

استخدام ذكاء الأسراب لتحسين أداء الشبكات الخصومية التوافقية

- * د.م جعفر سلمان
** د. م راغب طعمه
*** م. نور علي سليمان

(تاريخ الإيداع ٢٠٢٥/١١/٦ . قُبل للنشر في ٢٠٢٦/١/٢٠)

□ ملخص □

تعدّ شبكات الخصومة التوافقية (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 التوافقية تحديات عديدة تعيق العمل ومن أبرز هذه التحديات هي الدقة المرتبطة بحجم الفضاء الضخم للحلول الممكنة، مما يجعل عملية البحث عن الحل الأمثل تستغرق وقتاً طويلاً 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 التوافقية في التطبيقات الحوارية من خلال تقليل فضاء الحلول الممكنة للوصول إلى حل أمثل أكثر مطابقة للهدف المرغوب وتقليل الوقت المستغرق. قدم هذا النموذج المقترح تحسناً في دقة الإجابات الناتجة بنسبة 33% مقارنة باستخدام الشبكات الخصومية التوافقية دون استخدام ذكاء الأسراب.

الكلمات المفتاحية: التطبيقات الحوارية- الشبكات الخصومية التوافقية 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

Using swarm intelligence to improve the performance of generative adversarial networks

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

(Received 6/11/2025 . Accepted 20/1/2026)

□ 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 ٣٣% 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

١- مقدمة:

تُعَدُّ الشبكات الخصومية التوالدية (GANs) من أبرز الإنجازات في مجال الذكاء الاصطناعي، حيث تمتلك قدرة فريدة على توليد محتوى رقمي واقعي، مما يجعلها أدوات فعالة في التطبيقات الحوارية. فهي تُمكن الأنظمة من إنشاء حوارات طبيعية ومتنوعة، وتحسين تجربة المستخدم من خلال التفاعل الذكي والواقعي، سواء في مجالات خدمة العملاء أو الترفيه أو التعليم. على الرغم من تلك القدرات، تواجه شبكات GAN تحديات كبيرة تتعلق بمحدوديتها في البحث العام وفهم السياق بشكل دقيق. إذ أن نماذج GAN لا تزال تعاني من صعوبة في الفهم العام للسياق، مما يؤدي إلى إنتاج استجابات غير دقيقة أو غير ملائمة أحياناً. مما يهدد دقة التطبيقات الحوارية ويقيد قدرتها على تقديم تفاعلات ذات جودة عالية وموثوقة ويستدعي المزيد من البحث والتطوير لتحسين فهم السياق وتجاوز هذه التحديات التقنية.

تتكوّن الشبكات الخصومية التوالدية (GANs) من مولّد ومميز. تكون مهمة المولد توليد بيانات جديدة تشبه البيانات الأصلية، أما مهمة المميز هي تمييز بيانات المولّد عن البيانات الأصلية. تتنافس هاتين الودحتين مع بعضهما بعض في محاولة تحقيق أداء أفضل ينجح نظام الشبكة الخصومية التوالدية في تحسين أدائه مع مرور الوقت، حيث يتعلم المولّد والمميز من تفاعلها المستمر (GUI, 2021).

إن تطبيقات الشبكات الخصومية التوالدية متنوعة وواسعة النطاق، وتشمل (CHAKRABORTY, 2017): مجال الرؤية الحاسوبية: يمكن استخدام GANs لإنتاج صور واقعية وتحسين جودة الصور الرقمية وتعزيز الفيديو وتنظيم الصور وتعديل الوجه.

- مجال الموسيقى والصوت: يمكن استخدام الشبكات الخصومية التوالدية لتوليد وتحسين المقاطع الموسيقية وتحسين جودة الصوت وتكوين أصوات جديدة.

- مجال الألعاب: يمكن استخدام GANs لإنشاء شخصيات وعوالم افتراضية مفصلة وحقيقية ولإنتاج مستويات لعب جديدة.

- مجالات البيانات والتحليل: يمكن استخدام الشبكات الخصومية التوالدية لتوليد بيانات اصطناعية وتعزيز القدرات التنبؤية وتحسين جودة وتكامل البيانات.

تتيح الشبكات الخصومية التوالدية إمكانية التطوير والابتكار في المجالات المختلفة، وتساهم في تحسين الخدمات المقدمة للمستخدمين وتساهم في تعزيز تجربة المستخدم النهائي في العديد من القطاعات.

١-١ الدراسات المرجعية:

١- تتناول الدراسة (Li,2022) تحسين تدريب الشبكات التنافسية التوليدية (GANs)، التي تتكون من نموذجين: المولد (Generator) لإنشاء بيانات جديدة والمميز (Discriminator) للتحقق من صحتها. تواجه GANs تحديات كبيرة في الاستقرار أثناء التدريب، ما يؤدي إلى نتائج غير دقيقة. قدم الباحثون طريقة "التدريب العدواني المباشر" لزيادة التفاعل بين المولد والمميز، مما يعزز قدرة النموذج على التكيف مع الظروف المتغيرة ويقلل التقلبات. أظهرت التجارب أن الطريقة الجديدة حسنت استقرار التدريب وجودة البيانات المولدة مقارنة بالأساليب التقليدية، مما يجعلها خطوة مهمة نحو تحسين دقة وكفاءة تدريب GANs وتحقيق مخرجات أكثر واقعية.. GANs.

