

CZU: 004.8:[005.52:336.777]

UDC: 004.8:[005.52:336.777]

STRATEGII DE IMPLEMENTARE A INTELIGENȚEI ARTIFICIALE ÎN PROCESELE DE ANALIZĂ A PORTOFOLIILOR DE CREDITE

STRATEGIES FOR THE IMPLEMENTATION OF ARTIFICIAL INTELLIGENCE IN CREDIT PORTFOLIO ANALYSIS PROCESSES

Dr., conf. univ. Inesa BRUMĂ, USM
inesa.bruma@gmail.com

ORCID: 0000-0002-0901-5191

Dr., conf. univ. Angela FILIP, USM
filipangela05@gmail.com

ORCID: 0000-0003-2359-860X

Magistru în inginerie Mihai BRUMĂ, UTM
mihai.bruma123@gmail.com

ORCID: 0009-0007-3339-4586

DOI: <https://doi.org/10.53486/econ.2026.136.55>

Ph.D., Assoc. Prof. Inesa BRUMA, USM
inesa.bruma@gmail.com

ORCID: 0000-0002-0901-5191

Ph.D., Assoc. Prof. Angela FILIP, USM
filipangela05@gmail.com

ORCID: 0000-0003-2359-860X

Master of Engineering Mihai BRUMA, UTM
mihai.bruma123@gmail.com

ORCID: 0009-0007-3339-4586

DOI: <https://doi.org/10.53486/econ.2026.136.55>

Rezumat

Studiul de caz propus spre cercetare evidențiază integrarea intensivă a Tehnologiilor Informaționale în analiza sistemică a datelor, calibrarea valorică și formularea unei eventuale evoluții sau continuități a acestora. Drept exemplu, este analizat portofoliul istoric al evoluției în timp a creditelor, iar prin intermediul conceptelor de Inteligență Artificială se realizează o prognoză, care generează o valoare numerică la o dată prestabilită. Pe baza acestui rezultat, instituția bancară, structurile competente de guvernare și analiză a datelor, precum și direcțiile de creditare pot lua decizii privind acordarea în continuare a produselor bancare. Strategia poate fi implementată sub mai multe forme, însă, în cadrul cercetării, este descris procesul de dezvoltare a unei aplicații realizate în limbajul C++, care utilizează modele de învățare automată și o rețea neuronală simplă de tip Perceptron, cu scopul obținerii unei precizii sporite.

Cuvinte-cheie: inteligență artificială, portofoliu de credite, prognoză, rețele neuronale, automatizarea proceselor, analiza datelor.

Clasificare JEL: C53, C88, G21.

Introducere

Este cunoscut faptul că orice instituție bancară deține anumite produse financiare care îi susțin activitatea, unul dintre acestea fiind creditul. Creditele, în esență, reprezintă împrumuturi pe care instituțiile bancare le oferă persoanelor fizice sau juridice, în dependență de necesitățile clienților, începând de la creditele de consum, până la cele ipotecare. Fiecare dintre acestea are o valoare contractuală inițială, o rată lunară de rambursare și alți parametri semnificativi. Pentru a monitoriza evoluția acestora, structurile responsabile pentru analiza creditelor, efectuează diverse analize și rapoarte privind riscului de

Abstract

The proposed case study highlights the intensive integration of Information Technologies in the systemic analysis of data, value calibration, and the formulation of potential trends regarding their evolution or continuity. As an illustrative example, the historical evolution of a loan portfolio over time is analysed, and, through the application of Artificial Intelligence techniques, a forecast is made that generates a numerical estimate for a predetermined future date. Based on this result, the banking institution, relevant competent governance and data analysis structures, as well as the lending departments, can make decisions regarding the further provision of banking products. The proposed strategy can be implemented in various forms, however, this research describes the development of a C++ application which uses machine learning models and a simple Perceptron neural network to achieve a higher level of forecasting accuracy.

Keywords: artificial intelligence, loan portfolio, forecasting, neural networks, process automation, data analysis.

JEL Classification: C53, C88, G21.

