

تحسين نموذج الخوارزميات الجينية بمتجهات الدعم الآلي في التنبؤ بالفشل المالي للمؤسسات الجزائرية  
خلال الفترة 2011-2018

**Improving genetic algorithms model using automatic support vectors  
through Algerian institutions financial failure predicting experience  
during 2011-2018**

هلال وسام أرحاب\*، جامعة غرداية، (الجزائر). arhab.wissam@univ-ghardaia.dz

مروة زهواني، جامعة غرداية (الجزائر)، zahouani.marwa@univ-ghardaia.dz

تاريخ النشر: 2023/12/28

تاريخ القبول: 2023/09/28

تاريخ الاستلام: 2023/05/28

**ملخص:**

تهدف الدراسة الى إمكانية التنبؤ بالفشل المالي للمؤسسات الجزائرية باستخدام نموذج هجين بين الخوارزميات الجينية و متجهات الدعم الآلي، من خلال تحليل 23 نسبة مالية ل 1128 مؤسسة جزائرية بالاستعانة ببرنامج البايثون. وتوصلت الدراسة إلى أن دقة التنبؤ بالفشل المالي للمؤسسات الجزائرية لنموذج الخوارزميات الجينية المدربة والمصممة بالمتجهات الدعم الآلي قد بلغت 90,95 % مما يدل على قوة النموذج وقدرته على التنبؤ بشكل جيد.

كلمات مفتاحية: ذكاء اصطناعي، خوارزميات جينية، متجهات دعم آلي، فشل مالي.

تصنيفات JEL: O31، O32، G32.

**Abstract:**

The study aims the Algerian institutions predict financial failure which using a hybrid model between genetic algorithms and automated support vectors, throughout analyzing 23 financial ratios for 1128 Algerian institutions using the Python program. The study found out those such Algerian institutions financial failure prediction accuracy in view of the

\* المؤلف المرسل.

trained genetic algorithm model designed with automated support vectors reached 90.95%, indicating the model strength with its ability for well predicting.

Keywords: artificial intelligence, genetic algorithms, automated support vectors, financial failure.

**Jel Classification Codes: O31 ,O32, G32**

## 1. مقدمة:

يعد التعلم الآلي مجالاً متعدد التخصصات للغاية ويعتمد على أفكار من العلوم المعرفية، علوم الكمبيوتر، الإحصاء والرياضيات، وفي التعلم الآلي التصنيف هو نهج تعلم خاضع للإشراف وبمعلم، يستخدم لتحليل مجموعة بيانات معينة وبناء نموذج يفصل البيانات إلى عدد مرغوب و متميز من الفئات، كما أنه يوجد العديد من تقنيات التصنيف الجيدة بما في ذلك تصنيف k-nearest neighbors، شبكات Bayesian، الشبكات العصبية الاصطناعية Artificial Neural Network، الخوارزميات الجينية Genetic Algorithm، أشجار القرار Decesion Trees ومتجهات الدعم الآلي Sepport Vector Machine وغيرها العديد، حيث تتميز طرق الجار الأقرب بميزة أنها سهلة التنفيذ، ومع ذلك، فهي عادة ما تكون بطيئة جدًا إذا كانت مجموعة بيانات الإدخال كبيرة جدًا، ومن ناحية أخرى، هذه حساسة للغاية لوجود معلمات غير ذات صلة، كما تم استخدام أشجار القرار على نطاق واسع في مشاكل التصنيف وعادة ما تكون هذه الاخيرة أسرع من الشبكات العصبية في مرحلة التدريب، ومع ذلك، فهي لا تتمتع بالمرونة لنمذجة المعلمات، أما عن الشبكات العصبية فهي واحدة من أكثر التقنيات شيوعاً واستخداماً وتم استخدامها على نطاق واسع في عدد كبير من التطبيقات كنهج عالمي، فكانت أفضل التقنيات المعروفة لتحسين الحل المتوقع هو تقديم SVM بواسطة Vapnik كنموذج تعلم آلي قائم على النواة لمهام التصنيف والانحدار، وتم استخدامها كأداة قوية لحل مشاكل التصنيف الثنائي، وثبت أن SVMs تتفوق على طرق التعلم الخاضعة للإشراف الأخرى نظراً لأسسها النظرية الجيدة وقدرتها التعميمية الجيدة، فأصبحت SVMs في السنوات الأخيرة واحدة من أكثر طرق التصنيف استخداماً، ففي دراستنا هذه تم تمجيدنا مع الخوارزميات الجينية لإعطاء نتائج أدق وأفضل.

أ- إشكالية الدراسة: وعلى ضوء ما سبق، تمثلت اشكالتنا فيما يلي:

ما مدى فعالية تحسين نموذج الخوارزميات الجينية بمتجهات الدعم الآلي في التنبؤ بالفشل المالي

للمؤسسات الجزائرية خلال الفترة 2011-2018؟

ب- فرضية الدراسة: تختبر هذه الدراسة الفرضية التالية:

يتميز نموذج الخوارزميات الجينية بتحسين وتدريب نموذج متجهات الدعم الآلي بدقته العالية في

التنبؤ بالفشل المالي للمؤسسات الجزائرية.

ت- أهمية الدراسة:

إن الكثير من المؤسسات الجزائرية تعاني من معضلات في هياكلها التمويلية، وقد أثر فشلها في الهياكل المالية وخسائرها على مستوى كفاءتها في السوق الجزائرية، مما يؤدي إلى وجود تدني وخلل في أدائها المالي والتشغيلي، وهذا الأخير هو الذي يعرضها لمخاطر التعثر الدائم الذي يؤدي بصفة آلية للفشل المالي. لذا يتطلب عليها البحث على آليات تساعد في التنبؤ بمخاطر الفشل المالي وتساعد على تفاديه، والتعجيل بتقديم حلول مناسبة لتحسين وضعها المالي قبل تفاقم المشكل، لذلك فإن هذه الدراسة تساعد وترشد المساهمين وأصحاب الشركات والمصالح على التنبؤ بمخطر الفشل المالي في المؤسسات الاقتصادية وفق نموذج متطور وعالي الدقة والسرعة، من أجل أن تحتاط قبل وقوعها في مرحلة العسر الحقيقي والذي يؤدي بدوره إلى الفشل، ويكون ذلك وفقا لنموذج تحسين الخوارزميات الجينية بمتجهات الدعم الآلي.

