

مساهمة الخوارزمية الجينية في تحسين فعالية قرار منح القروض

- محاولة بناء نموذج (XGBoost-GA)

The Contribution of Genetic Algorithm in Enhancing the Effectiveness of Loan Approval Decisions: An Attempt to Develop an (XGBoost-GA) Model

خيدر زاهوي¹، عبد الله عنيش²، عبد اللطيف مصيطفي³¹ جامعة غرداية، مخبر التنمية الإدارية للارتقاء بالمؤسسات الاقتصادية بولاية غرداية، الجزائر، khider.zahoui@univ-ghardaia.dz² جامعة غرداية، الجزائر، مخبر التنمية الإدارية للارتقاء بالمؤسسات الاقتصادية بولاية غرداية، anichel.abdallah@univ-ghardaia.dz³ جامعة غرداية، الجزائر، مخبر التنمية الإدارية للارتقاء بالمؤسسات الاقتصادية بولاية غرداية، messaitfa.abdellatif@univ-ghardaia.dz

تاريخ النشر: 2025/09/15

تاريخ القبول: 2025/08/13

تاريخ الاستلام: 2024/11/18

ملخص

تهدف هذه الدراسة الى محاولة بناء نموذج تصنيفي باستخدام أحد نماذج تعلم الآلة (Extreme Gradient boosting) للحصول على نموذج أولي ثم محاولة تحسينه باستخدام تقنية الخوارزمية الجينية (GA)، تمثلت عينة الدراسة في 140 مؤسسة جزائرية مقسمة إلى 90 مؤسسة سليمة و 50 مؤسسة عاجزة و 16 نسبة مالية، كما تم تنفيذ النموذج باستخدام لغة البرمجة python على أرضية googlecolab.

توصلت الدراسة إلى أن نموذج (XGBoost) استطاع تحقيق دقة تصنيف قدرها 85.41% وبعد توظيف تقنية الخوارزمية الجينية من أجل الحصول على (Hyperparameters) التي تحقق أعلى درجة تصنيف ممكنة، حيث حقق النموذج (XGBoost-GA) دقة تصنيف قدرها 96%.

الكلمات المفتاحية: منح القروض، نموذج تعزيز التدرج الشديد، الخوارزمية الجينية.

تصنيفات JEL: C45, G21, C61

Abstract:

This study aims to build a classification model using one of the machine learning models (Extreme Gradient Boosting) to create an initial model, then attempt to improve it using Genetic Algorithm (GA) techniques. The study sample consisted of 140 Algerian companies, divided into 90 healthy companies and 50 distressed companies, with 16 financial ratios. The model was implemented using Python programming language on the Google Colab platform.

The study found that the XGBoost model achieved a classification accuracy of 85.41%. After applying the Genetic Algorithm technique to optimize the hyperparameters for the highest possible classification accuracy, the XGBoost-GA model achieved a classification accuracy of 96%.

Keywords: Loan granting, Extreme Gradient Boosting Model, Genetic Algorithm.

JEL Classification codes: C45, G21, C61

1. مقدمة:

يتمثل قرار منح القروض في الدور الرئيسي المنوط بعمل البنوك ، بحيث تسعى البنوك من خلال هذا النشاط بتوظيف أموالها لتمويل أرباب العمل والمؤسسات من أجل توسيع نشاطاتها المختلفة أو لتمويل عجز مؤقت أو غيرها ، حيث تحصل البنوك على ربح معين من هذا العمل ، والذي يتمثل في النهاية من استرجاع مبلغ القرض مع العائد المتفق عليه في عقد القرض الذي يتضمن المبلغ والمدة والطريقة التي يتم فيها الاسترداد والتصفية.

لكن كما هو معروف عند مديري البنوك ومحللي الائتمان والعديد من الباحثين أن هذا النشاط ترتبط به العديد من المخاطر التي تحول دون تحقق العائد المتوقع واكتمال عملية التسديد والتي يطلق عليها في كثير من أحيان مصطلح خطر القرض أو خطر عدم التسديد الناتج عن صعوبات تواجه العميل مثل عدم الكفاءة الادارية أو نقص في الجانب المالي للعميل .

وفي وقت ليس ببعيد كان يتم الاعتماد على التحليل المالي من أجل دراسة وضعية العميل وذلك عن طريق تحليل القوائم المالية الخاصة بالمقترض من أجل معرفة نقاط القوة والضعف لديه ثم الخروج بقرار هل يتم تمويله أم لا .

بعد ذلك ظهرت عدة أساليب رياضية واحصائية تم العمل عليها مثل القرض التنقيطي أو طريقة رجال القرض ثم تلتها عدة نماذج أخرى تعتبر جديدة ظهرت مع التطور الحاصل في مجال الذكاء الاصطناعي مثل الشبكات العصبية الاصطناعية والنظم الخبيرة وغيرها .

تعتبر الخوارزمية الجينية أحد أهم التقنيات التحسين ويعتبر نموذج تعزيز التدرج الشديد (**Extreme Gradient Boosting**) أحد نماذج تعلم الآلة التي ظهرت في سنة 2014 والتي حققت دقة عالية في بناء النماذج التصنيفية والانحدارية.

ومما سبق يمكن طرح الإشكالية على الطريقة التالية: كيف يمكننا الاستعانة بتقنية الخوارزمية الجينية في تحسين دقة تصنيف

نموذج XGBoost؟

• فرضيات الدراسة

- تعتبر الخوارزمية الجينية تقنية فعالة في تحسين الحلول
- يمكن بناء نموذج تعزيز التدرج الشديد (XGB) وتحسينه بالخوارزمية الجينية (GA) للحصول على دقة تصنيف عالية.

• أهمية الدراسة:

تكمن أهمية الموضوع فيما يلي:

- محاولة تناول الموضوع بطريقة مختلفة باستخدام نماذج جديدة.
- تسليط الضوء على تقنية الخوارزمية الجينية وأهميتها في تحسين الحلول.
- إبراز مدى أهمية نماذج تعلم الآلة في حل المشاكل المعقدة.

• أهداف الدراسة:

- وضع إطار مفاهيمي للخوارزمية الجينية واستخداماتها
- ذكر أهم الأساليب والنماذج التي تناولها الباحثون في مجال منح القروض
- بناء نموذج جيد من حيث دقة التصنيف
- شرح نموذج تعزيز التدرج الشديد

• منهجية الدراسة:

تم إتباع المنهج الوصفي التحليلي في عرض الجانب النظري للدراسة ، والمنهج القياسي في الجانب التطبيقي للدراسة.