٢- تركز الدراسة (GUPTA,2023) على تحسين دقة التصنيف عبر دمج الشبكات العصبية التلافيفية (CNN) مع الشبكات التنافسية التوليدية (GANs) وتقنيات زيادة البيانات. تُستخدم CNN لاستخراج الميزات، بينما تولد GANs بيانات تدريب إضافية لمعالجة نقص البيانات، ويُطبق زيادة البيانات لتعزيز تنوع مجموعة التدريب. تهدف الدراسة إلى تحسين التعلم والتعميم لنماذج التعلم العميق. أظهرت التجارب أن هذا الإطار المدمج أدى إلى تحسين ملحوظ في دقة التصنيف واستجابة النموذج، ما يعزز فعالية استخدام هذه التقنيات معًا في التطبيقات العملية.

٣- تسلط الدراسة (ZHANG,2024) الضوء على تحسين "لعبة مين-ماكس" في تدريب GANs لضمان عدالة التفاعل بين المولد والمميز. اقترح الباحثون تعديل القيم الحدية (Thresholds) لتقليل عدم التوازن، مما يحسن جودة العينات المنتجة. أظهرت النتائج أن النهج الجديد عزز عدالة التدريب وأدى إلى بيانات أكثر جودة وتنوعًا، مما رفع أداء GANs واستجابته في التطبيقات العملية. الدراسة تمثل خطوة مهمة نحو تعزيز العدالة والكفاءة في أنظمة التعلم التنافسي.

تتميز دراستنا عن الدراسات السابقة في استخدام خوارزمية ذكاء الأسراب لتوليد مجموعة حلول مثلى لتكون دخالاً في شبكات الخصومة التوليدية GANs وتصنيف تلك الحلول ضمن مجموعات واختيار المجموعة التي تحتوي على الحل الأكثر مقاربة للهدف المطلوب ليقوم المولد بتوليد الإجابات للمستخدم انطلاقاً من ذلك الحل.

٢- مشكلة البحث:

تتمحور مشكلة البحث حول ضعف قدرة الشبكات الخصومية التوليدية على فهم السؤال بدقة وتحديد السياق المناسب. تنشأ المشكلة من صياغة الأسئلة الغامضة، وتداخل السياقات وصعوبة تحليل اللغة الطبيعية، بالإضافة إلى تحديات برمجية في معالجة البيانات بسرعة. تحسين الخوارزميات يقلل التعقيد ويزيد دقة وسرعة توليد الإجابات، مما يعزز فعالية الشبكات الحوارية.

٣- أهمية البحث وأهدافه:

يهدف البحث لتحسين أداء الشبكات الخصومية التوليدية باستخدام خوارزمية ذكاء الأسراب لإيجاد الحلول المثلى وتجميعها عبر K-means، مما يقلل البحث العشوائي ويزيد دقة الإجابات. تحاكي الخوارزمية سلوك الأسراب في استكشاف فضاء الحلول الواسع، مما يعزز فرص الوصول للحل الأمثل، ويتجنب الحلول المحلية، مع مرونة عالية وتكيف مع المشكلات المعقدة.

٤- طرائق البحث وأدواته:

تتمثل أدوات البحث فيما يلي:

٤-١ خوارزمية ذكاء الأسراب:

خوارزمية ذكاء الأسراب مستوحاة من سلوك الكائنات الحية الجماعي، مثل أسراب الطيور ومستعمرات النمل، حيث يتعاون أفراد السرب للبحث عن حلول مثلى. تعمل خوارزمية ذكاء الأسراب وفق التتابع التالية (TANG,2021) :
لتحديد سرعة الأفراد ضمن المجموعة نستخدم تابع تحديث السرعة:

$$v_i(t+1) = wv_i(t) + c1r1 \odot (p_i - x_i(t)) + c2r2 \odot (g - x_i(t)) \quad (1)$$

حيث يشير الرمز \odot إلى الضرب العنصري أو الضرب الشعاعي أي أن كل عنصر يُضرب بالعنصر المناظر له في المتجه الآخر، وليس ضرباً متجهياً أو مصفوفياً

لتحديث موقع الأفراد نستخدم تابع تحديث الموقع:

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (2)$$

حيث تشير المعادلة (2) إلى أن موضع الجسم الجديد يُحسب بإضافة سرعته الحالية إلى موضعه السابق، أي أنه يتحرك خطوة مقدارها $v_i(t+1)$ من مكانه السابق $x_i(t)$.

حيث W : هي وزن القصور الذاتي (inertia weight)، c_1, c_2 : معاملات التعلم المعرفي والاجتماعي، $r_1, r_2 \sim U(0,1)$ متجهات عشوائية (عنصر بعنصر)، p_i أفضل موقع شخصي لجسيم i ، g أفضل موقع عالمي.