ث- أهداف الدراسة: تهدف هذه الدراسة إلى معرفة:

■ أهم تطبيقات نماذج الذكاء الاصطناعي؛

■ أبرز المؤشرات استخداما والتي تساعد على قياس الفشل المالي؛

■ إمكانية التنبؤ بالفشل المالي باستخدام نموذج هجين بين الخوارزميات الجينية ومتجهات الدعم؛

■ تشجيع المؤسسات الاقتصادية الجزائرية على تبني نماذج حديثة تفيدها في سرعة اتخاذ القرارات

الصائبة قبل وصولها إلى الفشل المالي.

### ج- منهج الدراسة:

تم الاعتماد على المنهج الوصفي لدراسة وصف، عرض وتحليل الخوارزميات الجينية، متجهات الدعم الآلي، مؤشرات الفشل المالي وصفا دقيقا، اضافة إلى الدراسات السابقة بهدف الحصول على الإطار النظري للدراسة من خلال عدة مراجع كالكتب، الأطروحات، الرسائل، المداخلات والمقالات العلمية... الخ، أما المنهج التحليلي لدراسة حالة الجانب التطبيقي والتعبير عنه كemia من خلال جمع البيانات وتحليلها للوصول إلى النتائج والاستنتاجات التي تسهم في تحسين التنبؤ بمخاطر الفشل المالي للمؤسسات باستخدام نموذج تحسين الخوارزميات الجينية بمتجهات الدعم الآلي بالاستعانة ببرنامج البايثون.

### ح- الدراسات السابقة:

1- عاجت دراسة (فراحي، 2022) المتغيرات الاقتصادية التي تؤثر إيجابيا على نشاط بورصة الجزائر خلال الفترة (1999- 2020) باستعمال خوارزمية متجهات الدعم الآلي والركائز الأخرى التي يمكن أن تحفز من انطلاقتها بشكل فعال، واستخدمت تقنيات حديثة لتعلم الآلة مثل خوارزميات التصنيف الذكية الموجودة في مكتبات برامج البايثون، انطلاقا من قاعدة البيانات الاقتصادية للجزائر، وتوصل الدراسة إلى استخلاص وتصنيف ثلاث متغيرات ذات تأثير إيجابي على أداء بورصة الجزائر.

2- عاجت دراسة (Acosta-González & Fernández-Rodríguez, 2013) التنبؤ بالفشل المالي للشركات بالخوارزمية الجينية وكان هدفها تقديم منهجية بحث حسابية باختيار 31 نسبة المالية، بالاعتماد على نموذج الخوارزمية الجينية من أجل التنبؤ بالفشل وعدم الفشل للمدة (2000-2004) قبل حدوثه، على عينة تتكون من 347 شركة إسبانية لقطاع الصناعة والبناء، 93 فاشلة و254 سليمة. وتشير نتائجها إلى أن الخوارزمية الجينية أسفرت عن دقة تصنيف مناسبة بشكل عام للتنبؤ بنسبة 83 و69٪ للسنة الأولى والثانية قبل الفشل على التوالي وبالمثل لوحظت قوة التنبؤ هذه في تحليل منحني ROC وCAP، استخدام البيانات للتنبؤ بفشل وعدم فشل الشركات للفترة (2006-2009) وكان أداء النماذج جيد جدا مقارنة بعام 2004؛

3- ناقشت دراسة (Kim & Kang, 2012): كيفية اختيار المصنفات في مجموعات باستخدام

الخوارزمية الجينية للتنبؤ بالإفلاس وهدفها هو اقتراح تقنية تحسين التغطية المستندة إلى الخوارزمية الجينية بهدف حل مشكلة العلاقة الخطية المتعددة، حيث تم تطبيقها على مجموعة بيانات معيارية تحتوي على 1200 شركة تصنيع خاضعة للتدقيق الخارجي تم الحصول عليها من أحد البنوك التجارية الكبرى في كوريا و31 نسبة مالية كالربحية، تغطية الديون، الرافعة المالية، هيكل رأس المال، السيولة، النشاط والحجم، نصفها أفلس خلال (2002-2005)، بينما تم اختيار الشركات المفلسة من النشطة في 2005، تشير النتائج التجريبية إلى أن خوارزمية تحسين التغطية المقترحة يمكن أن تساعد في تصميم نظام تصنيف متنوع ودقيق. أوصت الدراسة إجراء المزيد من الأبحاث المتقدمة حول تحسين قرار العملية في المستقبل؛

## 2. مفاهيم حول الخوارزميات الجينية ومنتجات الدعم الآلي:

زاد استخدام مصطلح الخوارزميات في القرن الماضي، وتعرف الخوارزميات على أنها مجموعة من الخطوات (التعليمات) مرتبة ومنتهية، لتنفيذ عملية حسابية أو منطقية، أو غيرها بشكل تسلسلي ومنطقي (السيد، 2016، صفحة 6)، وفي هذا الإطار سنتطرق إلى مفهوم الخوارزميات الجينية ومنتجات الدعم الآلي ونتعرض لأهم المصطلحات التي تخصها والخطوات التي تمر بها.

### 1.2 مفهوم الخوارزميات الجينية:

تعتبر أحد أهم وأحدث أساليب الذكاء الاصطناعي وبرزت أهميتها في حل المسائل المعقدة خلال زمن مناسب، وتعتمد على أفكار الهندسة الوراثية ويبدأ حلها باستخدام مجتمع عشوائي يمثل مجموعة الحلول، كل حل تُخصص له دالة صلاحية (Fitness Function)، ترتبط مباشرة بدالة الهدف لمسألة معينة وبعدها يتم تعديل هذا المجتمع وتوليد جيل جديد (Offspring)، من خلال تطبيق مجموعة من العوامل الجينية الوراثية منها: الانتقاء (Selection)، التقاطع أو التزاوج (Recombination/Crossover) والطفرة (Mutation)، بصورة متكررة وبالتتابع على أجيال هذا المجتمع لحين تحقق شرط التوقف (خروفة، 2010، صفحة 301)، حيث اعتبرت طريقة ناجعة لحل العضلات الصعبة، ففكرتها تكمن في توليد بعض الحلول للمشكلة عشوائيا، ثم

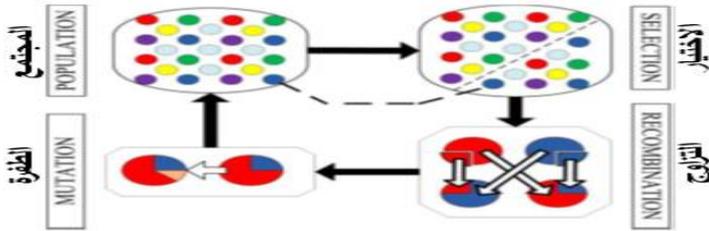
تفحص هذه الحلول وتقارن ببعض المعايير التي يضعها مصمم الخوارزميات وأفضل الحلول فقط هي التي تبقى، أما الحلول الأقل كفاءة فيتم إهمالها عملاً بالقاعدة البيولوجية "البقاء للأصلح" (Survival of the Fittest) (الحدابي، العمري، العبادي، و نور، 2004، صفحة 5).

