الشبكة بهذه المخرجات كدخل أي قدمنا طبقة دخل محسنة إلى لبنية الشبكة الخصومية التوليدية لتوليد حلول مشابهة وأكثر توافقًا مع احتياجات المستخدم الفعلية، وهو ما يشكل الفجوة التي نعالجها مقارنة بالاتجاهات السابقة.

1-2 مشكلة البحث:

تتجلّى الإشكالية الأساسية لهذا البحث في التحدي الدقيق لتطبيق الشبكات الخصومية التوليدية على الأنظمة الحوارية، حيث لا يكفي ضمان الصحة النحوية أو المنطقية الشكلية للاستجابة، بل يجب تحقيق الملاءمة السياقية والإقناع الوظيفي للمستخدم. غالبًا ما تعاني النماذج الحالية من اعتمادها على قواعد بيانات عامة لا تتماشى مع نية المستخدم أو السياق المحدد، مما ينتج ردودًا تبدو سليمةً ظاهريًا لكنها تفتقر إلى الدقة العميقة والارتباط بالموضوع.

يعود جوهر هذه المشكلة إلى فجوة التصميم في مرحلة الإدخال، حيث تُقدَّم البيانات للمولِّد دون فلترة أو تحسين مسبق، وهو قصور لا يمكن تعويضه بشكل كافٍ من خلال تحسين بارامترات التدريب التقليدية. للتغلب على هذه القيود، يقترح هذا البحث مدخلاً منهجيًا مبتكرًا يقوم على توظيف خوارزميات تحسين مستوحاة من الطبيعة (النمل، النحل، الجينية، الأسراب) كمكونات وظيفية تسبق عملية التوليد وتوجهها.

1-3 أهمية البحث:

يكتسب هذا البحث أهميته من كونه يتصدى لتحدٍ جوهري في مجال الذكاء الاصطناعي التوليدي، يتمثل في ضعف دقة الأنظمة الحوارية عند التعامل مع سياقات معقدة، على الرغم من التقدم الكبير في نماذج التعلم العميق الأساسية (De Souza et al., 2023). فبينما أثبتت النماذج الحالية كفاءتها في التعامل مع البيانات العامة، إلا أنها غالباً ما تنتج استجابات عامة أو منحرفة عن الهدف المحدد لاستفسار المستخدم. ينطلق البحث من فرضية أن تحسين جودة المدخلات هو مفتاح الحل، ويقدم منهجية هيكلية فريدة تدمج خوارزميات البحث والانتقاء المستوحاة من الطبيعة داخل بنية الشبكات الخصومية التوليدية (GANs) ذاتها..

1-4 أهداف البحث:

يهدف هذا البحث إلى ما يلي:

- اقتراح وتصميم منهجية هجينة تدمج خوارزميات التحسين المستوحاة من الطبيعة (الجينية، النمل، النحل، الأسراب) في البنية التحضيرية لمدخلات الشبكات الخصومية التوليدية، لتعزيز كفاءتها في التطبيقات الحوارية.
- إجراء دراسة تحليلية تجريبية لفعالية كل خوارزمية في هذا الإطار الهجين، بناءً على مقاييس أداء كمية تشمل الدقة، وسرعة التقارب، والقدرة على تجنب الحلول المحلية شبه المثلى.
- تطبيق خوارزمية التصنيف K-Means على المدخلات المُحسَّنة الناتجة عن خوارزميات التحسين المستوحاة من الطبيعة، بهدف تحقيق تمييز دقيق للمدخلات وانتقاء الأفراد الأكثر قرباً من الهدف (الحل الأمثل) لتشكيل مجموعة تدريبية عالية الجودة تُقدَّم كمدخلات للشبكة الخصومية التوليدية، مما يسهم في رفع كفاءة عملية التدريب وجودة المخرجات.