٤-٢ خوارزمية K-means:

إن خوارزمية K-means هي واحدة من أشهر خوارزميات التعلم غير الموجه المستخدمة في تجميع البيانات إلى مجموعات (Clusters) بناءً على السمات المشتركة بين العناصر (IKOTUN,2023). تعد خوارزمية K-means أداة فعالة في بحثنا لتقسيم فضاء الطول الناتج عن خوارزمية ذكاء الأسراب إلى مجموعات بناءً على تابع الكثافة الاحتمالي لكل حل، ومدى قرابه من الهدف الأمثل. تعمل خوارزمية K-means وفق المعادلة التالية: (IKOTUN,2023)

$$\text{Min}_{\{u_i, c_j\}} J = \sum_{k=1}^K \sum_{x_i \in C_j} \|x_i - \mu_j\|^2 \quad (3)$$

تعبر المعادلة (3) عن أن خوارزمية k-means تبحث عن أفضل تقسيم للبيانات إلى k مجموعات بحيث تُقلل مجموع مربعات المسافات بين كل نقطة أو مركز عنقودها μ_j .

حيث X_i : النقاط في البيانات، C_j مجموعة النقاط المنسوبة للعنقود j ، μ_j : مركز العنقود j

٤-٣ لغة البرمجة بايثون python:

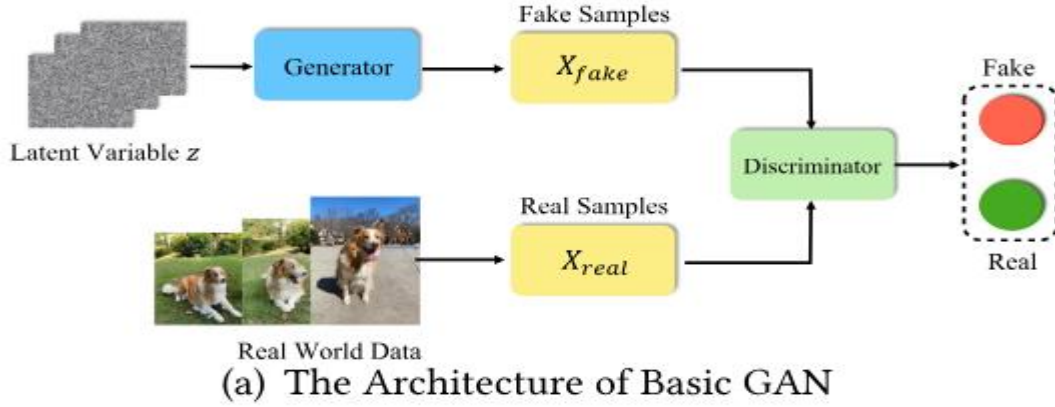
استخدمنا في بحثنا لغة البرمجة Python التي تعتبر أحد أساسيات هذا البحث، لأنها توفر بيئة برمجية قوية ومرنة، بالإضافة إلى أنها ملائمة لتطوير النماذج وتنفيذ خوارزميات الأسراب بفعالية. اعتمدنا على منصة Google Colab باعتباره بيئة مثالية لتنفيذ الأكواد باستخدام بايثون (NAIK,2023).

٤-٤ الشبكة الخصومية التوالدية:

يتم تكوين الشبكة الخصومية التوليدية كالتالي:

٤-٤-١ المولد (Generator):

يتكون المولد من طبقة الدخل تستقبل بيانات مقارنة للحل الأمثل الناتج عن خوارزمية الأسراب، لتشكل نقطة البداية لتوليد نماذج جديدة. الطبقات الخفية تتكون من طبقات كثيفة، النعاف، وتحويل عكسي، مع تفعيل ReLU أو Leaky ReLU لتحسين التعلم. طبقة الخرج تولد بيانات مشابهة للحل الأمثل مع تفعيل Sigmoid لضبط القيم ضمن النطاق المطلوب (CAI,2021). يظهر (الشكل (١)) بنية الشبكة الخصومية التوالدية.



الشكل (١) بنية الشبكة الخصومية التولادية [9]

٢-٤-٤ المميز (Discriminator) :

يتلقى المميز طبقة الدخل البيانات الحقيقية والمولدة، بينما تحتوي الطبقات الخفية على طبقات كثيفة والتفاف مع تفعيل Leaky ReLU لتحسين التعلم، وتنتج طبقة الخرج قيمة احتمالية بواسطة تفعيل Sigmoid لتحديد كون البيانات حقيقية أو مزيفة (CAI,2021) :

٣-٤-٤ دالة التدريب (Training Function)

تعتمد دالة التدريب على هدفين متعارضين حيث أن المولد يحسن توليد بيانات تقارب الحل الأمثل باستخدام دالة $\log(D(G(z)))$ ، حيث تزيد هذه الدالة عندما يستطيع المولد إنتاج عينة $G(z)$ تجعل المميز يعطي احتمالاً عالياً بأنها حقيقية، أي أن المولد يعظم $D(G(z))$ ليقترّب من ١، وبالتالي يقلل المسافة الإحصائية بين التوزيع المولد والتوزيع الحقيقي، بينما يسعى المميز لتمييز البيانات الحقيقية عن المزيفة عبر دالة $\log(D(x)) + \log(1 - D(G(z)))$ (LI,2022) - تزداد هذه الدالة عندما يصنّف المميز البيانات الحقيقية x باحتمال عالٍ (يزيد $D(x)$) ويصنّف البيانات المزيفة $G(z)$ باحتمال منخفض (يقلل $D(G(z))$)، مما يعني رياضياً أنه يعظم احتمال التمييز الصحيح بين التوزيعين الحقيقي والمولد عبر تعظيم دالة الاحتمالية السالبة.