أما (خوالد و بوزرب، 2020، صفحة 38) لخصها في أنها مزيج بين المفاهيم الداروينية البقاء للأصلح والانتخاب الطبيعي والرياضيات لإيجاد الحلول للمشكلة أو المهمة المطلوبة، وتمثل سمات الخوارزميات الجينية في سمتين أساسيتين وهما: العشوائية وفضاء البحث. (خليفة، 2013، الصفحات 37-38).

وبذلك اختصر (Guo & Yang, 2011, p. 230) آلية عمل الخوارزمية فيما يلي:

- 1- إنتاج مجموعة سكانية أصلية بشكل عشوائي والتي يكون عدد أفرادها ثابت  $N$ ؛
- 2- إنتاج الجيل القادم بالعبور والتحول بين الأفراد؛
- 3- تكوين السكان الجدد من  $N$  أفراد من جيل للخطوة (2) السابقة؛
- 4- إنتاج السكان التاليين بتكرار الخطوة (2) و(3) حتى الحصول على الفرد الذي يستوفي الشروط. نوضح هذه الآلية من خلال الشكل الموالي:

الشكل رقم (01): آلية عمل الخوارزمية الجينية



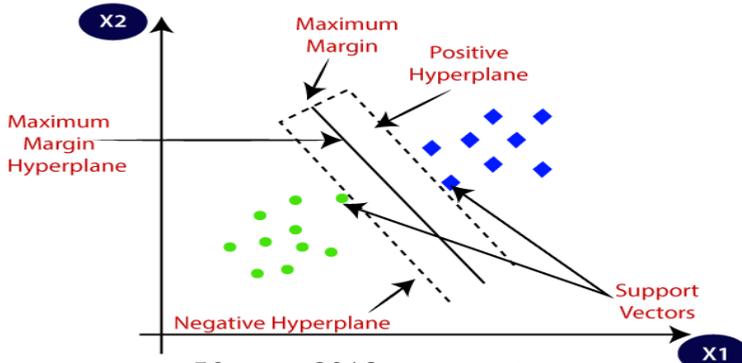
المصدر: (Niraula, 2010, p. 14)

## 2.2 تعريف متجهات الدعم الآلي (Support Vector Machine):

وتعرف باختصار (SVM) يعد نظامًا تعليميًا لتصنيف البيانات إلى مجموعتين من البيانات باستخدام مساحة افتراضية في شكل دوال خطية في مساحة الميزة بعدا عاليا، وتحتوي على خصائص غير مملوكة لآلة التعلم بشكل عام وهي في طور البحث عن أفضل خط فاصل (المستوى الفائتق)، ذلك

للحصول على أقصى حجم للهامش بين مساحة الإدخال غير الخطية مع مساحة الميزة باستخدام قواعد kernel، أما الهامش هو ضعف المسافة بين المستوي الفائق ومتجه الدعم والنقطة الأقرب للمستوى الفائق تسمى متجه الدعم (Manurung, Mawengkang, & Zamzam, 2017, p. 3). يمكن وصف ناقلات الدعم الآلي بأنها خوارزمية تعلم خاضعة للإشراف قادرة على حل مشاكل التصنيف الثنائي الخطي وغير الخطي. (Lessmann, Stahlbock, & Crone, p. 3063)

الشكل رقم (02): مخطط يوضح متجهات الدعم الآلي



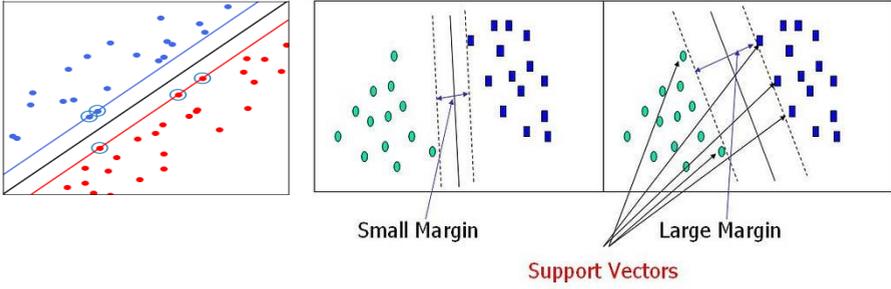
المصدر: (قاسم و الوازن، 2018، صفحة 53)

حسب (JavaPoint, 2023) تعد متجهات الدعم الآلي واحدة من أكثر خوارزميات التعلم الخاضع للإشراف شيوعا، والهدف منها هو إنشاء أفضل خط أو حدود قرار يمكنها فصل الفضاء ذي البعد  $n$  إلى فئات بحيث يمكننا بسهولة وضع نقطة البيانات الجديدة في الفئة الصحيحة في المستقبل، يُطلق على حدود القرار الأفضل اسم الهامش الفائق Margin Hyperplane، يختار SVM النقاط / المتجهات القصوى التي تساعد في إنشاء المستوى الفائق وتسمى هذه الحالات القصوى باسم ناقلات الدعم، وتسمى أيضا بخوارزمية آلة المتجهات الداعمة.

### 3.2 آلية عمل متجهات الدعم الآلي:

الهدف الرئيسي من SVM تقسيم مجموعات البيانات إلى فئات للعثور على الحد الأقصى للمستوى الفائق. والشكل رقم 03 أدناه يوضح ذلك:

الشكل رقم (03): آلية عمل متجهات الدعم الآلي



المصدر: (بوزيدي و بن عيسى، 2020، صفحة 174)