• الدراسات السابقة:

1- دراسة: stjepanoreski& Goran oreski 2014

Genetic algorithm-based heuristic for feature selection in credit risk assessment

قام الباحثان في هذه الدراسة ببناء نموذج هجين وهو دمج بين الخوارزمية الجينية و الشبكات العصبية من أجل اختيار أهم المتغيرات التي تزيد في دقة التصنيف ، حيث تمثلت العينة في 1000 طلبات قروض لدى بنك في كرواتيا قسمت الى 750 زبون صنف جيد و 250 زبون غير جيد وتم الاعتماد على 35 متغير ، قام الباحثان بالمقارنة بين نموذجين تم بنائهما النموذج الأول هو GA_NN والنموذج الثاني هو HGA_NN ، حيث حقق النموذج الأول دقة تصنيف قدرها 78.50% والنموذج الثاني حقق 78.90%.

2- دراسة: (AkinmoluwaOluseyeAyobami وآخرون 2023)

Predicting Credit Risk : Using Machine Learning Algorithms to Predict the Creditworthiness of Borrowers and Determine their Likelihood of Defaulting on Loans in Nigeria

قام الباحثون في هذه الدراسة بمحاولة بناء اربع نماذج تعلم آلي و بالاستعانة بقاعدة بيانات تمثلت في 654 ملف طلب قرض مقسمة الى 152 مقترض صنف سيء تم ترميزه ب صفر 0 و 502 مقترض جيد تم ترميزه بقيمة واحد 1 ، الملفات تم الحصول عليها من بنك zindiafrica وكانت النتائج المتحصل عليها كالتالي : نموذج Gaussian NB بدقة 76.75% ، نموذج الغابات العشوائية (RF) بدقة 76.29% ، نموذج Gradient boosting classifier بدقة 76.29% ، نموذج DecisionTreeClassifier بدقة 64.76%.

3- دراسة: (Nazin UDDIN وآخرون 2023)

An ensemble machine learning based bank loan approval predictions system with a smart application

قام الباحثون في هذه الورقة العلمية ببناء نظام ذكي للتنبؤ بجدارة المقترض وذلك بالاستعانة بنماذج التعلم الآلي (ensemblemachine learning) ، تم جلب قاعدة بيانات من kaggle source مكونة من 806 ملف طلب قرض مقسمة الى (422=yes) و (no=384) وكانت النتائج كالتالي:

الجدول 01: النتائج التي تحصل عليها الباحثون

Table 4 Model Wise Accuracy Performance.	
Model Name	Accuracy (%)
Logistic Regression (LR)	70.06
Decision Tree (DT)	78.98
Random Forest (RF)	84.71
Extra Trees (ET)	86.64
Support Vector Machine (SVM)	68.15
K-Nearest Neighbors (KNN)	79.61
Gaussian Naive Bayes (GNB)	68.15
AdaBoost (AdB)	71.33
Gradient Boosting Classifier (GBC)	79.61
Dense Neural Network (DNN)	73.24
Long Short-Term Memory (LSTM)	71.33
Recurrent Neural Network (RNN)	73.24

المصدر: Nazin UDDIN وآخرون 2023، ص 336 .

2. الأدبيات النظرية للدراسة:

1.2 الخوارزمية الجينية:

تعتبر هذه التقنية (Genetic Algorithm) أحد أهم الأساليب في البحث عن الحلول المثلى ومسائل التحسين وتنتمي إلى مجال الحوسبة التطورية Evolutionary Computation والذي يعتبر هذا الأخير جزء أو فرع من حقل الذكاء الاصطناعي Artificial Intelligence .

ويرتكز الأساس الفكري لهذه التقنية (GA) على أفكار العالم تشارلز داروين في كتابه "أصل الأنواع On the Origin of Species، والذي يتكلم فيه عن نظرية الانتقاء الطبيعي Natural sélection ، ويصف العملية التطورية للحياة على الأرض، وأن البقاء للأصلح والأقوى ، بينما يموت الضعيف أو غير المجهز ، وكيفية انتقال الصفات والميزات الوراثية عبر الأجيال. تم تطوير هذه الطريقة من قبل John Holland وأحد طلبته David Goldberg في جامعة Michigan في تسعينيات وسبعينيات القرن الماضي ، والذي استطاع حل مشكلة معقدة في أطروحته (Goldberg، 1989) والتي تتمثل في مراقبة أنابيب نقل الغاز.

ويمثل العمل الأصلي لـ Holland في كتابه "Adaptation in natural and artificial systems" الذي يعتبر أول من استطاع وضع الأساس النظري للخوارزمية الجينية (GA). (Randy & Sue , 2004, pp. 22-23) تقوم الخوارزمية الجينية بالنظر إلى طبيعة المسألة من منظور جيني لذلك اكتسبت هذا الاسم ، فكل حل فيها يمثل صبغي chromosome ولكل متغير ضمن الحل يمثل موروث أو ميزة أو صفة genes .

تقوم الخوارزمية الجينية بتقييم كل فرد من الأفراد باستخدام ما يسمى بتابع الملائمة ، ومن ثم لتحسين مجموعة الحلول تقوم الخوارزمية باختيار الأفضل من هذه الحلول عبر طرائق الاختيار المختلفة. (محمد ، 2021 ، صفحة 23)

1.1.2 أهم ما يميز الخوارزمية الجينية: (حسين ، 2022 ، صفحة 43)

- تقوم في مجتمع يكون عبارة عن مجموعة من المشاهدات وليس يختص بوحدة.
- لها ميزة في استعمال القوانين الاحتمالية ولا تستعمل القوانين الكلاسيكية .
- تمتاز الخوارزمية الجينية بأنها لا تتعامل مع المتغيرات نفسها ولكن تتعامل مع التشفير لمجموعة المتغيرات.
- تتميز الخوارزمية الجينية بأنها لا تتوسع في معلومات إضافية بل تستعمل دالة الهدف مباشرة (objective function) .

2.1.2 تطبيقات الخوارزمية الجينية :

تم تطبيق هذه التقنية في العديد من المجالات لا يمكننا حصرها و معرفتها كلها لكن نذكر أغلب المجالات التي صادفتنا دراسات تطرقت لها ، تم استخدامها في مجال الطب والإدارة ومشاكل التحسين و مشاكل التخطيط والإنتاج والتوزيع في مجال المياه وفي التعرف على أنماط الصور وفي مجال الكهرباء والميكانيك وغيرها ، ويمكن ذكر بعض الاستخدامات كالتالي: (Sivanandam & Deepa, 2008, p. 35)

- الأنظمة الديناميكية غير الخطية - التنبؤ وتحليل البيانات.
- تخطيط مسار الروبوت.
- وظائف لإنشاء الصور.
- الجدولة - التصنيع ، جدولة المرافق ، تخصيص الموارد.
- التعلم الآلي - تصميم الشبكات العصبية ، سواء الهندسة المعمارية أو الأوزان ،

- تحسين خوارزميات التصنيف وأنظمة المصنف.

- التحسين التوافقي - تغطية المجموعة ، البائع المتجول (TSP) ، التسلسل.