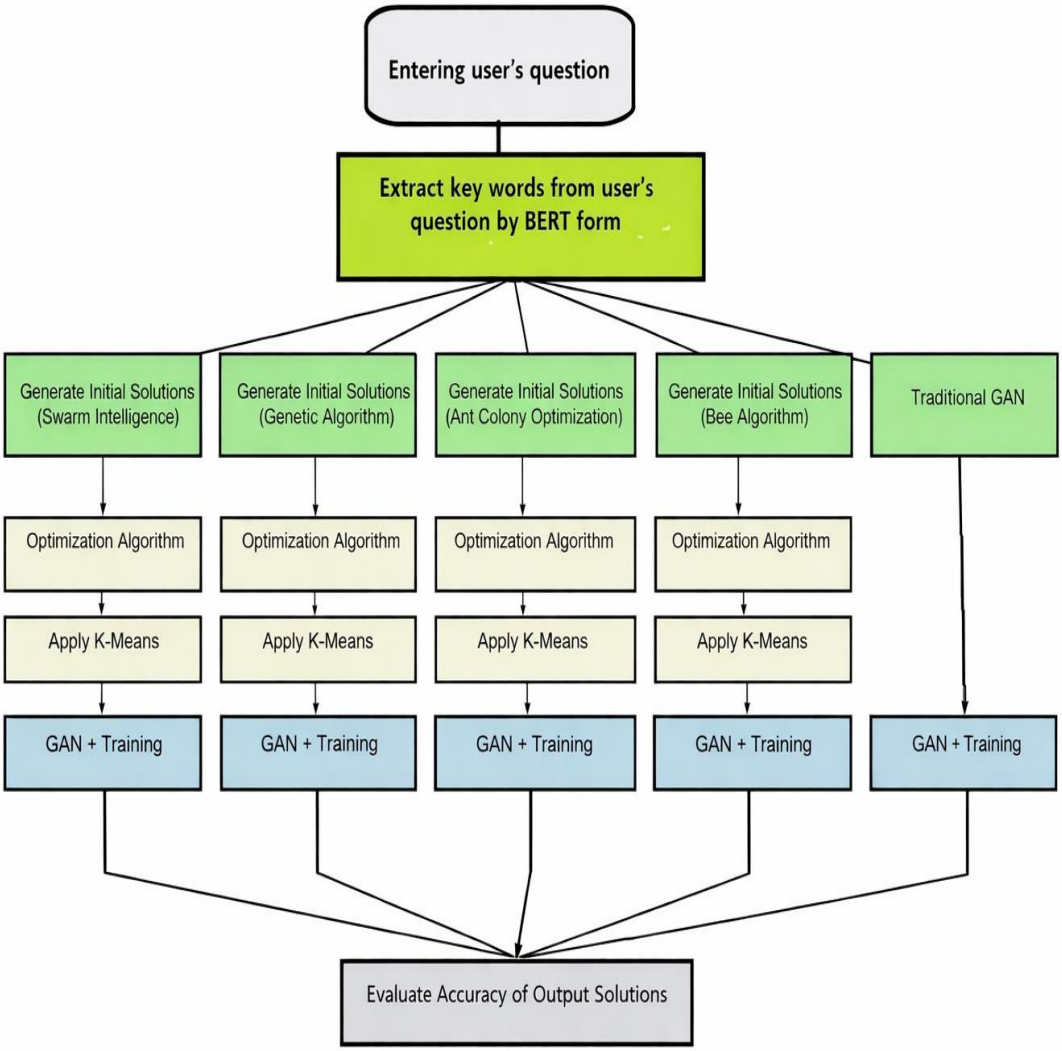
2-طرائق البحث وأدواته:

اعتمد هذا البحث على منهج تحليلي-تجريبي مقارن، حيث تم تصميم إطار تجريبي لتقييم تأثير دمج خوارزميات التحسين المستوحاة من الطبيعة مع خوارزمية التصنيف K-Means في تهيئة مدخلات الشبكات الخصومية التوليدية، بهدف اختبار فعاليتها عملياً في تحسين كفاءة الشبكة لتوليد مخرجات ذات اتساق دلالي وارتباط بسياق المستخدم. وقد جرى تنفيذ المنهج من خلال دمج كل خوارزمية على حدة مع K-Means كمدخل للشبكة، وإجراء مقارنة تحليلية شاملة لأدائها من حيث قدرتها على تحقيق الدقة في الاستجابة المتولدة. وتمثلت الأدوات البحثية الرئيسية في الخوارزميات التالية:

- الخوارزمية الجينية التي تستند إلى مبادئ الانتخاب الطبيعي وعلم الوراثة، تُستخدم لتوليد وتطوير مجموعة متنوعة وذات جودة عالية من المدخلات الأولية للمولد.
- خوارزمية مستعمرة النمل يتم توظيفها في هذه الدراسة لاكتشاف وترشيح تسلسلات المدخلات التي تشكل "مسارات" مثلى نحو توليد رد دقيق، مما يعزز التوجيه السياقي لعملية التدريب.
- خوارزمية مستعمرة نحل العسل تُستخدم في هذا البحث لضمان تنوع المدخلات المُولَّدة مع ارتباطها القوي بالهدف.
- خوارزمية ذكاء الأسراب تُستخدم لإنشاء مدخلات تتكيف بذكاء مع طبيعة الاستفسار الحواري المتغير.
- خوارزمية التجميع K-Means التي تقوم بتقسيم المدخلات المُحسَّنة الناتجة عن خوارزميات التحسين الأربع إلى مجموعات متميزة، ثم يتم انتقاء العناصر الأكثر قرباً من مراكز هذه المجموعات (الأقرب إلى الحل الأمثل) لتمثيل المدخلات النهائية. يُسهم هذا الإجراء في تحقيق تمييز دقيق للمدخلات وتقليل التشتت والتكرار، مما يضمن تقديم مجموعة تدريبية عالية الجودة ومكثفة للشبكة الخصومية التوليدية.

2-1منهجية البحث:

يوضح (الشكل (1)) منهجية العمل المقترحة ضمن البحث:



الشكل (1) المنهجية المقترحة في البحث

تبدأ المنهجية المقترحة في هذا البحث من سؤال المستخدم كمدخل وحيد، وتتم عبر المراحل التالية:

2-1-1المرحلة 1: الاستخلاص الدلالي والكلمات المفتاحية من سؤال المستخدم باستخدام نموذج BERT

يتم استخراج الكلمات ذات الأعلى وزنًا دلاليًا عبر عملية حسابية متسلسلة تبدأ بتقييم ثلاثي الأبعاد لكل كلمة، يشمل حساب درجة TF-IDF لإبراز الأهمية الإحصائية، واستخلاص أوزان الانتباه وفق نموذج BERT لتحديد الأهمية السياقية، وقياس التشابه الجيبي بين تمثيل الكلمة وتمثيل الجملة لتقييم الانسجام الدلالي. ثم يتم تحويل النتائج إلى نطاق موحد بين 0 و1. ثم تُرتَّب الكلمات تنازلياً حسب هذا الوزن ويتم انتقاء الأعلى منها لتشكيل الكلمات المفتاحية . (Devlin et al., 2019).

2-1-2 المرحلة 2: توليد المجتمع الأولي للحلول

يستخدم البحث تلك الكلمات المفتاحية المستخلصة كنواة لتوليد مجموعة أولية ومتنوعة من الحلول الأولية (الردود المقترحة) عبر أربع خوارزميات ذكاء جماعي مُستوحاة من الطبيعة، تعمل كل منها وفق السيناريوات التالية المقترحة حيث يتم تشكيل فضاء بحثي مصغر عن قاعدة البيانات بناء على النواة الأولية. حيث يتم تطبيق كل سيناريو بشكل منفصل لاختبار أداء كل خوارزمية بمفردها:

2-1-2-1 السيناريو 1: توليد مجموعة الحلول الأولية المحسنة باستخدام خوارزمية ذكاء السرب (Particle Swarm Optimization – PSO)

يتم العمل وفق المعادلة الأساسية التالية (Tang et al., 2021):

$$v_i(t+1) = w\, v_i(t) + c1\, r1\, (pbest_i - x_i(t)) + c2\, r2\, (gbest - x_i(t)) \quad (1)$$

حيث: v_i(t) هي سرعة الجسيم في التكرار الحالي، w: هي وزن القصور الذاتي، c1: معامل التسارع المعرفي، c2: معامل التسارع الاجتماعي، r1,r2: هي أعداد عشوائية بين 0 و1، gbesti: هي أفضل موقع شخصي للجسيم، gbest هو أفضل موقع عام للسرب.x_i(t) : هو الموقع الحالي للجسيم i في الزمن t. في المعادلة (1) يمثل كل جسيم (`x_i`) حلاً أولياً (كرد نصي). تتحرك هذه الجسيمات (تتطور الحلول) في فضاء البحث باتجاه المزيج الأمثل بين أفضل حل وجده الجسيم نفسه (`pbest_i`) وأفضل حل في السرب بأكمله (`gbest`)، حيث تُستخدم متجهات الكلمات المفتاحية كنقطة جذب ابتدائية `gbest` أولي لتوجيه البحث نحو المناطق الدلالية ذات الصلة.