٤-٤-٤ طبقات الدخل والخرج:

إن طبقات الشبكة الخصومية التولادية تشمل: طبقة دخل المولد التي تستقبل بيانات مقارنة للحل الأمثل، وطبقة خرج المولد التي تولد بيانات مشابهة، بينما طبقة دخل المميز تتلقى الحل الأمثل والبيانات المزيفة، وطبقة خرج المميز تحدد احتمالية كون البيانات حقيقية أو مزيفة

٥-٤-٤ حساب دالة الخطأ

إن دالة الخطأ هي $f(x) = -\log(D(x)) + \log(1 - D(G(z)))$ حيث تقوم هذه الدالة بتعظيم احتمال التمييز الصحيح بين التوزيعين الحقيقي والمولد عبر تعظيم دالة الاحتمالية السالبة (LEE,2021) .

٤-٥ طرائق البحث:

يعمل هذا البحث وفق الخطوات التالية:

٤-٥-١ إدخال سؤال المستخدم

يبدأ النظام الحواري بتلقي السؤال أو المشكلة المطلوب حلها من قبل المستخدم، سواء كان استفساراً مباشراً أو مشكلة معقدة تحتاج إلى تحليل. في هذه المرحلة، يقوم النظام بالتعرف على بنية السؤال، واستخراج الكلمات المفتاحية، وتحديد مقصود المستخدم من السياق العام.

٤-٥-٢ تشكيل مجموعة حلول مبدئية

يقوم النظام في هذه الخطوة بإنشاء مجموعة أولية من الحلول المحتملة، والتي تمثل نقاط الانطلاق التي تختبرها الخوارزميات لاحقاً. تكون هذه الحلول عبارة عن استجابات حوارية مختلفة صُممت لتغطي عدة اتجاهات أو احتمالات لمعالجة السؤال،

٤-٥-٣ تطبيق خوارزمية ذكاء الأسراب لتحديد الحل المثلى

تُطبَّق خوارزمية ذكاء الأسراب بعد توليد مجموعة الحلول المبدئية بهدف تحسين هذه الحلول بصورة تدريجية ومنظمة. يقوم كل عنصر في السرب (يمثل حلاً مرشحاً) بتحديث موقعه استناداً إلى أفضل موقع فردي سبق أن وصله، إضافة إلى أفضل موقع عالمي حققه السرب بأكمله. ويسهم هذا التفاعل بين البعدين الفردي والجماعي في تقليل الانحرافات، ودفع الحلول نحو مناطق أعلى جودة داخل فضاء البحث.

٤-٥-٤ تطبيق خوارزمية التصنيف (K-Means)

توظيف خوارزمية K-Means بعد الحصول على الحلول المحسنة، حيث تعتمد الخوارزمية على تقسيم الحلول إلى مجموعات بناءً على درجة التشابه فيما بينها، حيث تُحسب المسافات بين كل حل ومركز كل مجموعة. يُعتمد معيار التشابه في هذا البحث على التقارب في قيمة تابع الكثافة الاحتمالية لكل حل، مما يعكس مدى قربه من الحل الأمثل من الناحية الإحصائية.

٤-٥-٥ تحديد عدد المجموعات المثلى باستخدام خوارزمية المرفق (Elbow Method)

تطبيق خوارزمية المرفق لتحديد العدد الأمثل للمجموعات (N) وذلك من أجل ضمان أن عملية التصنيف باستخدام K-Means تتم بكفاءة، حيث يتم فحص العلاقة بين عدد المجموعات وقيمة الخطأ داخل المجموعات عند زيادة عدد المجموعات، ينخفض هذا الخطأ بشكل طبيعي، لكن بعد نقطة معينة يصبح الانخفاض ضئيلاً وغير مفيد. تُعرف هذه النقطة بنقطة المرفق، وهي التي تمثل التوازن بين الدقة وتجنب التعقيد الزائد (Elbow Method) المجموعة تحتوي على الحل الأمثل