3.1.2 خطوات تطبيق الخوارزمية الجينية:

يمكن كتابة خطوات التي تمر بها الخوارزمية الجينية كالتالي: (موفق، 2019، صفحة 41)

1- البداية: تشكيل المجتمع الابتدائي متكون من عدة أفراد متمثلة في كروموسومات

2- التقييم: من خلال دالة الملائمة يتم تقييم كل فرد واستخراج قيمة الملائمة الخاصة به

3- التوليد: إنشاء جيل جديد من خلال ثلاث مراحل التالية:

- الاختيار (selection)

- التزاوج أو التقاطع (crossover)

- الطفرة (mutation)


4- الاستبدال: استبدال الأفراد الأقل ملائمة في الجيل السابق بأفراد أفضل ملائمة في الجيل الجديد.

5- التوقف: إذا توفرت معايير الانهاء وتم الحصول على حلول جيدة يتم التوقف وأخذ أفضل حل ، وإذا لم يتوفر معيار التوقف يتم

العودة بالجيل الحالي الى مرحلة التقييم (evaluation).

والشكل التالي يوضح طريقة الانتقال من خطوة الى خطوة:

الشكل 01: مخطط تنفيذ خطوات الخوارزمية الجينية



source: Alokumar and other, Overview of Genetic Algorithm Technique for Maximum Power Point Tracking (MPPT) of Solar PV System ,International Journal of Computer Applications, Innovations in Computing and Information Technology (Cognition 2015), p23.

2.2 أهم النماذج التي استخدمت في دعم قرار منح القروض:

إن اتخاذ قرار منح القرض أمر تحوطه الكثير من المخاطر ، وهو موضوع تناوله الباحثون من عدة جوانب ، كما أنه موضوع قديم ومعاصر ، كما تعتبر البنوك مؤسسات تجارية تسعى الى تعظيم أرباحها فهي تمارس نشاطها من خلال وظائفها المتعددة ، ومن بينها منح القروض لدعم الأعمال والمشاريع ، ويتم منح القروض غالبا تحت شروط وضمانات وغيرها، هذا راجع الى أن بيئة الأعمال المصرفية دائما ما تلازمها عدة أنواع من المخاطر سواء كانت مخاطر مالية أو مخاطر تشغيلية ، مخاطر خاصة بالبنك وأخرى متعلقة بالزبون ، مخاطر متعلقة بالسوق... الخ.

لقد استخدم الباحثون عدة نماذج لدراسة هذا الموضوع ، ويتم في العادة استخدام نوعين من النماذج :

- نماذج تصنيفية (classification) : تهدف الى معرفة التصنيف الصحيح لطلبات القرض من ضمن مجموعتين من القروض ، قروض سليمة وأخرى عاجزة .

- نماذج البرمجة (max) : وتهدف إلى اختيار محفظة القروض التي تعظم ارباح البنك .

عند بناء هذه النماذج يتم الاعتماد على عدة متغيرات محاسبية (النسب المالية) ومتغيرات فوق المحاسبية (المتغيرات الكيفية)، سوف نحاول ذكر بعض النماذج التصنيفية كالتالي:

1.2.2 نموذج القرض التنقيطي:

يمكن تعريف هذا النموذج على أنه: " طريقة تحليل إحصائية تسمح بإعطاء نقطة خاصة بكل زبون لتعبر عن درجة ملائته المالية". (العايب، 2008، صفحة 34)

تعتبر هذه الطريقة (scoring) طريقة آلية في تنقيط و تصنيف خطر القرض، تعتمد على معالجة المعلومات (المتغيرات المحاسبية وغير المحاسبية)، وتستعمل التحليل الإحصائي الذي يسمح بتخصيص علامة لكل زبون، هذه العلامة تمثل درجة الخطر بالنسبة للبنك.

ظهرت هذه الطريقة في اختيار الزبائن في الولايات المتحدة الأمريكية خلال الخمسينات وبدأ العمل بها تدريجاً في أوروبا في السبعينات، وهي اليوم شائعة الاستعمال في كثير من المؤسسات المالية.

إذن القرض التنقيطي هو إعطاء نقطة " score " للزبون الطالب للقرض لتحديد وضعيته

و تقييمه من خلال نموذج تقييمي على شكل معادلة خطية لعدة متغيرات (النسب المالية، طبيعة القروض، قطاع النشاطات...) حيث يمكن مقارنة النقطة المعطاة لكل زبون مع نقطة فصل محددة مسبقاً، وعلى هذا الأساس يكون رفض أو قبول طلب القرض. (محمد و يوسف، أبريل 2007، صفحة 4)

تعطى دالة التمييز على الصيغة التالية:

$$Z = \sum \alpha_i R_i + \beta$$

حيث أن :

α_i : المعاملات المرتبطة بالنسب R_i (معاملات التسوية أو الترجيح).

R_i : النسب المالية أو مؤشرات درجة الخطر.

β : ثابت و يعبر عن الجزء الثابت من درجة الخطر.

2.2.2 نموذج الانحدار اللوجستي الثنائي (binary):

هو نموذج احتمالي غير خطي يستخدم في نمذجة علاقة ما بين متغير تابع يكون ثنائي يأخذ القيمتين (0,1) ومتغيرات مستقلة كمية كانت او نوعية لا يهم أو مزيج بينهم. (فاروق، 2019، صفحة 120)
وتعطي دالة التوزيع اللوجستي (logistic function)، أو ما يسمى بالمنحنى "s" بالعبارة التالية: (Régis , 2018, p. 350)

$$p_i = \text{prob}(y_i = 1) = \text{prob}(y_i^* > 0) = \text{prob}(\beta_0 + \beta_1 x_i + \varepsilon_i > 0) \\ = \text{prob}(\varepsilon_i > -\beta_0 + \beta_1 x_i) = \theta(\beta_0 + \beta_1 x_i)$$

حيث (Θ) هي دالة التوزيع (اللوجستي) للقانون اللوجستي

$$p_i = \theta(a_0 + a_1 x_i) = \frac{\exp(a_0 + a_1 x_i)}{1 + \exp(a_0 + a_1 x_i)} = \frac{1}{1 + \exp(-(a_0 + a_1 x_i))}$$


خصائص هذه المعادلة هي:

إذا كان $a_1 > 0$

$$\lim_{x_i \rightarrow +\infty} p_i \rightarrow 1 \quad \text{و} \quad \lim_{x_i \rightarrow -\infty} p_i \rightarrow 0$$

ومنه نضمن أن قيم (P_i) تنتمي إلى المجال (0-1) كما هو موضح في الرسم البياني:

الشكل 02: منحنى الدالة اللوجستية



source: Régis Bourbonnais, Econométrie, 10^{ème} édition, DUNOD, Paris, 2018, p350.