تفترض فكرة الحدود هذه أن البيانات قابلة للفصل خطياً، وهذا نادراً ما يحدث، وللتغلب على هذا، غالباً ما تعتمد SVM على استخدام "النواة"، تتيح هذه الدوال الرياضية إمكانية فصل البيانات عن طريق إسقاطها في مساحة مميزة (مساحة متجه ذات بُعد أعلى، انظر الشكل أعلاه)، كما تتيح تقنية تعظيم الهامش ضمان متانة أفضل ضد الضوضاء - وبالتالي نموذج أكثر قابلية للتعميم، للفصل بين فئتي نقاط البيانات، هناك العديد من المخططات الفائقة المحتملة التي يمكن اختيارها، هدفنا هو العثور على مستوى به الحد الأقصى للهامش، أي أقصى مسافة بين نقاط البيانات لكلا الفئتين، ويوفر تعظيم مسافة الهامش بعض التعزيزات بحيث يمكن تصنيف نقاط البيانات المستقبلية بمزيد من الثقة، فالمعلمت الفائقة هي عبارة عن حدود القرار التي تساعد في تصنيف نقاط البيانات، يمكن أن تُعزى هذه الأخيرة التي تقع على جانبي المستوى الفائق إلى فئات مختلفة، إذا كان عدد ميزات الإدخال 2، فإن المستوى الفائق هو مجرد خط، أيضاً يعتمد بُعد المستوى الفائق على عدد الميزات إذا كان عدد ميزات الإدخال 3، فسيصبح المستوى الفائق مستوى ثنائي الأبعاد ويصبح من الصعب تخيل ذلك عندما يتجاوز عدد الميزات 3.

(Mammone, Turch, & Cristianini, 2009, p. 284)

فمتجهات الدعم هي نقاط بيانات أقرب إلى المستوى الفائق وتؤثر على موضع واتجاهه باستخدام متجهات الدعم هذه، نقوم بتعظيم هامش المصنف سيؤدي حذف ناقلات الدعم إلى تغيير موضع المستوى الفائق هذه هي النقاط التي تساعدنا في بناء SVM الخاص بنا؛ وبالتالي تساعد خوارزمية SVM في العثور على أفضل خط أو حدود قرار؛ يُطلق على هذه الحدود أو المنطقة الأفضل اسم المستوى الفائق، تعثر خوارزمية SVM على أقرب نقطة من الأسطر من كلا الفئتين تسمى هذه النقاط 'نواقل الدعم'،

وتسمى المسافة بين المتجهات والمستوى الفائق بالهامش، والهدف من SVM هو تعظيم هذا الهامش، ويطلق على المستوى الفائق مع الحد الأقصى للهامش المستوى الفائق الأمثل. (Chen, Lin, & Scholkopf, 2005, p. 117)

### 3. التنبؤ بالفشل المالي للمؤسسة الاقتصادية:

ان المؤسسة التي تتعرض لفشل مالي لا تنتقل من حالة جيدة الى حالة فشل بشكل مفاجئ، وانما من خلال المرور بما يسمى بمسار الفشل المالي. نحاول من خلال هذا العنصر التطرق لماهية الفشل المالي وكيفية التنبؤ به لإنقاذ المؤسسة الاقتصادية قبل الوصول إلى آخر مرحلة من الفشل المالي.

### 1.3 مفهوم واسباب الفشل المالي للمؤسسة الاقتصادية:

يعتبر الباحث Beaver من الأوائل الذين استخدموا مصطلح الفشل المالي للدلالة على بداية وصول المؤسسة لإشهار افلاسها؛ فهو عدم قدرة المؤسسة على دفع التزاماتها حين يأتي وقت استحقاقها. (الصغير و زهواني، 2022، صفحة 475). و تعود أسباب الفشل المالي للمؤسسة الى أسباب مالية وأسباب غير مالية (استراتيجية، ادارية، تسويقية...)، "ذلك الاختلال الذي تواجهه المؤسسة نتيجة قصور مواردها و إمكانياتها لمواجهة إلتزاماتها في الأجل القصير. ويمكن أن نقول أن المؤسسة متعثرة ماليا إذا حققت خسائر متتالية لمدة ثلاث سنوات" (بوستة و عبد اللطيف، 2018، صفحة 138)، و فاشلة اذا حققت خسائر متتالية لمدة خمس سنوات متتالية.

كما سنركز في هذه الدراسة على تحليل الفشل المالي و ترجمة أسبابه من خلال الأعراض التي تظهرها البيانات المحاسبية والمالية للمؤسسة (مريخي، 2020، صفحة 17).

### 2.3 آليات التنبؤ بالفشل المالي بالمؤسسة الاقتصادية:

يقصد بالتنبؤ تقدير المستقبل، أو تخمين ومعرفة مستوى اقتصادي معين للمؤسسة بهدف توقع المستقبل وتصحيح مسار المؤسسة (الصغير و زهواني، 2022). وبهدف اعطاء قيم تقديرية لتلك الأحداث المستقبلية المالية للمؤسسة، اجتهد العديد من الباحثين في وضع نماذج مبنية على البيانات المالية. فقد اقترح Beaver نموذجا يعرف باسم النسب المالية المركبة، بتحليل كل نسبة لخمس سنوات متتالية (موضحة في الجدول رقم 01 أدناه).

4. الجانب العملي: تنبؤ المؤسسات الجزائرية بالفشل المالي من خلال تدريب الخوارزميات الجينية بمنتجات الدعم الآلي:

1.4 مجتمع الدراسة: تم التركيز في دراستنا على المؤسسات الاقتصادية الجزائرية ذات أسهم (SPA)، وذلك من خلال البحث في الدراسات السابقة للدراسة الحالية، والتي تجاوز عددها الإجمالي 2000 مؤسسة نشيطة حسب موقع السجل التجاري حتى نهاية 2019، وبناءً على الاحصائيات المتوفرة في بوابة سجلكم الى غاية 2021.01.10 (وزارة التجارة، 2021)

1.5 منهجية الدراسة:

➤ عينة الدراسة: تم الاعتماد في دراستنا على عينة مستهدفة، وتم اختيار المؤسسات المتماثلة من خلال نقاط مشتركة مثل (نفس الفترة الممتدة، الشكل القانوني، نفس السوق... الخ)، وعليه بلغ عددها 1128 مؤسسة منها 408 متعثرة و720 سليمة.

○ المتغير التابع: تمثل في الفشل المالي والذي رمزنا له بـ (Y)، حيث أن القيمة 0 تعبر عن فشل المؤسسة، والقيمة 1 تعبر عن سلامة المؤسسة (غير متعثرة)؛

وتم الاعتماد على معيارين في انتقاء المؤسسات الجزائرية محل دراستنا من خلال فشلها أو عدمها، حيث اعتبرنا مؤسسات فاشلة إذا تم تحقيق خسائر متوالية لمدة خمس سنوات في النتيجة المالية، أما المؤسسات السليمة إذا حققت أرباح متوالية لمدة خمس سنوات في السنة المالية؛

○ المتغيرات المستقلة: تمثلت في 23 نسبة مالية (نسب السيولة، النشاط، المديونية والربحية) وهي موضحة في الجدول أدناه، وتم الاعتماد على هذه الأخيرة بناءً على مرجعية الدراسات السابقة والتي استعملت أكثر من قبل الباحثين، والتي لها قدرة كبيرة على تصنيف المؤسسات بالفشل المالي عن بقية النسب الأخرى.