2-1-2-2 السيناريو 2: توليد مجموعة الحلول الأولية المحسنة باستخدام الخوارزمية الجينية (Genetic Algorithm – GA)

يتم استخدام المفاهيم التالية: التقاطع والطفرة مع دالة ملاءمة تستهدف التشابه الدلالي بين الكلمات المفتاحية. حيث يتم تمثيل الحلول كسلاسل جينية (تسلسلات للكلمات أو المفاهيم). يتم تطوير "مجتمع" الحلول عبر عمليات محاكاة بيولوجية وهي التقاطع والطفرة، حيث يُوجه التقاطع بين السلاسل والطفرة العشوائية ضمنها باستخدام قائمة الكلمات المفتاحية لضمان احتفاظ الحلول المتولدة بالمعنى والسياق الأساسي للسؤال الأصلي، بينما تختار دالة الملاءمة الأكثر تشابهاً دلالياً للبقاء والتكاثر.

2-1-2-3 السيناريو 3: توليد مجموعة الحلول الأولية المحسنة باستخدام خوارزمية مستعمرة النمل (Ant Co lony Optimization – ACO)

يتم العمل وفق المعادلة الأساسية لخوارزمية النمل:(Hama Rashid et al., 2021) :

$$p_{ij} = [\tau_{ij}]^{\alpha}\ [\eta_{ij}]^{\beta} / \Sigma([\tau_{ik}]^{\alpha}\ [\eta_{ik}]^{\beta}) \quad (2)$$

في المعادلة (2): `η_ij` تعتمد على الكلمات المفتاحية. p_ij: الاحتمالية التي تختار بها النملة الانتقال من العقدة (الكلمة) الحالية i إلى العقدة j التالية.τ_ij : كمية الفيرومون على الحافة (الرابط) بين العقدة i والعقدة j. يزداد كلما مرت نملات أكثر على هذا المسار، مما يدل على جودته.η_ij : الجاذبية الاسترشادية للانتقال من i إلى j. هنا تكمن الآلية الموجهة بالكلمات المفتاحية.α : معلمة تحكم أهمية الفيرومون (τ). إذا كانت α كبيرة، تتبع النمل المسارات المطروقة بقوة.B : معلمة تحكم أهمية الجاذبية الاسترشادية (η). إذا كانت

β كبيرة، تنجذب النمل بقوة نحو الكلمات المفتاحية مباشرة. المقام Σ(...): مجموع كل الخيارات الممكنة للانتقال من العقدة i إلى جميع العقد المجاورة المحتملة k. وهذا يضمن أن p_ij هو احتمال طبيعي.

يتم تمثيل مساحة الحلول برسم بياني كلمي، حيث تبني كل نملة مساراً باختيار كلمات وفق احتمالية تتأثر بالفيرومون والجاذبية الاسترشادية للكلمات المفتاحية، ثم تُقيّم المسارات ويُحدث الفيرومون لتعزيز الحلول الجيدة، فتتولد حلول مرتبطة دلالياً بالسؤال الأصلي..

2-1-2-4 السيناريو 4: توليد مجموعة الحلول الأولية المحسنة باستخدام خوارزمية مستعمرة النحل (Artificial Bee Colony – ABC)

يتم العمل وفق المعادلة الأساسية التالية:(Kaya et al., 2022) :

$$v_{ij} = x_{ij} + \varphi_{ij} (x_{ij} - x_{kj}) \quad (3)$$

من المعادلة (3):v_ij : الحل الجديد المُقترح (الجين/المُتغير الجديد) للنحلة العامل المُستكشفة. يمثل الموقع الجديد أو القيمة المُحدثة للحل في البعد j. x_ij: الحل الحالي (الجين/المُتغير الحالي) الذي تبحث حوله النحلة العاملة في البعد j. وهو يمثل المكون j من موقع مصدر الغذاء الحالي. x_kj: عنصر من حل آخر عشوائي مُختار من المجتمع. يمثل المكون j من موقع مصدر غذاء آخر (k) مختلف عن i، ويُستخدم لإدخال التنوع والاستكشاف. φ_ij: معامل عشوائي لتعديل حجم الخطوة. هو عدد عشوائي يتم توليده عادةً من توزيع موحد بين [−1, 1] أو [0, 1]. يتحكم في حجم واتجاه التغيير من الحل الحالي نحو الحل الآخر العشوائي.

تبحث نحلات العامل حول الكلمات المفتاحية، تعدل حلولها، وتقيّم جودة الرحيق بالتشابه الدلالي مع السؤال، ثم تكرس المستعمرة نحلاً إضافياً لاستكشاف الحلول الأعلى جودة وتحسينها تدريجياً.