يمكننا ملاحظة بعد إجراء التحويلات اللوغاريتمية أن الدالة اللوجستية يمكن كتابتها كالتالي: (Gujarati, 2004, p. 596)

$$\ln\left(\frac{p_i}{1 + p_i}\right) = y_i^* = \beta_0 + \beta_1 x_i + \varepsilon_i$$

هو الاحتمال المرتبط مع $(y_i = 1)$ ، هذه الخصائص يمكن تعميمها في حالة عدة متغيرات مفسرة.

3.2.2 نموذج الشبكات العصبية الاصطناعية (ANN)

تعتبر الشبكات العصبية الاصطناعية من الأساليب الحديثة التي تم العمل عليها في عدة أبحاث متواصلة ومتكاملة داخل حقل الذكاء الاصطناعي (من التعلم الآلي إلى التعلم العميق) من بداية أول أبحاث العالم النفساني (ويليام جيمس 1890) (طارق، صفحة 98)، إلى غاية (أبحاث) (العربي، 2021، صفحة 116) (Jeff Deam And Andrew Yan-Tak Ng 2012)، فهي تعتبر طريقة محاكاة عمل العصبون البيولوجي البشري، أي هي تقنية حاسوبية تم تصميمها لمحاكاة عمل الدماغ البشري لمهمة معينة، فهي نظام قادر على حل المشاكل المعقدة وذلك من خلال قدرته على معالجة ضخمة للبيانات موزعة على التوازي ومكونة من وحدات معالجة بسيطة (Neurons)، أو عقد والتي لها خاصية عصبية بحيث تقوم بتخزين المعلومات والمعرفة ومن ثم تكون جاهزة للمستخدم من خلال ضبط الأوزان، كما تعتبر هذه التقنية (ANN) طريقة قائمة على منهج التعلم أو التدريب من أجل التعرف على طبيعة البيانات ومن ثم محاولة محاكاتها.

ولا تزال الأبحاث مستمرة في تطوير هذا المجال من أجل بلوغ أهداف العلماء والتي من بينها إنشاء نظام له القدرة على محاكاة الحواس الخمسة للإنسان.

مكونات الشبكة العصبية الاصطناعية:

يمكن ذكرها باختصار كالتالي: (سهيلة، 2018، الصفحات 155-159)

- طبقة المدخلات: ويوجد بها عدد من العقد التي تمثل عدد المتغيرات المستقلة وهنا يتم استقبال المعلومة لتحويلها فيما بعد إلى الطبقة الموالية عن طريق العصبونات.

- الطبقة المخفية: وفي الطبقة الوسيطة وقد يوجد في الشبكة أكثر من طبقة مخفية.

- طبقة المخرجات: وهي طبقة تمثل نتائج أو مخرجات الشبكة

- وحدات المعالجة: وهي الوحدات التي تجري فيها العمليات الحسابية لضبط الأوزان ومن ثم الحصول على الأهمية النسبية لكل مدخل من مدخلات الشبكة.

- عقد الاتصال: حيث تقوم هذه العقد بربط عناصر المعالجة في مختلف الطبقات مع بعضها البعض ومن ثم تحديد معمارية الشبكة المناسبة للحل.


- الأوزان: وهو يعبر عن القوة النسبية لكل مدخل من مدخلات الشبكة.

- دالة التجميع: هي أول عملية يقوم بها العصبون وهي حساب مجموع المدخلات الموزونة القادمة إلى الوحدة باستخدام دالة التجميع.

- دالة التحويل: تعمل هذه الدالة على تحويل ناتج التجميع إلى أحد القيم التي يفترض أن تكون ضمن نواتج الشبكة المرغوب فيها،

- معدل التعلم: وهي نسبة التصحيح التي تعتمد من أجل التعديل في الأوزان الخلوية العصبية أثناء عملية التدريب، ويمكن توضيح مكونات الشبكة كما هو مبين في الصورة:

الشكل 03: مخطط مكونات الشبكة العصبية




source: James R. Coakley And Carol E. Brown, Artificial Neural Networks in Accounting and Finance : Modeling Issues, International Journal of Intelligent Systems in Accounting, Finance & Management, 9, 119-144 (2000), p121.

4.2.2 الأنظمة الخبيرة (Expert system):

يشير مصطلح نظام خبير إلى تلك الآلية التي تطبق في برامج الكمبيوتر والتي تستخدم مهارات ومعرفة الإنسان في مجال معين من أجل استخدامها في عملية محاكاة عمل الدماغ البشري في حل المسائل التي تتسم بالصعوبة والتعقيد، وذلك من خلال تحليل البيانات وإيجاد التوليفات وإجراء العمليات ثم تقديم النصائح الصحيحة والدقيقة، مما يساعد أي فرد أو مؤسسة على بناء واتخاذ قراراتهم ، وبالتالي الأنظمة الخبيرة هي فرع من فروع الذكاء الاصطناعي (Christina & Asmaa , p. 02) ، والشكل التالي يوضح كيفية عمل النظام الخبير:

الشكل 04: مخطط عمل النظام الخبير



source: Christina Albert Rayed, Asmaa Saeed Embark, op cit , p02.

مكونات النظام الخبير :

- القاعدة المعرفية: وهي مجمل ما يملكه الخبير من معلومات وحقائق وقواعد يتم صياغتها على شكل معادلات رياضية ومنطقية باستخدام لغات البرمجة المتوفرة مثل Python. (عبد الجليل، 2007، صفحة 33)
- محرك الاستدلال: ويعتبر أساس النظام الخبير حيث يعمل على إنشاء علاقات بين مختلف المعارف واستخلاص الاستنتاجات للتوصل إلى حل للمشكلة. (هاجر و جمال، 2023، صفحة 297)

- واجهة المستخدم: وهي الواجهة التي تربط المستخدم بالنظام الخبير ، ويجب أن تتصف بسهولة لغة الاتصال ، و وضوح النتائج والاستنتاجات.(يخلف و فاطمة الزهراء، 2019، صفحة 389)

5.2.2 تقديم نموذج تعزيز التدرج الشديد (XGBoost)

Extreme Gradient Boosting هي خوارزمية تعلم آلي تستخدم على نطاق واسع في عدة تطبيقات نظرا لكفاءتها وأدائها في التعامل مع البيانات الضخمة وغير المتوازنة، كما أنها تتفوق في التعامل مع مشاكل التصنيف والانحدار والترتيب. طورت هذه الخوارزمية كمشروع بحث علمي على يد الباحث CHenTiaqui في سنة 2014 كجزء من مجموعة التعلم الآلي العميق (DMLC(Luis)).