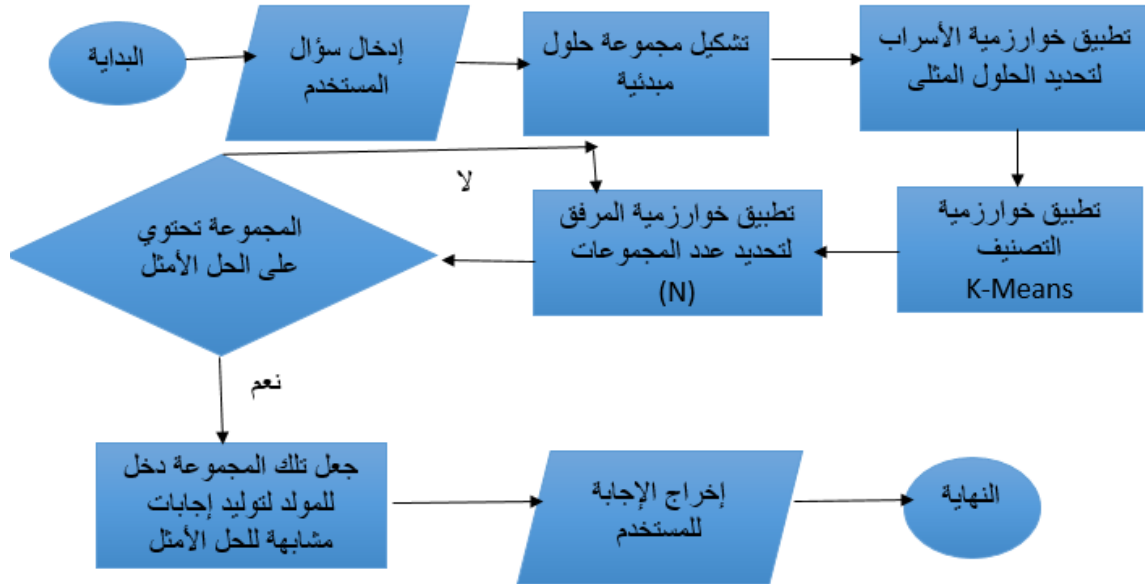
في هذه المرحلة تخضع المجموعات الناتجة من التصنيف لعملية تقييم دقيقة تهدف إلى تحديد مدى قرب حلول كل مجموعة من الحل الأمثل، وفقاً لمجموعة من العتبات. تتضمن هذه العتبات قيماً محددة لتابع اللياقة وحدوداً لمسافة الحلول عن أفضل حل معروف، ومعايير تقارب الكثافة الاحتمالية، إضافة إلى مستوى مقبول من النشئت الداخلي ودرجة انسجام حلول المجموعة. تُعتبر أي مجموعة تتجاوز هذه العتبات جميعها مرشحة للاحتفاظ بها والمتابعة في المراحل التالية. أما المجموعات التي تحقق قيماً أقل من تلك العتبات، فيعاد استكشافها عبر دورة تحسين جديدة تبدأ من الحلول المحسنة.

٤-٥-٧ حفظ الحل الأمثل والتدرّب عليه لتوليد حلول مشابهة

يتم في هذه المرحلة حفظ المجموعة التي تحتوي على الحلول الأقرب إلى الحل الأمثل، واستخدامها كبيانات تدريبية للمولد. تهدف هذه العملية إلى تمكين النموذج من استيعاب السمات البنوية للحلول المثلى، سواء كانت لغوية، دلالية، أو إحصائية، بحيث يصبح قادرًا على توليد حلول جديدة تحافظ على نفس معايير الجودة والاتساق.

٤-٥-٨ إخراج الإجابة للمستخدم

في المرحلة الأخيرة، يقوم النظام بعرض الحل النهائي للمستخدم بعد أن خضع لسلسلة متعددة من التحليل والتحسين والتصنيف والتعلّم. يضمن هذا التسلسل المتدرج أن يكون الحل الناتج قد تجاوز عدة مستويات دقيقة من التقييم الكمي والنوعي، بما في ذلك تحقق تابع اللياقة، وتقارب الحلول مع أفضل الحلول المعروفة، وتقييم التشنت الداخلي واتساق المجموعة. يتم صياغة الإجابة بشكل يراعي السياق الخاص بالمستخدم، بحيث تكون واضحة، ودقيقة، ومباشرة، مع تجنب أي معلومات غير ضرورية قد تؤدي إلى التشنت أو سوء الفهم.



الشكل (٢) منهجية البحث المقترحة

٥- المناقشة:

قمنا ببناء شبكة خصومية توليدية (GAN) لتوليد البيانات والنماذج الجديدة، باستخدام سيناريوين السيناريو الأول بدون استخدام خوارزمية ذكاء الأسراب، أما السيناريو الثاني باستخدام خوارزمية ذكاء الأسراب وخوارزمية K-Means لتحسين أداء الشبكة. ومقارنة أداء الشبكة في كل من الحالتين السابقتين.

٥-١ اذقة نموذج الشبكة الخصومية التولدية بدون استخدام خوارزمية ذكاء الأسراب وباستخدام خوارزمية

ذكاء الأسراب:

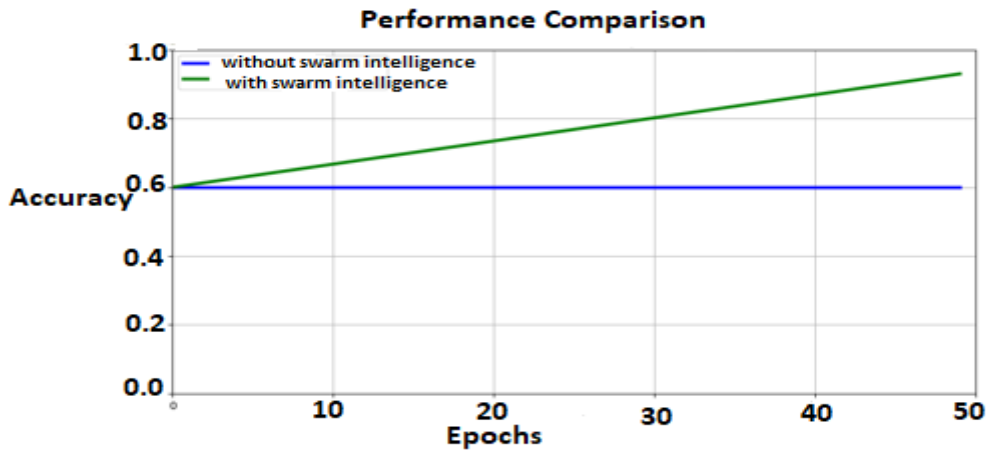
قمنا بتشكيل نموذج GAN بدون ذكاء الأسراب الذي يتكون من طبقة دخل بكثافة ١٠ مع تفعيل الدالة relu من أجل تحسين الاستقرار وطبقة خرج بكثافة ٢ مع تفعيل linear من أجل إنتاج قيم مستمرة. يوضح الشكل (٣) أن