2-1-3 المرحلة 3: تصنيف الحلول وتحديد المجموعة المُثلى

يتم في هذه المرحلة تنظيم الحلول الأولية المُولَّدة وانتقاء أفضل مجموعة منها عبر خطوات متسلسلة:

2-1-3-1 تجميع الحلول المتشابهة باستخدام خوارزمية التجميع K-Means:

تُطبق خوارزمية K-Means لتجميع الحلول بعد تمثيلها عدديًا، حيث تُنسب كل حل لأقرب مركز، ثم تُحدث المراكز حسابيًا، وتتكرر العملية حتى الاستقرار. ويُحدد العدد الأمثل للمجموعات باستخدام طريقة Elbow، باختيار K الذي يلي نقطة الانحدار الحاد في المنحنى تحقيقًا للتوازن بين الدقة والتجزئة. (Hamka et al., 2022).

2-1-3-2حساب قيمة اللياقة المتوسطية لكل مجموعة مُشكَّلة:

تُحسب قيمة اللياقة المتوسطية لكل مجموعة عبر دالة هدف تقيس التشابه الدلالي، والتنوع المعجمي، والطول المناسب. ثم يُقارن متوسطات اللياقة، ويُختار العنقود الأعلى متوسطاً لتمثيل المجموعة المثلى للحلول الواعدة.

2-1-4 المرحلة 4: تدريب الشبكة الخصومية التوليدية (GAN) باستخدام الحلول المُختارة

بعد اختيار الحلول المرشحة، تُدخل إلى الشبكة الخصومية التوليدية (GAN). يُولّد المولد إجابات جديدة تستند إلى هذه الحلول محاكياً السياق، ثم يُقيّم المُميز تلك الإجابات مقارنة بالحقيقية مُقدّماً إشارة تصحيحية. يُدرّب النموذج تبادلياً لـ 50 عصراً، حيث يحاول المولد خداع المُميز بتقليل خسارته وفق الدالة: (4) $LG = -E[\log(D(G(z)))]$، (De Souza et al., 2023).

تستخدم المعادلة (4) لحساب خسارة المولد، حيث يحاول المولد (G) خداع المميز (D) من خلال زيادة القيمة المتوقعة (E) لاحتمال تصنيف المميز لمخرجاته المولدة ((G(z)) على أنها حقيقية ((log(D(G(z))). بجعل الخسارة سالبة، يتم تحفيز المولد على توليد إجابات لا يمكن تمييزها عن الحقيقية.

حيث G(z) هي المخرجات المولدة و D هو المميز. بينما يسعى المُميز لتمييز الحقيقي من المُولّد بتعظيم دقته عبر خسارته وفق الدالة: (5) LD = -E[log(D(x))] - E[log(1-D(G(z)))]. (De Souza et al., 2023).

تستخدم المعادلة (5) لحساب خسارة المُميز، حيث يهدف المميز (D) إلى تعظيم دقة تصنيفه من خلال زيادة القيمة المتوقعة لتحديد البيانات الحقيقية (x) بشكل صحيح (الحد الأول) وفي نفس الوقت تقليل القيمة المتوقعة لتصنيفه للمواد المولدة ((G(z)) على أنها حقيقية (الحد الثاني)، مما يدفعه للتمييز الفعال بين النوعين. تتكرر عملية تحديث المولد والمُميز حتى تحقيق الاستقرار والدقة المطلوبة

3- مناقشة النتائج:

3-1 تشكيل الشبكة الخصومية التوادية:

يتم تدريب النموذج المقترح على مجموعة من مجموعات البيانات المتاحة للعموم والمفتوحة الوصول وهي Common Crawl – Open Repository of Web Crawl Data وdatasets Wikipedia، والتي تشمل نصوصًا واسعة النطاق مأخوذة من مصادر ويب عامة، وبيانات موسوعية منظمة، بالإضافة إلى مجموعات بيانات حوارية مُنسّقة(OpenAI, 2025) . وقد تم اختيار هذه البيانات نظرًا لأهميتها في تحقيق تنوع لغوي ومعرفي واسع، وضمان تغطية شاملة لمجالات متعددة، إلى جانب تعزيز القدرة على فهم السياق وإنتاج استجابات مترابطة ودقيقة.

يناقش البحث أربعة سيناريوهات لتحسين مدخلات الشبكة الخصومية التوليدية (GAN) باستخدام: ذكاء الأسراب، الخوارزمية الجينية، خوارزمية النمل، وخوارزمية نحل العسل، ومقارنتها بالنموذج التقليدي. بُني النموذج المقترح بطبقة إدخال ذات 10 وحدات وReLU، وطبقة إخراج ذات وحدتين وLinear. دُرّبت جميع السيناريوهات لـ 50 حقبة لتوليد ردود حوارية متعددة الأبعاد.