Introduction

It is widely recognised that every banking institution offers a range of financial products that support its activity, one of the most important being loans. Loans essentially represent borrowed funds that banking institutions provide to individuals or legal entities, depending on clients' needs, ranging from consumer loans to mortgages financing. Each loan is characterised by an initial contractual value, a monthly repayment rate, and other significant parameters. In order to monitor their evolution, the structures responsible for credit analysis conduct various assessments and prepare reports regarding

credit sau capacitatea de rambursare, evidențiind astfel situația financiară a beneficiarilor. În regim obișnuit, aceste analize consumă timp, pentru a fi integral realizate. În acest context, studiul în cauză prezintă inițiativa de automatizare a proceselor prin utilizarea Tehnologiilor Informaționale ce includ concepte de Inteligență Artificială. Această abordare presupune nu doar creșterea eficienței și economisirea timpului în cadrul procedurilor de analiză și raportare, dar și o sporire a exactității și preciziei a datelor obținute, facilitând astfel adoptarea unor decizii corespunzătoare privind menținerea creditelor actualilor clienți și dezvoltarea activităților de creditare pentru potențialii clienți ai băncii.

Metodologia cercetării

Deoarece datele din cadrul băncilor prezintă un caracter strict confidențial, acestea fiind prezentate cu titlu de exemplu sunt elaborate de către autori. Sumele supuse analizei, corespund realității, însă rezultatele expuse au rol ilustrativ. În continuare, este prezentată o strategie argumentată privind formele de acordare și administrare a creditelor. Tehnologii utilizate includ: un Sistem de Gestiune a Bazelor de Date și limbajul structurat de interogare a bazelor de date relaționale (T-SQL), Microsoft Excel cu formatul: Comma – Separated Values (CSV), limbajul de programare C++. Din gama metodelor matematice au fost utilizate regresia liniară și algoritmul Gradient Descent. Aferent Inteligenței Artificiale, au fost utilizate: o rețea neuronală simplă cu un singur strat (Perceptron) și elemente de învățare automată (Machine Learning).

Rezultate obținute și discuții

În strictă conformitate cu paradigmele contemporane, creditul reprezintă un produs bancar oferit unei persoane fizice sau juridice, prin intermediul căruia aceasta obține acces la resurse financiare pe care nu le deține la momentul solicitării. Acest produs financiar este acordat în baza unor criterii bine definite, care includ analiza capacității de rambursare, istoricul de credit al solicitantului și riscurile asociate [1]. Persoana sau entitatea, care accesează creditul, se angajează să returneze suma primită într-o perioadă de timp stabilită, împreună cu dobânda aferentă, ce constituie costul utilizării capitalului împrumutat.

În prezent, creditele prezintă o diversitate largă, în dependență de scopul, pe care îl urmărește clientul [2]. În acest sens, cele mai răspândite tipuri de credite sunt:

1. Creditele de consum – destinate finanțării nevoilor personale ale clienților (achiziționarea de bunuri, servicii);
2. Creditele ipotecare – utilizate pentru achiziționarea sau renovarea locuințelor;
3. Creditele pentru afaceri – acordate companiilor pentru a susține diverse activități comerciale sau investiționale.

credit risk or repayment capacity, thereby highlighting the financial situation of the beneficiaries. However, these analyses are routinely time-consuming and resource-intensive. In this context, the present study introduces an initiative aimed at automating such processes through the use of Information Technologies that include Artificial Intelligence concepts. This approach not only involves enhances efficiency and reduces the time required for analysis and reporting procedures but also improves the accuracy and precision of the data obtained, thus facilitating the adoption of appropriate decisions regarding both the management of current clients' loans and the development of lending activities for potential bank clients.

Research Methodology

Given the strictly confidential nature of banking data, the figures presented in the study have developed by the authors for illustrative purposes. Although the amounts subjected to analysis correspond to reality, the results presented serve solely as examples. Furthermore, the study outlines a reasoned strategy regarding the mechanisms for granting and managing loans. The technologies used include: a Database Management System and the structured query language for relational databases (T-SQL), Microsoft Excel using the Comma-Separated Values (CSV) format, and the C++ programming language. From the range of mathematical modelling concepts, linear regression and the Gradient Descent algorithm were utilised. In terms of Artificial Intelligence, the research incorporates a simple single-layer neural network (Perceptron) and Machine Learning techniques.

Obtained Results and Discussion

In strict accordance with contemporary paradigms, a loan is a banking product offered to a physical or legal person, through which they gain access to financial resources they do not possess at the time of the request. This financial product is granted based on well-defined criteria, which include the analysis of the repayment capacity, the applicant's credit history, and the associated risks [1]. The person or entity accessing the loan commits to returning the received amount within an established timeframe, together with the related interest, which constitutes the cost of using the borrowed capital.