فهي تقنية تعتمد على تحسين التدرج (Gradient boosting)، بحيث ينطلق في البداية بتكوين نماذج أولية (مجموعة من النماذج الضعيفة أو مجموعة من الأشجار أو مجموعة من المتعلمين) ثم ينتقل خطوة بخطوة في بناء نماذج متسلسلة كل نموذج يحسن من النموذج السابق، وذلك من خلال التقليل من الأخطاء المتبقية بشكل تدريجي ، حتى يتم الوصول الى النموذج النهائي. حيث في حالات التصنيف، يتم تخصيص وزن أولي للأفراد، ويتم تعديل هذا الوزن بناءً على دقة توقعات النموذج. تلعب هذه الأوزان دوراً في التقدير اللاحق باستخدام النموذج (XGB).

غالباً ما تُستخدم خوارزميات الأشجار كمتعلمين ضعفاء في تقنية التعزيز التدريجي (Gradient Boosting). تتميز XGBoost بتوفير مجموعة واسعة من فرط المعلمات (Hyperparameters)، مما يمنح الممارسين تحكماً كاملاً في تطبيق تقنية التعزيز التدريجي (Gradient Boosting)، ما يتيح لهم إدارة العملية بشكل كامل عبر إدخال أنواع مختلفة من التنظيم (Regularization) ضمن دالة الخسارة، يمكن معالجة مشكلة الإفراط في التكييف (Overfitting) التي غالباً ما تواجهها خوارزميات التعزيز التدريجي بشكل فعال.

تستفيد XGBoost من مزيج من أشجار التصنيف والانحدار (Classification and Regression Trees - CARTs) للتعامل بفعالية مع المهام التي تشمل كلاً من التصنيف والانحدار ويُعبر عن نموذج التنبؤ الخاص بـ XGBoost كالتالي :

$$\hat{y}_i = \sum_{k=1}^k f_k(x_i)$$

حيث أن $(\hat{y}_i)$ تشير الى القيمة التنبؤية و k يمثل عدد أشجار القرار و f_k يمثل شجرة القرار رقم k . دالة الخسارة في خوارزمية XGBoost تتكون من مكونين: خطأ التدريب ويرمز له بـ L ومصطلح التنظيم ويرمز له بـ Ω ، ويمكن صياغتها كالتالي:

$$obj = \sum_{i=1}^n l(y_i, \widehat{y}_i^{(t-1)}) + \sum_{k=1}^k \Omega(f_k)$$

أما عن صيغة مصطلح التنظيم (regularization term) فتعطى كالتالي:

$$\Omega(f_t) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2$$

يساعد مصطلح التنظيم المضاف هنا في تنعيم الأوزان النهائية المتعلمة لتجنب الإفراط في التكيف (Overfitting). حيث يشير الرمز (T) في معادلة على عدد العقد الطرفية، و (w) تمثل درجة العقد الطرفية. (Adil & other, 2024, pp. 6-7)

(Hyperparameters) في خوارزمية XGBoost:

- Eta: معدل التعلم الذي يؤثر على سرعة التدريب ، حيث أن القيم الصغيرة تجنب الإفراط في التكيف.
- Max_depth: يتحكم في عمق الشجرة ويساعد في السيطرة على الإفراط في التكيف
- Min-child-weight: يقلل من التفرعات غير الضرورية عن طريق ضبط الحد الأدنى من حجم العينة في العقدة.
- Gamma: يحكم الانقسام بين العقد ويقلل من الإفراط في التكيف.
- Subsample: يحدد النسبة المئوية من البيانات التي سيتم استخدامها في كل خطوة، ويساعد في تقليل الإفراط في التكيف.
- Colsample-bytree: يحدد نسبة الميزات التي سيتم اختيارها لتدريب كل شجرة.

بالرغم من أن لهذه الخوارزمية (XGBoost) مميزات كثيرة منها الكفاءة في الحساب والدقة العالية ومعالجة البيانات الناقصة وإمكانية التوازي وخاصية (régularization)، لكن يعاب عليها في مسألة التعقيد حيث هي حساسة للتخصيص قد تتطلب إعدادات دقيقة لـ (Hyperparameters) للوصول الى أداء مثالي ، وإلا قد تؤدي الى أداء ضعيف، كذلك يعاب عليها أنها تستهلك ذاكرة كبيرة خاصة عند التعامل مع البيانات الضخمة.


3. الجانب التطبيقي للدراسة:

1.3 تقديم العينة:

من أجل تنفيذ وتقييم هذه الخوارزمية تم الاستعانة ببيانات تخص 140 مؤسسة جزائرية مقسمة الى 90 مؤسسة سليمة (تم ترميزها برقم 1) و 50 مؤسسة عاجزة (تم ترميزها بالصفر 0).^{*}

والشكل التالي يوضح ذلك :

الشكل 05: توزيع العينة حسب الحالة (سليمة 1، عاجزة 0)



المصدر: من اعداد الباحثين، عن مخرجات بايثون

^{*} البيانات مأخوذة من مصدر ثانوي ، وتتمثل في جزء من قاعدة البيانات الخاصة بالاستاذة مروة زهواني، أستاذة بجامعة غرداية، أطروحة الدكتوراه : تطبيقات الذكاء الاصطناعي للتنبؤ بمخاطر التعثر المالي بالمؤسسة الاقتصادية-دراسة حالة-، جامعة غرداية ، 2022.

2.3 متغيرات الدراسة:

من أجل بناء نموذج تصنيفي تم الاعتماد على 16 نسبة مالية وتم ترميزها كالتالي:

الجدول 02: ترميز متغيرات الدراسة

y1=(نسبة التداول السريعة)	y9=(نسبة المديونية)
y2=(نسبة التداول)	y10=(نسبة حقوق الملكية الى اجمالي الخصوم)
y3=(نسبة النقدية)	y11=(نسبة حقوق الملكية الى اجمالي الاصول)
y4=(نسبة الاصول المتداولة بالنسبة لإجمالي الاصول)	y12=(نسبة حقوق الملكية الى اجمالي الخصوم المتداولة)
y5=(معدل دوران الموجودات)	y13=(هامش الربح)
y6=(معدل دوران الموجودات المتداولة)	y14=(العائد على الموجودات)
y7=(معدل دوران رأسمال العامل)	y15=(العائد على الملكية)
y8=(معدل دوران النقدية)	y16=(العائد على الخصوم)

المصدر : من اعداد الباحث

كما يمكن عرض الجزء العلوي منها كالتالي:

الشكل 06: الجزء العلوي من عينة الدراسة

```
[ ] df.head()
```

	y	y1	y2	y3	y4	y5	y6	y7	y8	y9	y10	y11	y12	y13	y14	y15	y16
0	1	4.675849	6.034465	3.317263	0.627628	0.602000	0.959167	1.149687	1.744831	1.0	0.357076	0.357076	3.433186	0.113609	0.068392	0.191535	0.068392
1	1	1.441093	1.611824	0.088415	0.722177	0.309532	0.428610	1.129153	7.813681	1.0	0.180999	0.180999	0.403972	0.062677	0.019400	0.107185	0.019400
2	1	0.573290	1.192901	0.119216	0.759111	0.674949	0.889131	5.498396	8.896857	1.0	0.363643	0.363643	0.571445	0.038796	0.026186	0.072009	0.026186
3	1	1.052682	1.856399	0.230566	0.821826	1.641536	1.997425	4.329779	16.082215	1.0	0.119286	0.119286	0.269451	0.033736	0.055379	0.464251	0.055379
4	1	11.996938	12.863504	3.810724	0.791841	0.417043	0.526675	0.571070	1.777847	1.0	0.029385	0.029385	0.477363	0.412927	0.172208	5.860389	0.172208