3-2 شرح النتائج:

يتم قياس دقة النموذج المقترح لكل سيناريو وفق المعادلة التالية (Salmanpour et al., 2025):

PDRA = (pdf(R_generated) / pdf(R_reference)) * 100 (6)

من المعادلة (6):PDRA : دقة النسبة الاحتمالية (بالنسبة المئوية %).(pdf(R_generated : قيمة دالة الكثافة الاحتمالية (Probability Density Function) للاستجابة المولَّدة بواسطة النموذج. (pdf(R_reference: قيمة دالة الكثافة الاحتمالية للاستجابة الصحيحة المرجعية (Ground Truth).

تم اختبار دقة النموذج المقترح بناء على عدة أسئلة حوارية تم طرحها على النظام وكانت نتائج أحد الاختبارات كالتالي:

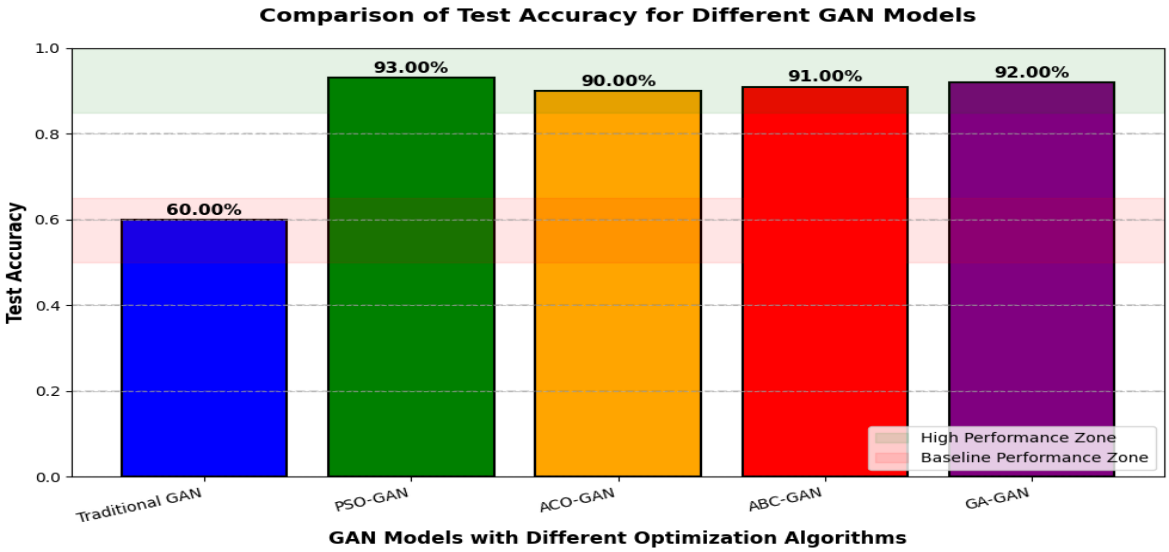
Which type of Arabic poetry achieves the highest quality standards based on meter, rhyme, rhetorical images, and style?

Comparison of Model Responses and Accuracy

Traditional Model	Ant Colony	Bee Colony	Genetic Algorithm	Swarm Intelligence
Modern (Classical)	Pre-Islamic	Contemporary Modern	Pre-Islamic	Pre-Islamic (rules, controls, language)
60%	90%	91%	92%	93%

الشكل (2) مثال تنفيذي للاختبار

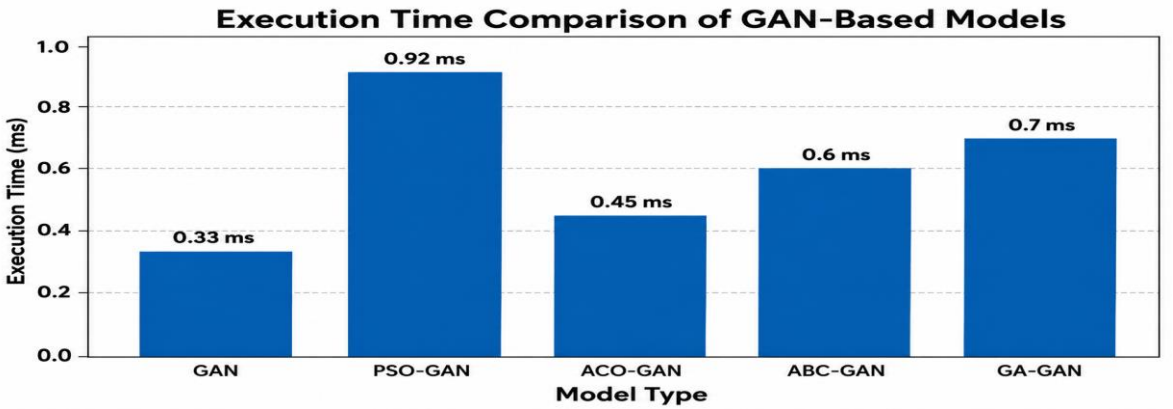
يظهر (الشكل (2)) يظهر الشكل أن النموذج التقليدي دون خوارزميات طبيعية حقق دقة 0.6 بسبب عشوائية التوليد وعدم التوجيه. بالمقابل، تفوق النموذج المدمج مع ذكاء الأسراب في دقة الاستجابة، مما يؤكد أهمية تحسين المدخلات لتقارب الحلول وتقليل التباين.