Currently, loans show a wide diversity, depending on the client's objective [2]. In this regard, the most widespread types of loans are:

1. Consumer loans – intended to finance clients' personal needs (purchasing goods and services);
2. Mortgage loans – used for purchasing or renovating residential properties;
3. Business loans – granted to companies in order to support various commercial or investment activities.

Tipurile de credite enumerate sunt acordate, practic, de majoritatea băncilor comerciale, fiind produse financiare strategice, cu capacitatea de asigurare a diverselor nevoi ale clienților.

În mod tradițional, toate băncile dispun de echipe specializate în analiza datelor, performanței și evoluției actualității instituției financiare, atât la nivelul clienților, cât și la nivelul produselor financiare pe care le dețin. În cadrul cercetării efectuate, se evidențiază faptul că analiza creditelor este un proces complex, prin care instituțiile financiare au obligația de a realiza evaluări detaliate pentru a stabili condițiile actuale de sustenabilitate, monitorizare, continuitate și supraveghere a creditării. Dacă în precedent, analiza datelor se efectua manual, cu o eficiență redusă din punct de vedere al timpului, în prezent, Tehnologiile Informaționale intervin în sprijinul acestui proces.

În prezent, băncile, împreună cu echipele de Business Intelligence, au început să adopte soluții de automatizare bazate pe tehnici și tehnologii moderne, cu un accent deosebit pe aplicarea Inteligenței Artificiale (IA). Aceste tehnologii oferă o serie de avantaje semnificative instituțiilor financiare:

- a. **Precizie sporită** – Inteligența Artificială poate identifica anomalii și riscuri ascunse cu o acuratețe mai mare decât metodele tradiționale, reducând la minimum erorile umane [3].
- b. **Îmbunătățirea procesului decizional** – Algoritmii de învățare automată și analizele predictive permit băncilor să prevadă procesul comportamental de rambursare al clienților și să optimizeze condițiile de creditare.
- c. **Monitorizarea creditelor și analiza pieței** – Inteligența Artificială și tehnologiile avansate contribuie nu doar la evaluarea individuală a creditelor, ci și la supravegherea pieței de creditare în ansamblu.

Luând în considerare toate cele menționate referitoare la credite și automatizarea procesului de supraveghere a acestora, în continuare va fi prezentată o soluție tehnică în acest sens. Pentru început, vor fi prezentate modelele matematice, care stau la baza analizei datelor, respectiv regresia liniară și metoda coborârii pe gradient.

Pentru a automatiza supravegherea creditelor, un model de regresie liniară poate fi utilizat pentru a prezice comportamentul financiar al debitorilor pe baza unor factori precum veniturile, scorurile de credit, istoricul de plată și valoarea totală a activelor. Metoda coborârii pe gradient permite ajustarea iterativă a modelului, fiind foarte utilă în seturile mari de date, unde metoda clasică a celor mai mici pătrate poate deveni costisitoare din punct de vedere tehnic.

În esență, regresia liniară reprezintă o metodă statistică simplă și des utilizată pentru a modela relația dintre o variabilă dependentă (de obicei notată cu y) și una sau mai multe variabile independente

The aforementioned types of loans are offered by the majority of commercial banks and constitute strategic financial products capable of addressing various client needs.

Traditionally, banks maintain specialised teams for analysing data, performance indicators, and the current evolution of the financial institution, both at the client level and at the level of the financial products they hold. The conducted research highlights that credit analysis is a complex process through which financial institutions are required to perform detailed evaluations aimed at assessing sustainability, monitoring performance, ensuring continuity, and supervising lending activities. If previously data analysis was predominantly performed manually, with reduced time efficiency, Information Technologies currently intervene to support this process.

Nowadays, banks, together with Business Intelligence teams, have started to adopt automation solutions based on modern techniques and technologies, with a special emphasis on applying Artificial Intelligence (AI). These technologies offer a series of significant advantages to financial institutions:

- a. **Increased precision** – Artificial Intelligence can identify anomalies and hidden risks with higher accuracy than traditional methods, thereby minimising human errors [3].
- b. **Improved decision-making process** – Machine learning algorithms and predictive analytics allow banks to forecast clients' repayment behaviour and optimise lending conditions accordingly.
- c. **Loan monitoring and market analysis** – Artificial Intelligence and advanced technologies contribute not only to the evaluation of individual creditworthiness but also to the supervision and analysis of the lending market as a whole.