دقة النظام بعد تدريب النموذج التقليدي دون خوارزمية ذكاء الأسراب تصل إلى ٠,٦، نتيجة التوليد العشوائي للبيانات وعدم توجيه الشبكة نحو الحل حيث أن النموذج التقليدي يفتقر إلى آلية تنظيمية فعّالة لضبط فضاء الحلول أثناء التدريب، مما يجعل دالة الخسارة تتحرك ضمن مسارات غير مستقرة يصعب معها الوصول إلى نقطة توازن مناسبة بين المولد والمميز. حيث أن كل حقبة تدريب تولد حلولاً مستقلة، ما يزيد التباين بين النتائج ويقلل قدرة النموذج على الاقتراب من الهدف المرجو. يؤدي ذلك إلى حلول غير متقاربة وعشوائية، تجعل الشبكة غير دقيقة نسبياً وتحد من فعالية التنبؤ وتحسين الأداء، مقارنة بالنماذج التي تستخدم تحسين جماعي أو خوارزميات ذكية لتوجيه البحث نحو الحل الأمثل.

٢-٥ بناء وتدريب نموذج الشبكة الخصومية التوالدية باستخدام خوارزمية ذكاء الأسراب وخوارزمية K-

:Means

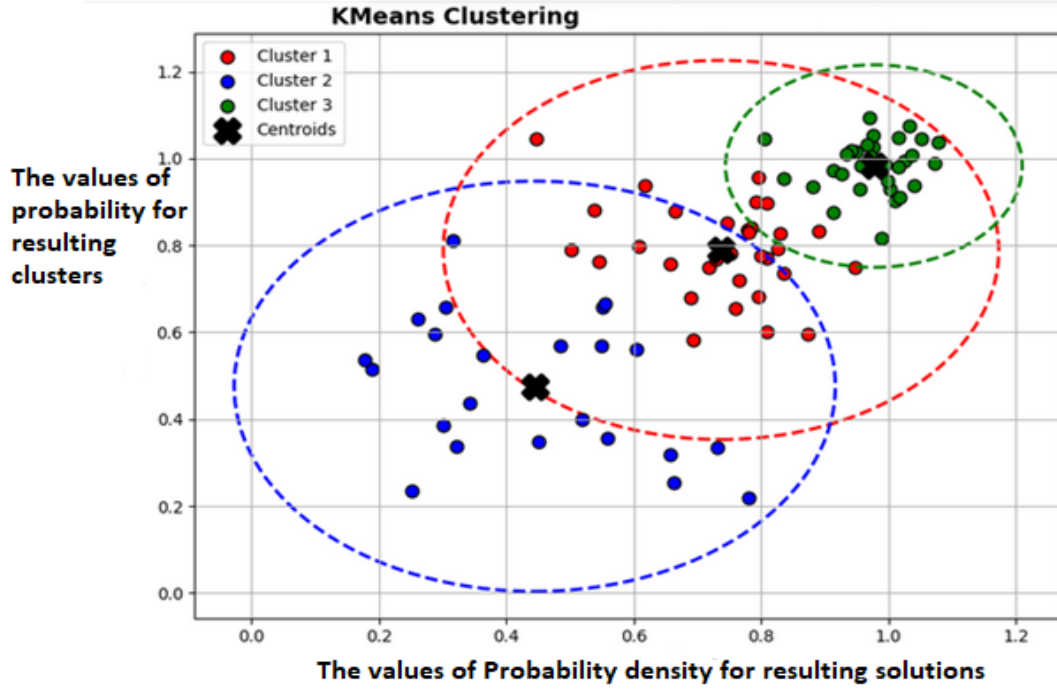
قمنا بتشكيل نموذج GAN باستخدام ذكاء الأسراب الذي يملك نفس بنية النموذج GAN بدون ذكاء الأسراب ولكن يحتوي بامتدادات الأسراب التي هي حجم فضاء الاحتمالات والقيمة الاحتمالية للحل المثل، كما تم التدريب عند استخدام خوارزمية ذكاء الأسراب لـ ٥٠ حقبة وذلك لتقليل الزمن المستغرق في التدريب على حقب أكفأ. يوضح (الشكل (٣)) أن تدريب النموذج باستخدام خوارزمية ذكاء الأسراب يعزز أداء الشبكة الخصومية التوليدية بدقة ٠,٩٣، نظرًا لأن دمج خوارزمية ذكاء الأسراب ضمن نموذج الـ GAN له قدرة أعلى على استكشاف فضاء الحلول بشكل موجه، حيث تعمل معلمات الأسراب مثل حجم فضاء الاحتمالات واحتمالية الاقتراب من الحل الأمثل على ضبط حركة الجسيمات نحو مناطق ذات قيمة أعلى في دالة الهدف.