المصدر : من اعداد الباحثين، عن مخرجات بايثون

3.3 الدراسة الوصفية للعينة:

يمكن عرض المقاييس الوصفية لكل المتغيرات كالتالي :


الشكل 07: المقاييس الوصفية لمتغيرات الدراسة

	count	mean	std	min	25%	50%	75%	max
y	140.0	0.642857	0.480878	0.000000	0.000000	1.000000	1.000000	1.000000
y1	140.0	1.818007	3.837477	-0.220470	0.485991	0.890066	1.625987	40.968355
y2	140.0	2.151091	3.849017	0.116148	0.740622	1.342201	1.919668	40.969556
y3	140.0	0.518443	0.967992	0.001488	0.048861	0.131573	0.491068	5.726316
y4	140.0	0.570396	0.278868	0.014707	0.337587	0.616657	0.793064	1.000000
y5	140.0	0.539228	0.552229	0.000000	0.102146	0.359590	0.754200	2.766443
y6	140.0	0.995805	1.026034	0.000000	0.260635	0.712935	1.292048	6.227550
y7	140.0	1.872826	40.062881	-361.615552	-0.067277	1.310990	3.084969	295.920261
y8	140.0	22.313695	95.091014	0.000000	2.194041	6.227723	13.703579	1058.541628
y9	140.0	1.044767	0.526464	0.876303	1.000000	1.000000	1.000000	7.226694
y10	140.0	0.247271	0.261997	-0.438227	0.046331	0.183015	0.333262	1.090668
y11	140.0	0.279112	0.490226	-0.438227	0.046331	0.183015	0.333262	5.169095
y12	140.0	2.495644	9.014472	-0.304699	0.146344	0.397927	0.970694	60.097977
y13	140.0	-3.795866	25.262989	-173.539965	-0.108622	0.046800	0.139305	15.609702
y14	140.0	0.027513	0.121050	-0.370254	-0.011514	0.024004	0.062624	0.553536
y15	140.0	5.382669	30.938494	-109.260532	-0.017184	0.105900	0.857893	217.615503
y16	140.0	0.026666	0.120600	-0.370254	-0.011514	0.022667	0.062624	0.553536

المصدر : من اعداد الباحثين، عن مخرجات بايثون

بالنظر الى المتوسط الحسابي (mean) ومقارنته بأعلى قيمة (max) و أدنى قيمة (min) يتضح لنا أن أغلب المتغيرات لا تتوزع طبيعياً ماعدا المتغيرات (y14.y16) كما يظهر بوضوح في الرسم البياني للمتغيرات كالتالي:

الشكل 08: الرسم البياني لتوزيع المتغيرات



المصدر : من اعداد الباحثين، عن مخرجات بايثون

مصفوفة الارتباطات:

الشكل 09: مصفوفة الارتباطات بين المتغيرات

	y	y1	y2	y3	y4	y5	y6	y7	y8	y9	y10	y11	y12	y13	y14	y15	y16
y	100.0%	11.6%	15.0%	11.3%	33.1%	35.5%	23.0%	-12.2%	-7.2%	6.7%	-18.8%	-5.2%	-21.0%	21.8%	51.6%	18.9%	51.4%
y1	11.6%	100.0%	99.3%	36.9%	-9.9%	-9.7%	-14.9%	-1.1%	-6.8%	-2.9%	2.8%	-0.8%	30.4%	-23.4%	7.7%	3.3%	7.9%
y2	15.0%	99.3%	100.0%	38.3%	-7.2%	-7.9%	-14.6%	-0.4%	-6.9%	-3.6%	3.5%	-0.9%	29.2%	-22.1%	8.4%	1.8%	8.6%
y3	11.3%	36.9%	38.3%	100.0%	-12.7%	-4.2%	-3.2%	-4.9%	-10.9%	-4.0%	6.3%	0.2%	38.0%	-28.7%	19.8%	5.6%	20.0%
y4	33.1%	-9.9%	-7.2%	-12.7%	100.0%	46.2%	-10.1%	0.5%	-0.9%	13.2%	-28.1%	-5.0%	-33.7%	23.5%	7.1%	10.3%	6.3%
y5	35.5%	-9.7%	-7.9%	-4.2%	46.2%	100.0%	64.6%	21.7%	25.0%	30.5%	-19.0%	13.2%	-18.9%	15.0%	35.2%	15.1%	33.5%
y6	23.0%	-14.9%	-14.6%	-3.2%	-10.1%	64.6%	100.0%	11.8%	39.0%	12.6%	-10.8%	3.9%	-13.5%	15.0%	34.4%	19.1%	33.8%
y7	-12.2%	-1.1%	-0.4%	-4.9%	0.5%	21.7%	11.8%	100.0%	1.2%	-0.9%	-4.4%	-3.0%	-0.9%	0.7%	-7.2%	0.2%	-7.2%
y8	-7.2%	-6.8%	-6.9%	-10.9%	-0.9%	25.0%	39.0%	1.2%	100.0%	0.4%	-3.5%	-1.5%	-4.9%	3.5%	-12.6%	-2.7%	-12.6%
y9	6.7%	-2.9%	-3.6%	-4.0%	13.2%	30.5%	12.6%	-0.9%	0.4%	100.0%	15.2%	84.9%	0.0%	1.3%	4.8%	-0.6%	-0.5%
y10	-18.8%	2.8%	3.5%	6.3%	-28.1%	-19.0%	-10.8%	-4.4%	-3.5%	15.2%	100.0%	65.1%	50.3%	-35.4%	-20.9%	-16.2%	-21.5%
y11	-5.2%	-0.8%	-0.9%	0.2%	-5.0%	13.2%	3.9%	-3.0%	-1.5%	84.9%	65.1%	100.0%	26.9%	-17.9%	-7.9%	-9.8%	-12.3%
y12	-21.0%	30.4%	29.2%	38.0%	-33.7%	-18.9%	-13.5%	-0.9%	-4.9%	0.0%	50.3%	26.9%	100.0%	-94.6%	-5.0%	-4.8%	-4.9%
y13	21.8%	-23.4%	-22.1%	-28.7%	23.5%	15.0%	15.0%	0.7%	3.5%	1.3%	-35.4%	-17.9%	-94.6%	100.0%	6.9%	3.7%	6.8%
y14	51.6%	7.7%	8.4%	19.8%	7.1%	35.2%	34.4%	-7.2%	-12.6%	4.8%	-20.9%	-7.9%	-5.0%	6.9%	100.0%	43.9%	99.8%
y15	18.9%	3.3%	1.8%	5.6%	10.3%	15.1%	19.1%	0.2%	-2.7%	-0.6%	-16.2%	-9.8%	-4.8%	3.7%	43.9%	100.0%	43.3%
y16	51.4%	7.9%	8.6%	20.0%	6.3%	33.5%	33.8%	-7.2%	-12.6%	-0.5%	-21.5%	-12.3%	-4.9%	6.8%	99.8%	43.3%	100.0%