Considering the aspects mentioned above regarding loans and the automation of their supervision process, a technical solution addressing is presented below. Firstly, the mathematical models underlying the data analysis approach are presented, namely linear regression and the gradient descent method.

To automate credit supervision, a linear regression model may be used to predict the financial behaviour of borrowers based on factors such as income, credit scores, payment history, and total value of assets. The gradient descent method allows the iterative adjustment of model parameters and is particularly useful when large datasets, where the classical ordinary least squares method may become technically costly. In essence, linear regression represents a simple and frequently used statistical method to model the relationship between a dependent variable (usually denoted by y) and one or more independent variables (denoted by x). Its purpose is to determine the coefficients of a linear function that

(notate cu x). Scopul acesteia este de a determina coeficienții unei funcții liniare, care arată cât de bine variabilele independente pot explica sau prezice variabila dependentă [4].

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (1)$$

unde: x – variabilă independentă; y – variabilă dependentă; β_0 – reprezintă termenul liber (ordonat la origine) reprezentând valoarea lui y la condiția $x = 0$; β_1 – coeficientul de regresie (panta dreptei) care evidențiază schimbarea lui y , la o variație unitară a lui x ; ε – termenul de eroare cu distribuție normală.

Coeficienții β_0 și β_1 pot fi determinați prin intermediul metodei celor mai mici pătrate, care are proprietatea matematică de a minimiza suma pătratelor diferențelor dintre valorile controlate și estimările variabilei y , conform relației:

$$\min_{\beta_0, \beta_1} \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2 \quad (2)$$

Pentru minimizarea funcției de cost, se va utiliza metoda Gradient Descent, care presupune o tehnică iterativă, care ajustează coeficienții β_0 și β_1 în direcția gradientului negativ, astfel apropiind valorile obținute de cele optime [5]. În acest sens, funcția de cost care urmează a fi ajustată este următoarea:

$$J(\beta_0, \beta_1) = \frac{1}{2n} \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2 \quad (3)$$

Expresia matematică de actualizare iterativă pentru Gradient Descent este:

$$\beta_j := \beta_j - \alpha \frac{\partial J(\beta_0, \beta_1)}{\partial \beta_j} \quad (4)$$

unde: α – reprezintă rata de învățare (un parametru specific algoritmilor de Inteligență Artificială) și $J(\beta_0, \beta_1)$ – funcția de cost.

Iterând această formulă, datele obținute prin regresia liniară, vor fi aduse la limitele admisibile realității ca să fie mai apropiate de valorile precedente. Acest proces este denumit – calibrarea datelor.

Având deja modelul matematic corespunzător, poate fi definită și funcționalitatea aplicației, care va realiza o prognoză, pe baza datelor istorice prezente într-un fișier Excel cu extensia .csv;

Înainte de executarea aplicației, este necesară extragerea din Sistemul de Gestiune a Bazelor de Date (SGBD) a informației necesare, care va fi analizată automat. În cazul dat, conform **Figurei 1** vor fi extrase date din baza de date exemplificativă *BankHistoricalData* (marcată convențional cu 1), respectiv din tabela *dbo.BankLoanPortfolio* (marcată convențional cu 2):

best describe how the independent variables explain or predict the dependent variable [4].

where x – independent variable, y – dependent variable, β_0 – intercept, representing the value of y when $x = 0$, β_1 – slope coefficient, indicating the change in y for a one-unit change in x , ε – error term, assumed to follow a normal distribution.

Coefficients β_0 and β_1 can be determined using the least squares method, which possesses the mathematical property of minimising the sum of the squared differences between the observed values and the estimated values of y , according to the following relationship:

To minimise the cost function Gradient Descent will be applied. This iterative optimisation method adjusts the coefficients β_0 and β_1 in the direction of the negative gradient, thereby moving the parameter estimates closer to their optimal values [5]. In this context, the function to be minimised is defined as follows:

The mathematical expression for the iterative update in Gradient Descent:

where α – represents the learning rate (a concept specific to elements of Artificial Intelligence) and $J(\beta_0, \beta_1)$ – the cost function.

By iteratively applying this formula, the data obtained from linear regression are adjusted towards admissible real-world limits and values closer to the observed data, a process known as data calibration.