الشكل (٣) دقة أداء النموذج المقترح بدون استخدام ذكاء الأسراب و K-means ومع استخدام ذكاء الأسراب و K-means

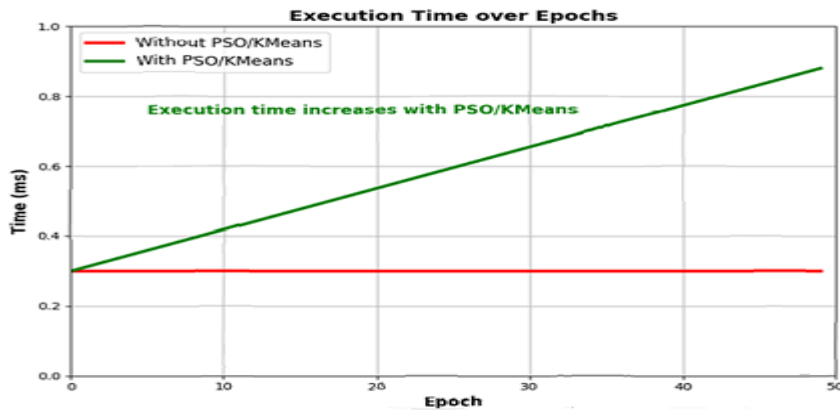
يوضح (الشكل (٤)) كيفية تصنيف الحلول المثلى الأكثر مقاربة إلى سؤال المستخدم إلى مجموعات

حسب تابع كثافتها الاحتمالي واقترب قيمته من قيمة التابع الهدف.



الشكل (٤) تصنيف الحلول المثلى إلى مجموعات

يوضح (الشكل (٤)) تصنيف الحلول الأقرب لهدف المستخدم إلى مجموعات حسب تابع كثافتها الاحتمالي ودرجة قربها من الهدف. حيث يتم تجميع الحلول المتقاربة في عنقود واحد اعتماداً على وزن كل حل وقيمة تابع الكثافة الاحتمالي الخاصة به، حيث تُقاس المسافة بين كل حل ومركز العنقود باستخدام المسافة الإقليدية، فكلما كانت قيمة الكثافة الاحتمالية أعلى والمسافة إلى مركز العنقود أصغر، زادت درجة انتماء الحل لذلك العنقود. تعكس هذه الآلية مدى تقارب الحلول في فضاء الميزات، مما يسمح بتمييز العناقيد ذات الجودة المرتفعة عن غيرها. وبهذا يصبح تركيز النموذج موجّهًا نحو المجموعات التي تحمل حلولاً عالية الاتساق والاقتراب من الهدف، مما يعزز دقة التنبؤ واستقرار الأداء.



الشكل (٥) زمن تنفيذ النظام المقترح عند استخدام ذكاء الأسراب وبدون استخدام ذكاء الأسراب

يوضح (الشكل (٥)) أن دمج خوارزمية ذكاء الأسراب في عملية التدريب يؤدي بطبيعته إلى زيادة زمن التنفيذ، حيث بلغ زمن التشغيل 0.92ms مقارنة بـ 0.3ms في النموذج التقليدي. تعود هذه الزيادة إلى العبء الحسابي

الإضافي الناتج عن تحديث مواقع الجسيمات وتقييم لياقتها بشكل مستمر داخل فضاء الحلول، إضافةً إلى ضرورة إعادة تقدير دوال الكثافة والبحث المتكرر عن النقاط المثلى. كما تتطلب الخوارزمية آليات ضبط دقيقة لتفادي الاستقرار في مناطق محلية منخفضة الجودة، مما يرفع زمن المعالجة. ورغم هذا التعقيد الإضافي، يحقق النموذج المحسن توفراً واضحاً في دقة النتائج واستقرارية الأداء مقارنة بالمنهج غير المدعوم بذكاء الأسراب.

اختبار النظام

Submit اكتب سؤالك، ثم اضغط

ادخل سؤالك هنا

اعطني اسماء 10 شعراء جاهليين

Clear Submit

الإجابة الأولى دون استخدام ذكاء الأسراب والتصنيف

يمكن ذكر شعراء مثل: المتنبي، أبو نواس، محمود درويش، امرؤ القيس، طرفة بن العبد، عنترة بن شداد، النابغة الذبياني، الحطيئة، الأخطل، جرير. لاحظ أن هذه القائمة تضم شعراء من عصور مختلفة وليست مخصصة للعصر الجاهلي فقط.

الإجابة الثانية مع استخدام ذكاء الأسراب والتصنيف

شعراء العصر الجاهلي المشهورون هم: امرؤ القيس، طرفة بن العبد، زهير بن أبي سلمى، عنترة بن شداد، الحارث بن حلزة، النابغة الذبياني، عمرو بن كلثوم، ليبيد بن ربيعة، الأعشى، عبيد بن الأبرص.