الشكل (3) دقة أداء النموذج المقترح عند تطبيق الخوارزميات التي تحاكي الطبيعة وبشكل تقليدي دون استخدام تلك الخوارزميات

يُظهر (الشكل (3)) تفاوتاً في أداء خوارزميات التحسين الذكية عند دمجها مع الشبكة الخصومية التوليدية مقارنة بالنموذج التقليدي الذي بلغت دقته 0.60. فقد حققت خوارزمية ذكاء الأسراب دقة 0.93، بنسبة تحسن على النموذج التقليدي بلغت 33%، ويعود ذلك إلى التبادل المعلوماتي المستمر والتعاون الجماعي بين الجسيمات مما يمنع الوقوع في الحلول المحلية. تلتها الخوارزمية الجينية بدقة 0.92 ونسبة تحسن 32% على النموذج التقليدي، مستفيدة

من التهجين والطفرة لتوليد تنوع وراثي. ثم خوارزمية النحل بدقة 0.91 ونسبة تحسن 31% على النموذج التقليدي، بفضل توازنها بين الاستكشاف والاستغلال. وأخيراً خوارزمية النمل بدقة 0.90 ونسبة تحسن 30% على النموذج التقليدي، متأثرة باعتمادها على تراكم الفيرومون التدريجي الذي يبطئ التقارب.



الشكل (4) زمن تنفيذ النموذج المقترح عند تطبيق الخوارزميات التي تحاكي الطبيعة مقارنة مع زمن التنفيذ عند تطبيق النموذج التقليدي المكون من الشبكة الخصومية التوليدية فقط

تُظهر النتائج تبايناً واضحاً في أزمنة التنفيذ، حيث سجل النموذج التقليدي أقل زمن تنفيذ قدره (0.33 ms) لخلوه من طبقات تحسين إضافية. مقابل ذلك، ارتفع زمن خوارزمية النمل إلى 0.45 ms مسبباً تأخير عن النموذج التقليدي بمقدار 0.12 ms بسبب محاكاة المسارات المتعددة وتحديث الفيرومونات التراكمي. بلغ زمن خوارزمية النحل 0.60 ms مسبباً تأخير عن النموذج التقليدي بمقدار 0.27 ms نتيجة تقسيم العمل بين النحل الكشاف (استكشاف) والعامل (استغلال محلي)، مما يستلزم مقارنات وتقييم مستمر. كما سجلت الخوارزمية الجينية زمن تنفيذ قدره 0.70 ms حيث كان مقدار التأخير الزمني عن النموذج التقليدي 0.37 ms لاعتمادها على دورة تطورية كاملة: انتقاء، تهجين، ثم طفرة، مما يولد عبئاً حسابياً. أما خوارزمية ذكاء الأسراب فاحتلت أعلى زمن تنفيذ وقدره (0.92 ms) حيث كان مقدار التأخير عن النموذج التقليدي 0.59 ms ويعود ذلك إلى آليتها التعاونية القائمة على التبادل المستمر للمعلومات بين جميع الجسيمات للتقارب نحو الحل الأمثل العالمي، ما يبرر هذه التكلفة هو تحقيق أعلى دقة (93%).