Having established the corresponding mathematical model, the functionality of the proposed application can then be defined: it will perform a forecast (prediction) based on historical data contained in an Excel file with the .csv extension;

Prior to the execution of the application, it is necessary to extract the required information from the Database Management System (DBMS), which will be automatically analysed. In this case, according to **Figure 1**, the data are extracted from the exemplary database *BankHistoricalData* (conventionally marked with 1), specifically from the table *dbo.BankLoanPortfolio* (conventionally marked with 2).




Figura 1. Sursa informațională a SGBD pentru extragerea datelor aferente creditelor/

Figure 1. Database Management System (DBMS) information source for extracting credit-related data
Sursă: elaborată de către autori/
Source: developed by the authors

Pentru realizarea automată a prognozei, va fi necesar ca, cu ajutorul limbajului structurat de interogare Transact – SQL (T-SQL), să fie extrase datele necesare, precum data de raportare și bilanțul total al creditelor pentru fiecare dată. În mod teoretic, tabela *dbo.BankLoanPortfolio* funcționează pentru fiecare sfârșit de lună, cumulând toate soldurile creditelor. Drept exemplu, vor fi analizate primele trei trimestre (Q1: 01.01 – 31.03, Q2: 01.04 – 30.06 și Q3: 01.07 – 30.09) ale anului 2024. Drept urmare, perioada de raportare definită în script va fi cuprinsă între „2024-01-01” și „2024-09-30”. Rezultatul generat de script trebuie să conțină nouă înregistrări, corespunzătoare fiecărui sfârșit de lună (EOM– End Of Month) împreună cu suma totală corespunzătoare acesteia. Mai jos este prezentat scriptul T-SQL, corespunzător cerințelor definite.

For the automated completion of the forecast, it will be necessary, using the structured query language (T-SQL), to extract the required data, such as the reporting date and the total loan balance per date. Theoretically, the *dbo.BankLoanPortfolio* table operates at each month's end, cumulatively recording all loan balances. As an example, the first three quarters of 2024 are considered : (Q1: 01.01 – 31.03, Q2: 01.04 – 30.06, and Q3: 01.07 – 30.09). Accordingly, the reporting period defined in the script has a start date of “2024-01-01” and an end date of “2024-09-30”. The script output should return nine records, each representing the End of Month (EOM), together with the corresponding total balance. The T-SQL script that meets these specified requirements is presented below.




Figura 2. Scriptul nr.1 Sursa informațională a SGBD pentru extragerea datelor aferente creditelor/
Figure 2. Script no.1, DBMS information source for extracting credit-related data

Sursă: elaborată de către autori/ *Source: developed by the authors*

Pentru a asigura includerea tuturor perioadelor relevante, variabilei *@EndReportingPeriod* îi va fi atribuită funcția „GETDATE ()”, care are proprietatea de a prelua data curentă. În continuare, sunt prezentate rezultatele rulării scriptului T-SQL, în **Figura 3**.

To ensure that all reporting periods are included, the variable *@EndReportingPeriod* is assigned the “GETDATE ()” function, which retrieves the current date. The results obtained after executing the T-SQL script are presented in **Figure 3** below.




Figura 3. Rezultatele rulării scriptului nr.1/ Figure 3. Results of executing Script No.1

Sursă: elaborată de către autori/ Source: developed by the authors

Tabelul-rezultat este exportat într-un fișier MS Excel (în formatul .csv), stocat în aceeași directivă cu aplicația pentru prognoză. Aplicația ce urmează a fi prezentată, fiind realizată cu ajutorul limbajului de programare C++, va efectua prognoze, pe bază de datele obținute din SGBD. Codul C++ utilizează concepte de Inteligență Artificială, după cum a fost menționat anterior. Drept funcționalitate, acesta are următoarele elemente-cheie:

a. Citirea fișierului .csv:

Secțiunea nr.1 de cod C++ pentru citirea fișierului .csv;

```

#define READ_CSV(filename, xDates, ySums, result) { \
    std::ifstream file(filename); \
    if (!file.is_open()) { \
        std::cerr << ORANGE << "Error opening file!" << RESET_COLOR << std::endl; \
        result = false; \
    } else { \
        std::string line, date; \
        double sum; \
        std::getline(file, line); \
        while (std::getline(file, line)) { \
            std::istringstream ss(line); \
            std::getline(ss, date, ','); \
            ss >> sum; \
            int days; \
            DATE_TO_DAYS(date, days); \
            xDates.push_back(days); \
            ySums.push_back(sum); \
        } \
        file.close(); \
        result = true; \
    } \
}