رمز	النسبة	مدلولها	تفسير النسب
<b>نسب السيولة</b>			
R1	نسبة السيولة السريعة	(أصول متداولة - المخزون) / الخضوم المتداولة	قياس قدرة المؤسسة على مواجهة الخضوم الجارية بأصول المتداولة دون اللجوء إلى المخزون
R2	نسبة التداول	الأصول المتداولة / الخضوم المتداولة	قدرة المؤسسة على سداد ديونها قصيرة الأجل لتغطية أصولها المتداولة، ارتفاعها جيد
R3	نسبة صافي رأسمال	صافي رأسمال / إجمالي الأصول	قدرة تقييم الأداء وصحة المالية المؤسسة
R4	نسبة النقدية	الخزينة/الخضوم المتداولة	قياس مقدار النقدية المتوفرة لسداد الخضوم المتداولة، وارتفاعها يدل امتلاك المؤسسة للسيولة اللازمة لسداد ديونها
R5	نسبة الأصول المتداولة إلى الأصول	الأصول المتداولة / إجمالي الأصول	قياس قدرة المؤسسة على مواجهة أصولها بالأصول المتداولة
<b>نسب النشاط</b>			
R6	معدل دوران الأصول الثابتة	رقم الأعمال/الأصول غير المتداولة	يشير إلى مدى كفاءة المؤسسة في استخدام استخداماتها الثابتة الخاصة بالمؤسسة لتوليد رقم الأعمال
R7	معدل دوران الأصول	رقم الأعمال/ مجموع الأصول	يدل على عدد المرات التي تتحول فيها الأصول إلى رقم الأعمال، وارتفاعه يبين أن الإدارة تستغل أصولها بكفاءة وفعالية
R8	معدل دوران الأصول المتداولة	رقم الأعمال/ الأصول المتداولة	يشير معدل دوران الأصول الجارية إلى مدى كفاءة المؤسسة في استخدامها للأصول الجارية في توليد رقم الأعمال.
R9	معدل دوران صافي رأسمال العامل	رقم الأعمال/ صافي رأسمال العامل	ارتفاعه العالي يشير على كفاءة الإدارة في استخدام صافي رأسمالها العامل في توليد الإيرادات
R10	معدل دوران النقدية	رقم الأعمال/ الخزينة	تبين هذه النسبة عدد المرات التي تدورها النقدية خلال العمليات التشغيلية التي تقوم بها المؤسسة
<b>نسب الهيكل المالي (المديونية)</b>			

مؤشر الارتفاع غير جيد، ويبين عدم قدرة المؤسسة على خدمة دينها مما يزيد من مخاطر أصحاب القروض والمستثمرين	اجمالي الديون/ اجمالي الأصول	نسبة الديون إلى الأصول (الاستدانة)	<b>R11</b>
مدى اعتماد المؤسسة على مصادرها الخارجية في تمويل استثماراتها، وانخفاضها يدل اعتمادها على مصادرها الذاتية في تمويلاتها ويتيح هامش أمان أكبر	اجمالي الخصوم / اجمالي الأصول	نسبة المديونية	<b>R12</b>
مدى مساهمة الخصوم في التمويل من حقوق الملكية	حقوق الملكية / اجمالي الخصوم	نسبة حقوق الملكية إلى الخصوم	<b>R13</b>
مدى مساهمة الدائنين في أصول المؤسسة بالمقارنة مع مساهمة المالكين، وقدرة ومثانة المشروع على الوفاء بالتزاماته	اجمالي الخصوم / حقوق الملكية	نسبة الدين إلى حقوق الملكية	<b>R14</b>
تستخدم كدليل على مدى استقرار وسلامة المركز المالي من منظور طويل الأجل	حقوق الملكية / اجمالي الأصول	نسبة حقوق الملكية إلى الأصول	<b>R15</b>
المدى الذي ذهبت اليه المؤسسة في تمويل أصولها الثابتة من أموال الغير	حقوق الملكية / الأصول الثابتة	نسبة حقوق الملكية إلى الأصول الثابتة	<b>R16</b>
مدى مساهمة الخصوم المتداولة في التمويل من حقوق الملكية	حقوق الملكية / الخصوم المتداولة	نسبة حقوق الملكية إلى الخصوم المتداولة	<b>R17</b>
<b>نسب الربحية</b>			
تبين مقدرة دينار واحد من صافي المبيعات على توليد هامش من صافي الربح، والمؤشر المرتفع لها يدل على الأداء الجيد	النتيجة الصافية / رقم الاعمال	هامش صافي الربح	<b>R18</b>
مدى كفاءة المؤسسة في تحقيق الأرباح من استخدام اصولها، وارتفاعها يدل على الكفاءة التشغيلية للإدارة	النتيجة الصافية / اجمالي الأصول	العائد على الأصول	<b>R19</b>
قياس العائد المتحقق من استثمار المالكين في المؤسسة، والمؤشر العالي لها يدل على قدرة الادارة على تعظيم عوائدها	النتيجة الصافية / حقوق الملكية	العائد على حقوق الملكية	<b>R20</b>

## تحسين نموذج الحوارزميات الجينية بمتجهات الدعم الآلي في التنبؤ بالفشل المالي

### للمؤسسات الجزائرية خلال الفترة 2011-2018

R21	العائد على الخصوم	النتيجة الصافية / اجمالي الخصوم	مدى كفاءة إدارة المؤسسة في تحقيق الأرباح من استخدام خصومها
R22	العائد على الأصول الثابتة	النتيجة الصافية / الأصول الثابتة	مدى كفاءة إدارة المؤسسة في تحقيق الأرباح من استخدام أصولها الثابتة
R23	نسبة صافي الربح إلى رأسمال	النتيجة الصافية / (الأصول المتداولة- الخصوم المتداولة)	مدى كفاءة إدارة المؤسسة في تحقيق الأرباح من استخدام رأسمالها

المصدر: إعداد الباحثان اعتمادا على مراجعة الدراسات السابقة

من خلال معالجة بيانات الدراسة تم توصيفها عن طريق عملية تحليل البيانات الاستكشافية أو ما يعرف بـ(EDA) Explanatory Data Analysis، للحصول على بعض المعلومات حولها، ولاكتشاف إن كانت هناك قيما مفقودة ومتطرفة أو لا. وعليه أظهرت البيانات القيم المفقودة التالية:

الجدول رقم (02): يوضح القيم المفقودة المتعلقة بالبيانات الدراسة

المستغير	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	R13	R14	R15	R16	R18	R19	R20	R21	R22	R23	
التكرار	11	11	42	11	10	15	10	10	9	20	10	10	9	11	10	15	11	42	10	11	9	15	9
نسبته	0,98	0,98	3,73	0,98	0,89	1,33	0,89	0,89	0,80	1,77	0,89	0,89	0,80	0,98	0,89	1,33	0,98	3,73	0,89	0,98	0,80	1,33	0,80

المصدر: اعداد الباحثان بالاعتماد على مخرجات البايثون

ونظرا لتأثر مخرجات الدراسة بوجود القيم المفقودة، كان لابد من معالجتها حيث تم استخدام أكثر الطرق شيوعا واستخداما وهي طريقة المتوسطات، وبما أنها بيانات كمية نستدل في وصفها على المقاييس التالية (mean, std, min, 25%, 50%, 75% max)، والجدول أدناه يوضح تعويض القيم المفقودة.

الجدول رقم (03): التحليل الوصفي للمتغيرات المالية لوضعية المؤسسات

	count	mean	std	min	25%	50%	75%	max
Y	1127.0	0.882343	0.465772	0.00	0.000	1.00	1.000	1.00
R1	1127.0	4.174359	49.478974	-11.16	0.545	1.00	1.865	1802.48
R2	1127.0	8.328117	73.922124	-0.88	0.795	1.38	2.370	2443.93
R3	1127.0	1.128705	159.576506	-3145.55	-0.115	0.29	0.950	1371.19
R4	1127.0	1.203737	10.563210	-0.35	0.040	0.16	0.640	304.14
R5	1127.0	0.842605	1.741233	0.00	0.350	0.61	0.800	41.40
R19	1127.0	6.524828	109.602682	-967.87	-1.500	1.88	6.905	2446.08
R20	1127.0	647.956817	6052.956350	-15349.69	-2.765	13.90	73.920	172456.97
R21	1127.0	0.071601	0.738084	-1.89	-0.010	0.02	0.070	20.70
R22	1127.0	0.115513	3.959963	-63.32	-0.020	0.06	0.235	28.62
R23	1127.0	2.768094	92.581476	-269.47	0.000	0.10	0.355	3094.37

المصدر: اعداد الباحثان اعتمادا على مخرجات البايثون

نلاحظ من الجدول أن تعداد المؤسسات السليمة يمثل 769 حالة أي ما نسبته 68,21%، وتم ترميزه بـ (Y = 1). أما تعداد المؤسسات المتعثرة يمثل 358 حالة أي ما نسبته 31,79% من إجمالي المؤسسات، وتم ترميزها بـ (Y = 0).

الجدول رقم (04): الحالة المالية للمؤسسات

حالة المؤسسة	الرمز	التكرار	نسبته
سليمة	1.0	769	68,21%
متعثرة	0.0	358	31,79%

المصدر: اعداد الباحثان اعتمادا على مخرجات البايثون

## 2.4 نموذج الدراسة:

تم تصميم وتدريب نموذج الخوارزمية الجينية باستخدام بمتجهات الدعم الآلي، لتحسين أدائها في التنبؤ بالفشل المالي للمؤسسات الجزائرية محل دراستنا، فمرحلة بناء النموذج كانت كما يلي:

❖ كخطوة أساسية تم تقسيم البيانات إلى عيني تدريب واختبار (80%، 20% على التوالي)، لاحظ الجدول رقم (05)؛

الجدول رقم (05): تقسيم بيانات الدراسة إلى عيني تدريب واختبار

التسمية	تقسيم البيانات
(عينة التدريب، عدد المتغيرات)	(10,902)
(عينة التدريب،)	(,902)
(عينة الاختبار، عدد المتغيرات)	(10,226)
(عينة الاختبار،)	(,226)

المصدر: اعداد الباحثان اعتمادا على مخرجات البايثون

❖ تم تصميم وتدريب نموذج الخوارزمية الجينية باستخدام متجهات الدعم الآلي، لتحسين أدائها في التنبؤ بالفشل المالي للمؤسسات الجزائرية الاقتصادية محل الدراسة، وبناء النموذج والاعتماد على

مدخلات الدراسة 23 نسبة مالية بأنواعها (سيولة، ربحية، نشاط ومدىونية)، والمتغير التابع الذي يمثل الحالة المالية للمؤسسات فاشلة أو سليمة. وعليه يتكون هيكل متجهات الدعم الآلي من المعلمات الفائقة الضرورية التالية:

✓ **'C'**: حيث تمثل معلمة تحسين درجة التصنيف الصحيح أو التحسين الذي يجب أن تفي به

الخوارزمية لكل نقطة خطأ، وتصنيف جميع نقاط التدريب بشكل صحيح؛

✓ **\*Kernel**: هي دالة مستخدمة للمساعدة في حل المشكلات التصنيف ولتجنب العمليات

الحسابية المعقدة وتمثلت في (linear, 'poly', 'rbf', 'sigmoid) ليختار النموذج أي الدوال أصلح لتوليد جيل جديد؛

❖ بعد تحديد معلمات متجهات الدعم الآلي، تم تجميع نموذج لقيامه بعملية التصنيف عن طريق

تدريب الخوارزميات الجينية بـ SVM، وكانت معلماته تتمثل في:

✓ **Params**: وهي المعلمات المتمثلة في الخطوة السابقة 2؛

✓ **Estimator**: والمتمثل في المصنف 'clf'، بما أننا نقوم بعملية التصنيف بين المؤسسات الاقتصادية الجزائرية؛

✓ **Scoring**: وهو تحديد مقياس التصنيف المستخدم في دراسة البيانات وتمثل في "accuracy"؛

✓ **CV**: تقسيم بيانات الدراسة إلى 3 عينات مختلفة لتقدير مهارة النموذج على البيانات الجديدة،

عن طريق تقسيم العينة الأصلية إلى عيني تدريب، لتدريب النموذج وعينة اختبار لتقييمه، ثم التحقق من صحة النموذج في عينة الاختبار وبتكرير الخطوات السابقة عدة مرات لتقديم أفضل نموذج؛

✓ **population\_size**: تم تحديد حجم المجتمع بالقيمة 10 من خلال عملية التجربة والخطأ؛

✓ **tournament\_size**: تم تحديد حجم اختبار الأفراد بالقيمة 3 لتوليد جيل جديد من خلال

عملية التجربة والخطأ؛

\* تشير النواة (kernel) إلى طريقة تسمح لنا بتطبيق المصنفات الخطية على المشكلات غير الخطية عن طريق تعيين البيانات غير الخطية في مساحة ذات أبعاد أعلى دون الحاجة إلى فهم ذلك الفضاء ذي الأبعاد الأعلى، والشئ المدهش فيها هو أننا تمكننا من إجراء حسابات سلسلة بمساعدة منها.