4-الاستنتاجات والتوصيات:

تثبت هذه الدراسة التأثير البالغ لاستراتيجيات التحسين الخوارزمي على أداء الشبكات الخصومية التوليدية. فالنموذج التقليدي، رغم سرعته (0.33 ms)، أظهر قدرة محدودة على تقديم إجابات دقيقة. في المقابل، حققت الخوارزمية الجينية تحسناً ملحوظاً في الدقة (0.92) بزمن معقول (0.70 ms)، مستفيدة من آليات التطور. أما الذروة فكانت لدمج ذكاء الأسراب مع K-Means، حيث أن التبادل المعلوماتي التعاوني بين الجسيمات قاد إلى أعلى دقة (0.93) رغم ارتفاع زمن التنفيذ (0.92 ms). يوصى باعتماد هذا النموذج الهجين الأمثل لتعزيز الأداء في التطبيقات الحوارية المعقدة.

يوصي هذا البحث بما يلي:

1-تبسيط البنية التقنية وذلك باستخدام دوال برمجية بسيطة وتقنيات أقل تعقيداً لخفض التعقيد الزمني والمعرفي للنظام، وتقليل التكاليف الحسابية مع الحفاظ على الأداء.

2-تحسين كفاءة التجميع وذلك عن طريق اختبار خوارزميات تجميع بديلة لتصنيف الاستجابات الناتجة عن خوارزميات التحسين المحاكية للطبيعة.

3-تطوير معالجة المدخلات وذلك بإجراء معالجة مسبقة لقواعد البيانات وإضافة بارامترات إثرائية (كعلامات سياقية ودلالية) لاستخلاص نوايا المستخدم بدقة قبل التوليد.

4-تحسين تجربة التكامل وذلك بتصميم واجهات ونماذج خفيفة تتيح تكاملاً سلساً مع الأنظمة الحالية وتقلل زمن الاستجابة في التطبيقات الحية.

5-المراجع:

1. AHMAD, B. et al. 2022, *Brain tumor classification using a combination of variational autoencoders and generative adversarial networks*. Biomedicines, Switzerland. Vol.10, N.2, pp 223.
2. ALHIJAWI, B. ; AWAJAN, A. 2024, *Genetic algorithms: Theory, genetic operators, solutions, and applications*. Evolutionary Intelligence, Germany. Vol.17, N.3, pp 1245-1256.
3. CHEN, T. et al. 2021, *Data-efficient gan training beyond (just) augmentations: A lottery ticket perspective*. Advances in Neural Information Processing Systems, U.S.A. Vol.34, pp 20941-20955.
4. DE SOUZA, V.L.T. et al. 2023, *A review on generative adversarial networks for image generation*. Computers & Graphics, U.S.A. Vol.114, pp 13-25.
5. DEVLIN, J. et al. 2019, *Bert: Pre-training of deep bidirectional transformers for language understanding*. Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics, U.S.A. pp 4171-4186.
6. HAMA RASHID, D.N. ; RASHID, T.A.; MIRJALILI, S. 2021, ANA: *ant nesting algorithm for optimizing real-world problems*. Mathematics, Switzerland. Vol.9, N.23, pp 3111.
7. HAMKA, M. ; RAMDHONI, N. 2022, *K-means cluster optimization for potentiality student grouping using elbow method*. AIP Conference Proceedings, U.S.A. Vol.2578, N.1, pp 060011.
8. KAYA, E. et al. 2022, *A review on the studies employing artificial bee colony algorithm to solve combinatorial optimization problems*. Engineering Applications of Artificial Intelligence, U.K. Vol.115, pp 105311.
9. LI, W. et al. 2022, EID-GAN: *Generative adversarial nets for extremely imbalanced data augmentation*. IEEE Transactions on Industrial Informatics, U.S.A. Vol.19, N.3, pp 3208-3218.

10. ROUT, L. ; KOROTIN, A.; BURNAEV, E. 2021, *Generative modeling with optimal transport maps*. arXiv preprint arXiv:2110.02999.

11. SALMANPOUR, M.R. et al. 2025, *Machine learning evaluation metric discrepancies across programming languages and their components in medical imaging domains: need for standardization*. IEEE Access, U.S.A.

12. SAXENA, D. ; CAO, J. 2021, *Generative adversarial networks (GANs) challenges, solutions, and future directions*. ACM Computing Surveys (CSUR), U.S.A. Vol.54, N.3, pp 1-42.

13. TANG, J. ; LIU, G.; PAN, Q. 2021, *A review on representative swarm intelligence algorithms for solving optimization problems: Applications and trends*. IEEE/CAA Journal of Automatica Sinica, U.S.A. Vol.8, N.10, pp 1627-1643.

14. OPENAI. 2025, *How ChatGPT and our foundation models are developed*. 30April2025. https://openai.com/policies/how-chatgpt-and-our-foundation-models-are-developed.