```

Sursă: elaborată de către autori/ Source: developed by the authors

The resulting table is inserted into a Microsoft Excel file (in .csv format) located in the same directory as the forecasting application. The application, which is presented below and developed using the C++ programming language, performs a forecast based on the data obtained from the DBMS. As previously mentioned, the C++ code incorporates Artificial Intelligence concepts. Its key functionalities include:

a. Reading the .csv file:

Section No.1 of the C++ code for reading the .csv file;

Utilitate: Prin încărcarea datelor istorice de tip „dată – sumă”, se creează baza de antrenament a modelului de prognoză. Din perspectivă financiară, acest pas corespunde construirii unei serii cronologice care reflectă evoluția zilnică a unui indicator-cheie, în cazul studiului dat, soldul total al portofoliului de credite. În analiza financiară, importanța citirii și preprocesării corecte a datelor nu poate fi subestimată, deoarece calitatea predicțiilor ulterioare depinde direct de exactitatea și consistența acestor informații. În plus, această etapă asigură posibilitatea detectării unor tipare sezoniere, identificării valorilor aplicate (plăți excepționale, rambursări anticipate) și pregătirii ulterioare a datelor pentru scenarii de stres sau proiecții bugetare.

b. Implementarea macrocomenzii LINEAR:
Secțiunea nr.2 de cod C++ pentru macrocomanda LINEAR;

```
#define LINEAR(x, result) { \
    result = x; \
}
```

Sursă: elaborată de către autori/ Source: developed by the authors

Utilitatea acestei alegeri este evidentă atunci când obiectivul este prognoza unor valori continue, precum sumele financiare. Spre deosebire de funcțiile de activare neliniare (Sigmoid, ReLU, Tanh), care limitează sau distorsionează intervalul ieșirii, macrocomanda Linear permite estimarea unor valori neîngrădite, fiind astfel varianta optimă pentru prognozarea sumelor monetare. Din perspectivă financiară, aceasta echivalează cu un model simplu de creștere liniară sau cu o proiecție pe termen scurt a evoluției portofoliului.

c. Antrenarea Perceptronului:
Secțiunea nr.3 de cod C++ pentru antrenarea Perceptronului;

```
#define TRAIN_PERCEPTRON(xDates, ySums, weights, bias, learningRate, epochs) { \
    int n = xDates.size(); \
    for (int epoch = 0; epoch < epochs; epoch++) { \
        for (int i = 0; i < n; i++) { \
            double z = weights[0] * xDates[i] + bias; \
            double prediction; \
            LINEAR(z, prediction); \
            double error = ySums[i] - prediction; \
            double dLinear; \
            LINEAR_DERIVATIVE(prediction, dLinear); \
            weights[0] += learningRate * error * dLinear * xDates[i]; \
            bias += learningRate * error * dLinear; \
        } \
        if (epoch % 100 == 0) { \
            std::cout << ORANGE << "Epoch " << epoch << " completed." << RESET_COLOR << \
            std::endl; \
        } \
    } \
}
```

Sursă: elaborată de către autori/ Source: developed by the authors

Utility: By loading historical “date–amount” data, the training base of the forecasting model is created. From a financial perspective, this step corresponds to building a time series that reflects the daily evolution of a key indicator, in this study, the total balance of the loan portfolio. In financial analysis, the importance of accurately reading and pre-processing data cannot be overstated, as the quality of subsequent predictions depends directly on the precision and consistency of this information. Furthermore, this stage enables the detection of seasonal patterns, the identification of outliers (such as exceptional payments or early repayments), and the further preparation of data for subsequent stress-testing or budget projection scenarios.

b. Implementation of the LINEAR macro:
Section No.2 of the C++ code for the LINEAR macro;

The usefulness of this choice becomes evident when the objective is to forecast continuous values, such as financial amounts. Unlike non-linear activation functions (Sigmoid, ReLU, Tanh), which may limit or transform the output range, the Linear macro allows the prediction of unbounded values, making it the optimal option for forecasting monetary amounts. From a financial perspective, this approach corresponds to a simple linear growth model or a short-term projection of portfolio developments.

c. Training the Perceptron:
Section No.3 of the C++ code for training the Perceptron;