المصدر : من اعداد الباحثين، عن مخرجات بايثون

بالنظر الى المصفوفة أعلاه يتبين أن أهم ثلاث متغيرات لها القدرة في التأثير على حالة المؤسسة هم 16y و 14y و 13y والتي تشير الى العائد على الخصوم والعائد على الموجودات وهامش الربح حيث تؤثر كل منها على حالة المؤسسة كالتالي ب: 51.4% ، 51.6% ، 21.8% .

4.3 بناء النموذج الأول :

بعد تقسيم العينة إلى 80% للتدريب و 20% للاختبار وبتشغيل خوارزمية (XGB) على معلمات ابتدائية مختارة بطريقة

تلقائية كالتالي:

الشكل 10: ضبط المعلمات للنموذج الأول

```
[ ] # تعريف النموذج مع المعلمات المحددة
model = XGBClassifier(
    learning_rate=.5,
    max_depth=7,
    n_estimators=500,
    min_child_weight=10,
    colsample_bytree=0.8,
    subsample=0.5,
    scale_pos_weight=4,
    alpha=0.5,
    max_bin=50,
    max_leaves=15,
    random_state=42
)
```

المصدر: من اعداد الباحثين، عن مخرجات بايثون

وبعد تنفيذ الخوارزمية تحصلنا على نسبة دقة Accuracy بالنسبة لعينة التدريب بلغت 89.29% ، أما بالنسبة لعينة الاختبار بلغت 85.71% . كما هو مبين في الشكل أدناه:

الشكل 11: مقاييس الأداء للنموذج الأول

Classification Report:				
	precision	recall	f1-score	support
0	0.80	0.57	0.67	7
1	0.87	0.95	0.91	21
accuracy			0.86	28
macro avg	0.83	0.76	0.79	28
weighted avg	0.85	0.86	0.85	28

المصدر: من اعداد الباحثين، عن مخرجات بايثون

يتم الاعتماد على أربع مقاييس أداء لتقييم نموذج المصنف يمكن شرحها كالتالي:

1- **دقة التصنيف:** هي عدد العينات التي صنف بشكل صحيح إلى العدد الكلي للعينات

$$\text{accuracy} = \frac{TP+TN}{TP+TN+FP+FN}$$

2- **الاسترجاع (Recall):** هو عدد النتائج الإيجابية الصحيحة مقسوما على عدد جميع العينات: $\text{Recall} = \frac{TP}{TP+FN}$

3- **الحساسية (Precision):** هو عدد النتائج الإيجابية الصحيحة مقسوما على عدد النتائج الإيجابية المتنبأ بها

$$\text{Precision} = \frac{TP}{TP+FP}$$

4- **F1 SCORE:** هو الوسط التوافقي بين Precision و Recall: $\text{F1 score} = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}}$


5.3 بناء النموذج الثاني (التحسين بالـGA):

بعد ضبط المعلمات في النطاق المحدد وتشغيل الخوارزمية من أجل الحصول على أعلى دقة تصنيف

أعطت نتائج الخوارزمية الجينية أفضل المعلمات ومن ثم قمنا بتشغيل خوارزمية XGBoost باستخدام المعلمات الجديدة وكانت النتائج كالتالي:

بالنسبة لعينة التدريب أعطت دقة تصنيف 99.11% وهي نسبة عالية جدا، أما بالنسبة لعينة الاختبار فقد حققت الخوارزمية نسبة 96.43% وهي نسبة عالية، مما يدل على أن النموذج الجديد قد تحسن على النموذج السابق. أما عن مصفوفة الارتباك فقد كانت نتائجها كالتالي:

الشكل 12: مصفوفة الارتباك لعينة التدريب وعينة الاختبار



المصدر: من اعداد الباحثين، عن مخرجات بايثون

كما نلاحظ على اليسار مصفوفة الارتباك الخاصة بعينة التدريب تشير الى أنه 42 مؤسسة عاجزة تم تصنيفها على أنها عاجزة ، و 69 مؤسسة سليمة تم تصنيفها على أنها سليمة ، و مؤسسة واحدة سليمة تم تصنيفها على أنها عاجزة .

أما فيما يخص عينة الاختبار فقد تم تصنيف 6 مؤسسات عاجزة على أنها عاجزة، وقام بتصنيف 21 مؤسسة سليمة بأنها سليمة ، ومؤسسة واحدة سليمة قام بتصنيفها على أنها عاجزة .

أما بالنسبة لمقياس الاسترجاع (recall) بالنسبة للفئة الاولى (0) بلغ 86% ، بخصوص الفئة (1) بلغت نسبة الاسترجاع نسبة 100% ، أما بخصوص مقياس الحساسية (precision) بالنسبة للفئة (0) كانت 100% و للفئة (1) كانت 95% .
وفيما يخص مقياس F1 Score بلغ نسبة 92% بالنسبة للفئة (0) و نسبة 98% للفئة (1).

الشكل 13: نتائج مقياس الأداء للنموذج الثاني

Classification Report:				
	precision	recall	f1-score	support
0	1.00	0.86	0.92	7
1	0.95	1.00	0.98	21
accuracy			0.96	28
macro avg	0.98	0.93	0.95	28
weighted avg	0.97	0.96	0.96	28

المصدر: من اعداد الباحثين، عن مخرجات بايثون

4. خاتمة:

باعتبار أن موضوع منح القروض له أهمية كبيرة بالنسبة للبنوك، لأنه غالبا ما يكلف قرار غير مدروس العديد من الخسائر في رأس المال ، هذا ما يتطلب دائما من محلي الائتمان بأن يكونوا على استعداد ودراية تامة بكيفية تحليل طلبات القروض من خلال دراسة كافة الجوانب المتعلقة بالزبون والمشروع والسوق عموما ، وكذلك الإحاطة بالأساليب والمناهج الحديثة المستخدمة في دراسة طلبات القروض .

1.4 نتائج الدراسة

تم تنفيذ خوارزمية تعزيز التدرج الشديد (XGBoost) وقد أعطت نتائج عالية 85.71% بالنسبة لدقة التصنيف و بمعدل استرجاع بلغ 57% بالنسبة للفئة (0) و 95% للفئة (1)، وبدرجة حساسية precision للفئة (0) بلغت 80% والفئة (1) بلغت 87% ، ولمقياس F1score للفئة (0) 67% و للفئة (1) بلغت 91% .