✓ **gene\_mutation\_prob**: وهي احتمالية الطفرة الجينية حيث تم تركها بشكلها الافتراضي وحددت بـ 0.10؛

✓ **gene\_crossover\_prob**: وهي احتمالية العبور الجيني وهي الأخرى تركت بشكلها الافتراضي، وحددت بـ 0.5؛

✓ **generations\_number**: وبالنسبة لتوليد الأجيال تم تحديدها بـ 5 أجيال.

❖ تقييم ولياقة النموذج: بعد القيام بالخطوات الثلاثة السابقة فإن النموذج يقوم بالتقييم واللياقة، من خلال اختيار أفضل المعلمات، مقابل الحصول على مخرجات تدريب الخوارزمية الجينية كالدقة (Accuracy) وأفضل فرد في الخوارزمية الجينية؛

❖ وكخطوة أخيرة قمنا بتنفيذ تعليمات النموذج على عينة التدريب للتحقق من دقتها في عينة الاختبار.

وبعد بناء النموذج وتنفيذ الخوارزمية، كانت النتائج موضحة أدناه كما يلي:

الجدول رقم (06): مخرجات تدريب الخوارزميات الجينية بمتجهات الدعم الآلي

```
Types [2, 1] and maxint [999, 3] detected
--- Evolve in 4000 possible combinations ---
gen      nevals  avg          min           max           std
0         10     0.771631    0.626773    0.904255    0.0965492
1         7      0.831472    0.695922    0.904255    0.081684
2         8      0.900266    0.853723    0.909574    0.0156755
3         3      0.902482    0.887411    0.909574    0.00699175
4         9      0.901862    0.887411    0.909574    0.00896267
5         4      0.90922     0.906028    0.909574    0.00106383
6         7      0.909574    0.909574    0.909574    1.11022e-16
Best individual is: {'C': 46.57441885021812, 'kernel': 'poly'}
with fitness: 0.9095744680851063
{'C': 46.57441885021812, 'kernel': 'poly'}
Accuracy: 0.9095744680851063
```

المصدر: اعداد الباحثان اعتمادا على مخرجات البايثون

وفي ضوء ما سبق تبين النتائج أن:

الخوارزميات الجينية تبحث بنجاح عن قيم معلمات SVM التي تعمل على تحسين نسبة الدقة بطريقة SVM، وهذا دليل أنها فعالة للغاية، خاصة البيانات الصغيرة ومع ذلك، فإن توقيت تنفيذ الخوارزمية الجينية سيزداد مع زيادة حجم السكان، التوليد، نطاق قيمة المعلمة وكذلك حجم البيانات، وعليه يؤدي هذا إلى طول عملية التنفيذ، مما يجعلها أقل كفاءة عند مقارنتها بزيادة قيمة الدقة. فخوارزمية متجهة الدعم الآلي التي تم الحصول عليها بتدريب وتصميم الخوارزمية الجينية صنفت أن أنسب وأفضل فرد يحمل الميزات التالية:

• المعلمة C قيمتها 46.5744، وهي التي تحسن درجة التصنيف وكل نقطة خطأ في نقاط التدريب؛

• دالة kernel: poly كانت الأفضل من بين باقي الدوال، لقدرتها على التصنيف الثنائي للمؤسسات الاقتصادية الجزائرية بالتعثر أو السلامة؛

تظهر نتائج البحث عن قيمة معلمة SVM التي تعمل على تحسين قيمة الملاءمة باستخدام الخوارزمية الجينية وزيادة في دقة تصنيف البيانات وهذا مما يثبت أن تحسين معلمات SVM باستخدام الخوارزميات الجينية تنجح في تحقيق الدقة المثلى، ونتج عن ذلك دقة تصل إلى 0.9095 أي ما نسبته 90,95%، وهي نسبة جيدة للتمييز وتصنيف المؤسسات الجزائرية.

## 5. خاتمة:

تم تنفيذ SVMs في العديد من تطبيقات والعديد من المجالات البحثية كالتصنيف، الانحدار، حيث أظهر العديد من الباحثين أن SVMs أفضل من تقنيات التصنيف الحالية الأخرى، ومع ذلك، وعلى الرغم من أن SVM لديها بعض القيود المتعلقة باختيار المعلمات، التعقيد الحسابي، مجموعات البيانات متعددة الفئات ومجموعات البيانات غير المتوازنة، فقد تم تنفيذ SVM في العديد من مشاكل التصنيف الواقعية بسبب أسسها النظرية الجيدة وقدرتها على التعميم، ويتضح من خلال هذه الدراسة أن تحسين نموذج متجهات الدعم الآلي باستخدام الخوارزميات الجينية له خطوات واضحة، منظمة ومنطقية، وبالتالي، من المحتمل أن تستمر SVMs في تقديم رؤى قيمة حول الكمية المتزايدة وتنوع بيانات المؤسسات.

وتوصلنا في دراستنا هذه إلى النتائج التالية:

- تمثلت الفرضية الرئيسية: في أنه 'يتميز نموذج الخوارزميات الجينية بتحسين وتدريب نموذج متجهات الدعم الآلي بدقته العالية في التنبؤ بالفشل المالي للمؤسسات الجزائرية.' هي فرضية صحيحة وذلك من خلال النتائج المتوصل إليها في دراستنا، وهذا ما أثبتته النموذج حيث كلما حاولنا تحسين نموذج الخوارزميات الجينية بتدريبها بنموذج متجهات الدعم الآلي كلما كانت نسبة دقة النموذج أفضل وأمثل وهذه هي غاية نماذج الذكاء الاصطناعي تحسين النماذج من أحسن فأفضل إلى الأمثل.
- بلغت دقة التنبؤ بالفشل المالي للمؤسسات الجزائرية لنموذج الخوارزميات الجينية المدربة والمصممة بالمتجهات الدعم الآلي 90,95%؛
- قوة نموذج متجهات الدعم الآلي خصوصا بتهجينه بالخوارزميات الجينية؛
- تم التوصل الى أن النسب المالية لها دور كبير في التنبؤ بالفشل المالي والكشف عن الوضعية المالية للمؤسسات الجزائرية.
- وكتوصيات لدراستنا تم اقتراح ما يلي:
- إضافة متغيرات نوعية للكمية وإعادة دراسة مدى دقة النموذج؛
- استخدام نماذج تحسين أخرى من نماذج الذكاء الاصطناعي كخوارزميات مستعمرات النمل، مستعمرات النحل، اسراب الطيور... الخ
- مراعاة الإفصاح والشفافية للقوائم المالية وغيرها من الوثائق الضرورية والمصرحة من طرف المؤسسات، لتقديم نتائج دقيقة واقعية.