Utilitate: Învățarea propriu-zisă a modelului: prin ajustări repetate, perceptronul identifică relația dintre date (numărul de zile) și sumele asociate. Din perspectivă financiară, acest proces corespunde calibrării unui model predictiv care, pe baza istoricului, poate estima seturile de date viitoare. Modelul învață efectiv cum se distribuie în timp valorile financiare, iar la final poate fi utilizat pentru a anticipa evoluția portofoliului. De asemenea, este important de menționat că perceptronul reprezintă echivalentul unui neuron biologic, definit matematic ca un element fundamental al Inteligenței Artificiale, care calculează o sumă ponderată a intrărilor, multiplicând fiecare intrare cu ponderea sa (care reprezintă importanța intrărilor respective) și apoi adună toate produsele [6]. Modelul matematic este reprezentat mai jos:

$$z = (\sum_{i=1}^n (w_n * x_n)) + b \quad (5)$$

unde: w_n reprezintă greutatea, x_n sunt intrările de date, b – reprezintă constanta de ajustare a rezultatului final, denumită și bias.

d. Prognoza:

Secțiunea nr.4 de cod C++ pentru prognoză;

```
#define FORECAST_PERCEPTRON(newDate, weights, bias, result) { \
    double z = weights[0] * newDate + bias; \
    LINEAR(z, result); \
}
```

Sursă: elaborat de către autori/ Source: developed by the authors

Din punct de vedere practic, aceasta este funcționalitatea care conferă valoare aplicației: oferă posibilitatea de a prognoza bilanțul portofoliului de credite pentru perioade viitoare.

În analiza financiară, o astfel de prognoză sprijină procese precum planificarea lichidității, estimarea fluxurilor de numerar, calculul rezervelor minime obligatorii și evaluarea riscului financiar [7]. Deși modelul implementat este unul simplu (liniar), acesta poate fi extins ulterior prin activări neliniare, introducerea mai multor variabile explicative sau integrarea unor metode avansate de regresie. Totuși, chiar și în această formă elementară, instrumentul are o utilitate practică pentru un analist financiar, permițând obținerea rapidă a unor estimări preliminare pe baza datelor istorice.

Drept rezultat a soluției tehnice, perceptronul linier se evidențiază ca un instrument util în domeniul analizei datelor, oferind un cadru simplu, pentru explorarea relațiilor dintre variabile și realizarea unor prognoze preliminare. Bazat pe o formulare matematică elementară, acesta operează printr-o combinație liniară a variabilelor de intrare, completată de un termen de ajustare (bias), ceea ce îi conferă atât claritate în interpretare, cât și ușurință în implementare.

În analiza financiară, aplicabilitatea perceptronului linier se manifestă prin capacitatea sa de a sprijini estimarea evoluției unui produs bancar specific, anticiparea fluxurilor de numerar și conturarea

Utility: This stage represents the actual learning of the model: through repeated adjustments, the perceptron identifies the relationship between the input data (number of days) and the corresponding financial amounts. From a financial perspective, this process corresponds to the calibration of a predictive model that, based on historical records, can estimate future datasets. The model effectively learns how financial values are distributed over time and can subsequently be used to anticipate portfolio developments. It is also important to note that the perceptron is the equivalent of a biological neuron and is mathematically defined as a fundamental element of Artificial Intelligence. It computes a weighted sum of the inputs by multiplying each input by its weight (representing the importance of each input) and then summing all the products [6]. The mathematical model is shown below:

where w_n represents the weights, x_n are the data inputs, b – is a constant used to adjust the final result, also referred to as the bias.

d. Forecast:

Section No.4 of the C++ code for Forecast;

From a practical standpoint, this is the functionality that gives the application its value: it provides the ability to forecast the loan portfolio balance for future periods. In financial analysis, such forecasting supports processes such as liquidity planning, cash-flow estimation, calculation of minimum reserve requirements, and assessment of financial risk [7]. Although the implemented model is simple (linear), it can be further extended through non-linear activations, the introduction of additional explanatory variables, or the integration of advanced regression methods. Nevertheless, even in this basic form, the tool offers significant practical utility for a financial analyst, enabling rapid preliminary estimates based on historical data.

As a technical solution overall, the linear perceptron stands out as a useful instrument in data analysis, offering a straightforward framework for exploring relationships between variables and producing preliminary forecasts. Based on a simple mathematical formulation, it operates through a linear combination of input variables complemented by an adjustment term (bias), which provides clarity in interpretation. In financial analysis, the applicability of the linear perceptron is evident in its ability to support the estimation of the evolution of a specific banking product, the anticipation of cash flows, and the formation of perspectives regarding the development of asset or bond portfolios. At the same time,

unor perspective privind evoluția portofoliilor de active sau a obligațiunilor. Totodată, simplitatea metodei îl recomandă ca etapă inițială în procesul de modelare.