تنشيط dows

الشكل (٦) اختبار أداء النظام على سؤال المستخدم

في (الشكل (٦)) يتم عرض تقييم أداء النموذج على سؤال مدخل هو "اذكر أسماء ١٠ شعراء جاهليين"، مع مقارنة نتائج النظام بين حالتين: عند عدم استخدام خوارزميات ذكاء الأسراب والتصنيف، وعند استخدامها. يوضح الشكل اختلاف جودة النتائج بشكل واضح. في الحالة الأولى، أي عند استخدام النموذج بدون خوارزميات ذكاء الأسراب والتصنيف، قدم النظام إجابة تقريبية تضمنت شعراء مثل المتنبي، أبو نواس، محمود درويش، امرؤ القيس، طرفة بن العبد، عنترة بن شداد، النابغة الذبياني، الحطيئة، الأخطل، وجرير، وهي إجابة غير دقيقة لاحتوائها على شعراء من عصور مختلفة لا تنتمي للعصر الجاهلي. أما عند استخدام خوارزميات ذكاء الأسراب والتصنيف في النموذج، قدم النظام إجابة دقيقة تضم شعراء العصر الجاهلي الفعليين: امرؤ القيس، طرفة بن العبد، زهير بن أبي سلمى، عنترة بن شداد، الحارث بن حلزة، النابغة الذبياني، عمرو بن كلثوم، ليبيد بن ربيعة، الأعشى، وعبيد بن الأبرص، ما يعكس تحسناً دقة النموذج وقدرته على التمييز بين المعلومات الصحيحة والغامضة، مؤكداً فعالية خوارزميات التحسين الذكية في تعزيز جودة المخرجات.

٦- الاستنتاجات والتوصيات:

نستنتج من هذا البحث أهمية وفوائد استخدام خوارزمية ذكاء الأسراب في التطبيقات الحوارية للشبكات الخصومية التوافقية والتي تكمن فيما يلي:

- استخدام خوارزمية ذكاء الأسراب يعزز قدرة الشبكات الخصومية التوافقية على التمييز بين السياقات المختلفة وتوجيه البحث نحو الإجابات الصحيحة بدقة أعلى مقارنة بالدراسات السابقة التي اعتمدت على أساليب تقليدية.
- الخوارزمية تركز البحث على المجالات الأكثر احتمالاً لاحتواء الإجابة الصحيحة، ما يقلل التشتت ويزيد الدقة، خلافاً للأساليب التقليدية التي تنتج إجابات عامة ومتباعدة.
- دمج ذكاء الأسراب يسمح بإنتاج بيانات متسقة وعالية الجودة، ويقلل الحاجة لمعالجة بيانات غير ضرورية، مما يجعل النموذج أكثر فعالية واعتماداً في التطبيقات المستقبلية مقارنة بالدراسات السابقة.
- يتميز هذا البحث عن الدراسات السابقة بأنه يركز على تحسين جودة النتائج و زيادة دقة التوليد مقارنة بالدراسات السابقة التي ركزت بشكل أساسي على تحسين استقرار التدريب والاعتماد فقط على تقنيات تقليدية لتحسين الشبكة الخصومية التوافقية، و بالتالي إن دمج خوارزميات ذكاء الأسراب يوفر قدرة فريدة على استكشاف مساحة الحلول بشكل أكثر كفاءة مما يتيح للمولد إنتاج إجابات أكثر دقة و تقارباً مع هدف المستخدم .

٧-المراجع:

1 -GUI, J.; SUN, Z.; WEN, Y.; TAO, D.; YE, J. 2021. A review on generative adversarial networks: Algorithms, theory, and applications. IEEE transactions on knowledge and data engineering. United States. 3313-3332.

2 -CHAKRABORTY, A.; KAR, A. K. 2017. Swarm intelligence: A review of algorithms. Nature-inspired computing and optimization. Switzerland. 475-494.

3 -LI, Z.; XIA, P.; TAO, R.; NIU, H.; LI, B. 2022. A new perspective on stabilizing GANs training: Direct adversarial training. IEEE Transactions on Emerging Topics in Computational Intelligence. United States. 178-189.

4- GUPTA, S.; RANI, R.; JAISWAL, G.; SHARMA, A. 2023. Enhancing the Classification Accuracy using CNN, GANs, and data Augmentation Techniques. 2023 International Conference on Evolutionary Algorithms and Soft Computing Techniques (EASCT). IEEE. United States. 1-7.

5 -ZHANG, Z.; HUA, Y.; WANG, H.; McLOONE, S. 2024. Improving the fairness of the min-max game in GANs training. Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. United States. 2910-2919.

6 -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. United States. 1627-1643.

7 -IKOTUN, A. M.; EZUGWU, A. E.; ABUALIGAH, L.; ABUHAIJA, B.; HEMING, J. 2023. K-means clustering algorithms: A comprehensive review, variants analysis, and advances in the era of big data. Information Sciences. Netherlands, 178-210.

8 -NAIK, P. G. 2023. Conceptualizing python in google colab: Hands-on practical sessions. Shashwat Publication. India.

9 -CAI, Z.; XIONG, Z.; XU, H.; WANG, P.; LI, W.; PAN, Y. 2021. Generative adversarial networks: A survey toward private and secure applications. ACM Computing Surveys (CSUR). United States. 1-38.

10 -LEE, K.; CHANG, H.; JIANG, L.; ZHANG, H.; TU, Z.; LIU, C. 2021. Vitgan: Training gans with vision transformers. arXiv preprint. United States.

11- PERMADI, V. A.; TAHALEA, S. P.; AGUSDIN, R. P. 2023. K-means and elbow method for cluster analysis of elementary school data. Progres Pendidikan. Indonesia. 50-57.