بالرغم من أن النتائج التي تحصلنا عليها تعتبر جيدة لكن يبقى احتمال أنه يمكن تحسينها ، ولأن الخوارزمية الجينية تعتبر أداة فعالة في تحسين الحلول الابتدائية قمنا ببناء نموذج (XGBoost-GA). وقد أعطى نتائج عالية ، حيث بلغت دقة التصنيف 96.43% ، بمعدل استرجاع للفئة (0) بلغ 86% و للفئة (1) معدل 100% ودرجة حساسية (precision) للفئة (0) بلغت 100% و للفئة (1) ب 95% وبمعامل توافقي بلغ بالنسبة للفئة (0) 92% و للفئة (1) قدر ب 98%.

يمكننا القول أن الاستعانة بنماذج تعلم الآلة في دراسة موضوع ترشيد قرارات منح القروض أعطت نتائج قوية خاصة نموذج تعزيز التدرج الشديد (XGBoost) لأنه يستطيع التعامل مع البيانات غير المتوازنة ، وكذلك تعتبر نماذج تعلم الآلة فعالة لأنها تتبع منهج التدريب والتعرف من أجل المحاكاة .

في الأخير يمكن القول أن فرضيات هذا البحث قد تحققت كالتالي:

- استطاعت الخوارزمية الجينية تحسين الحل .
- قمنا ببناء نموذج (XGBoost) وأعطى دقة تصنيف عالية.
- تفوق نموذج (XGBoost-GA) على النموذج (XGBoost) .

2.4 التوصيات

- تعتبر القروض البنكية أداة فعالة لدعم المؤسسات والتي بدورها تساهم في زيادة الدخل الوطني، وعليه يجب على صانعي القرارات المصرفية الاستعانة بالطرق الحديثة لتدعيم قراراتهم .
- تطوير مهارات محلي الائتمان وذلك بالتدريب على نماذج تعلم الآلة من أجل هندسة تطبيقات ذكية لتسهيل دراسة مجموعات كبيرة من الملفات في وقت قصير.

5. قائمة المراجع

المراجع العربية

• الأطروحات:

- 1-العايب ياسين، استعمال القرض التنقيطي في تقدير مخاطر القرض، مذكرة ماجستير، جامعة الجزائر، 2008.
- 2- بوداح عبد الجليل، استخدام الانظمة الخبيرة في مجال اتخاذ قرار منح القروض البنكية-دراسة تحليلية تطبيقية-، اطروحة دكتوراه، جامعة قسنطينة، 2007.
- 3- حسين خليل عبيد مخيلف، تقدير معلمات النحدر (log-logistic) باستخدام الخوارزمية الجينية مع تطبيق عملي، مذكرة ماجستير، جامعة كربلاء، العراق، 2022.
- 4- عتروس سهيلة، استخدام منهجية بوكس جينكنز والشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية بمؤسسة سونلغاز-دراسة حالة: ولاية بسكرة-، اطروحة دكتوراه، جامعة بسكرة، 2018.
- 5- فاروق فخاري، تطبيق نموذج تحليل الانحدار اللوجستي للتحكم في تعثر الائتمان البنكي-دراسة مجموعة من البنوك التجارية في الجزائر-، اطروحة دكتوراه، جامعة المسيلة، 2019.
- 6- محمد راتب حباب، توليد الجداول الدراسية اعتمادا على الخوارزميات الجينية وتعلم الآلة -تطبيق على المعهد العالي، مذكرة ماجستير، المعهد العالي للعلوم التطبيقية والتكنولوجيا، سوريا، 2021.
- 7-موفق عمر، استخدام الخوارزميات الجينية في التنبؤ بتطايير الأوراق المالية، أطروحة دكتوراه، جامعة تلمسان، 2019.
- 8- يخلف العربي، الشبكات العصبية الاصطناعية وتقدير مخاطر القروض بالبنوك التجارية الجزائرية، أطروحة دكتوراه، جامعة سوق اهراس، 2021،

• المقالات:

- 1- طير هاجر، لطرش جمال، أثر النظم الخبيرة في ادارة علاقة العملاء التحليلية في البنوك التجارية: دراسة مقارنة بين البنوك الأجنبية والبنوك الوطنية في الجزائر، المجلة الجزائرية للأمن الإنساني، المجلد 08، العدد 02، 2023.
- 2- فيلاي طارق، التنبؤ بتعثر الشركات المقترضة باستعمال نماذج الشبكات العصبية الاصطناعية : دراسة حالة بنك الجزائر الخارجي، مجلة التنظيم والعمل، المجلد 06، العدد 03، 2017.
- 3- يخلف العربي، رقايقية فاطمة الزهراء، الطرق غير التقليدية في تقدير مخاطر القروض البنكية، مجلة الدراسات المالية والحاسبية والادارية، المجلد 06، العدد 04، 2019.

• المداخلات:

1- محمد بن بوزيان، صوار يوسف، محاولة تقدير خطر القروض البنكية بإستعمال طريقة القرض التنقيطي - دراسة حالة البنك الوطني الجزائري بسعيدة-، ورقة عمل مقدمة للمؤتمر العلمي : ادارة المخاطر واقتصاد المعرفة ، 17/16 افريل، 2007، جامعة الزيتونة الأردنية، الأردن.

المراجع الأجنبية:

• المؤلفات:

- 1-D.Gujarati, basic économetrie, MC Graw-hill Inc,3rdédition, new york.2004.
- 2- Randy L.Haupt, Sue Ellen Haupt,PRACTICAL GENETIC ALGORITHMS, second edition, JOHN WILEY & sons, INC., PUBLICATION, 2004.
- 3-Régis Bourbonnais,Econométrie,10édition,DUNOD,Paris, 2018.
- 4-S.N.Sivanandam, S.N.Deepa, Introduction to Genetic Algorithms, springer- verlag berlin Heidelberg, 2008.

• المقالات:

- 1- AdilMehdary and other , Hyperparameter Optimization with Genetic Algorithms and XGBoost: A Step Forward in Smart Grid Fraud Detection, sensor, mdpi, 2024.
- 2-Christina Albert Rayed, AsmaaSaeed Embark, A PROPOSED EXPERT SYSTEM FOR EVALUATING THE PARTNERSHIP IN BANKS, International Journal of Advance Robotics & Expert System(JARES) Vol.1,No.2.

• المواقع الالكترونية:

- 1- Luis , Fernando Torres, xgboost the king of machine learning algorithms, <https://medium.com/latinxinai/xgboost-the-king-of-machine-learning-algorithms-6b5c0d4acd87>,(11/11/2024)