## 6. قائمة المراجع:

- Acosta-González, E., & Fernández-Rodríguez, F. (2013, 07 28). Forecasting Financial Failure of Firms via Genetic Algorithms. *Comput Econ*, (-), 1-25.
- Kim, M.-J., & Kang, D.-K. (2012). Classifiers selection in ensembles using genetic algorithms for bankruptcy prediction. *Expert Systems with Applications*, 39, 9308–9314.
- Lessmann, S., Stahlbock, R., & Crone, S. (July 16-21, 2006). Genetic Algorithms for Support Vector Machine Model Selection.

- International Joint Conference on Neural Networks* (pp. 3063-3069). Canada: IEEE.
- Chen, P.-H., Lin, C.-J., & Scholkopf, B. (2005). A tutorial on n-support vector machines. *APPLIED STOCHASTIC MODELS IN BUSINESS AND INDUSTRY*, 21, 111-136.
- Guo , C., & Yang, X. (2011, February). A Programming of Genetic Algorithm in Matlab7.0. . *Modern Applied Science*, 5(1), 230-235.
- JavaPoint. (2023). *Support Vector Machine Algorithm*. Retrieved from java T point: <https://www.javatpoint.com/machine-learning-support-vector-machine-algorithm>
- Mammone, A., Turch, M., & Cristianini, N. (2009, 12). Support vector machines. *WIREs Computational Statistics*, 01, 283- 289.
- Manurung, J., Mawengkang, H., & Zamzam, E. (2017). Optimizing Support Vector Machine Parameters with Genetic Algorithm for Credit Risk Assessment. *International Conference on Information and Communication Technology (IconICT)* (pp. 1-6). Journal of Physics: Conference Series.
- Niraula, N. (2010, November 11). *Genetic Algorithm*.
- أبوبكر خوالد، و خير الدين بوزرب. (2020 ,06 10). فعالية استخدام تطبيقات الذكاء الاصطناعي الحديثة في مواجهة فيروس كورونا (COVID-19): تجربة كوريا الجنوبية نموذجاً. مجلة بحوث الادارة والاقتصاد، 2(2)، 34-49.
- بدر السيد. (2016). تصميم و تحليل الخوارزميات. القاهرة، كلية الحاسبات والمعلومات، مصر: المكتبة العربية.
- حسين خليفة. (2013). الحل الأمثل لنظم توزيع شرب المياه باستخدام تقنية الخوارزميات الجينية. I- 130. اللاذقية، سوريا. دمشق: جامعة اللاذقية.
- رميصاء بوسنة، و مصيطفى عبد اللطيف. (أفريل، 2018). محاولة بناء مؤشرات التعثر المالي باستخدام طريقة المركبات الأساسية ACP خلال الفترة 2009-2014. (كلية العلوم الاقتصادية والتجارية وعلوم التسيير، جامعة غرداية) مجلة إضافات إقتصادية، 2(3).
- شهلة خروفة. (2010). استخدام الخوارزمية الجينية لتحديد خصائص صور الأبنية. مجلة تكريت للعلوم الصرفة، 15(1)، 301-309.
- عباس عبد الرحمان، و حسين خليفة. (2012). الحل الأمثل لنظم توزيع مياه الشرب باستخدام تقنية الخوارزميات الجينية. مجلة تشرين للبحوث والدراسات العلمية، 34(4)، 155-173.

- عبد الرزاق مريخي. (2020). الانذار بالفشل المالي للمؤسسات الاقتصادية بتطبيق مقارنة الشبكات العصبية الاصطناعية-حالة عينة من مؤسسات الجزائرية-. أطروحة دكتوراه علوم في المحاسبة والتدقيق. الجزائر: جامعة الجزائر03.
- علي جنود، رائد جعفر، و نغم عصفوري. (2013). تقدير الكلف الأولية للمشاريع الهندسية باستخدام نموذج هجين بين الخوارزميات الجينية والشبكات العصبونية. مجلة جامعة تشرين للبحوث والدراسات العلمية، 35(7)، 243-261.
- عمر صابر قاسم، و محمد علي محمد الوزان. (2018). تحسين أداء تصنيف تقانة آلة المتجه الداعم باستخدام الخوارزمية الجينية. مجلة الراصد للعلوم الحاسوب والرياضيات، 12(2)، 49 - 60.
- عوني محمد الصغير، و رضا زهواني. (2022). التنبؤ بالفشل المالي. (جامعة الواد، المحرر) مجلة الاقتصاد والتنمية المستدامة، 05(01)، الصفحات 469-491.
- فضيلة فراحي. (2022). استخلاص المتغيرات الاقتصادية المحفزة لنشاط بورصة الجزائر باستخدام خوارزمية متجه الدعم الآلي. Les Cahiers du Cread، 38(03)، 147-175.
- لمجد بوزيدي، و عبد الرحمان بن عيسى. (2020، 10). دور طريقة متجهات شعاع الدعم الآلي SVM في تحليل وإدارة المخاطر في المؤسسة الاقتصادية. دراسات وأبحاث المجلة العربية للأبحاث والدراسات في العلوم الانسانية والاجتماعية، 12(04)، 168 - 178.
- محمد داود الحدابي، أحمد عبد العظيم العمري، عبد القادر محمد العبادي، و محمد خضر محمد نور. (2004). استخدام الخوارزميات الجينية في حل مشكلة الجداول الدراسية الجامعية. مجلة العلوم والتكنولوجيا، 9(1 و 2)، 3-13.
- وزارة التجارة. (2021). السجل التجاري مؤشرات واحصائيات. تم الاسترداد من مركز الوطني للسجل التجاري:

[https://sidjilcom.cnrc.dz/web/cnrc/recherche\\_efournisseur#navigation](https://sidjilcom.cnrc.dz/web/cnrc/recherche_efournisseur#navigation)