Astfel, perceptronul liniar nu trebuie privit doar ca un model predictiv limitat, ci și ca un punct de plecare indispensabil în procesul de dezvoltare a tehnicilor moderne de învățare automată și a modelelor complexe utilizate în cercetarea contemporană și în practica economică. Conform funcționalităților implementate, în imaginile ce urmează este prezentată funcționalitatea aplicației în timp real. Aplicația poate fi accesată de orice utilizator, care o deține. Primul pas constă în introducerea datelor istorice în fișierul .csv, după cum este demonstrat în **Figura 4**, ce urmează:

the simplicity of the method recommends it as an initial stage in the modelling process. Thus, the linear perceptron should not be viewed merely as a limited predictive model, but also as an indispensable starting point in the development of modern machine-learning techniques and complex models used in contemporary research and economic practice. According to the implemented functionalities, the following figures illustrate the real-time operation application. The application can be accessed by any authorised user who has access to it. The first step to perform is entering the historical data into the .csv file, as demonstrated in **Figure 4** below:




Figura 4. Introducerea datelor istorice din SGBD în MS Excel (.csv)/ Figure 4. Entry of historical data from the DBMS into Microsoft Excel (.csv)

Sursă: elaborată de către autori/ Source: developed by the authors

Ulterior fișierul MS Excel este salvat, după care este executată aplicația C++, după cum este demonstrat în **Figura 5** de mai jos.

Subsequently, the Microsoft Excel file is saved, and then the C++ application is launched, as shown in **Figure 5** below.




Figura 5. Aplicația în derulare. Meniul de comandă/ Figure 5. Application in operation – Command menu

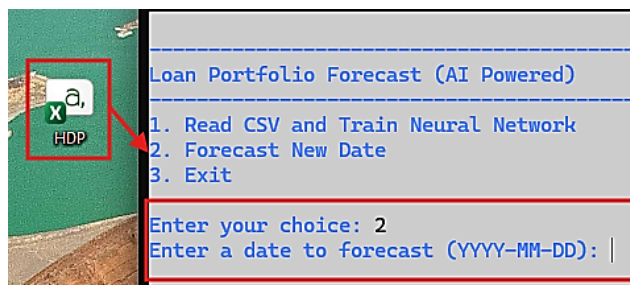
Sursă: elaborată de către autori/ Source: developed by the authors

Conform **Figurii 5** este evidențiată aplicația, în cadrul căreia utilizatorul are posibilitatea de a efectua citirea fișierului .csv, și ulterior, antrenarea automată a rețelei neuronale, care operează direct asupra datelor scanate. Apoi, utilizatorul va avea oportunitatea de a efectua prognoza asupra portofoliului de credite. Aceste etape sunt reprezentate în figurile următoare.

According to **Figure 5**, the application is shown, in which the user can read the .csv file and automatically train the neural network that works directly with the scanned data. The user then has the opportunity to generate a forecast for the loan portfolio. These steps are illustrated in the following figures.

Figura 6. Încărcarea fișierului .csv pentru procesarea datelor prin IA/ Figure 6. Application in operation – Command menu

Sursă: elaborată de către autori/ Source: developed by the authors




În cadrul **Figurii 6** este demonstrată etapa de încărcare a fișierului cu date istorice. Ulterior încărcării, fișierul va fi procesat de către componentele IA ale aplicației, în strictă conformitate cu conceptele descrise și implementate în cadrul acestui studiu.

In **Figure 6**, the stage of uploading the file with historical data is shown. After the upload, the file will be processed by the application's Artificial Intelligence (AI) components, in strict accordance with the concepts described and implemented in this study.

Figura 7. Afișarea rezultatului final al procesării portofoliului/ Figure 7. Final display of the portfolio processing result

Sursă: elaborată de către autori/ Source: developed by the authors



După cum se poate observa în **Figura 7**, utilizatorul a introdus data pentru care urmează să fie generată prognoza, iar aplicația a returnat valoarea – 7803.2, ceea ce semnifică faptul că portofoliul de credite se va diminua până la data de 2024-12-31, cu valoarea indicată.

As shown in **Figure 7**, the user entered the date for which the forecast was to be generated, and the application returned the value –7803.2, indicating that the loan portfolio is projected to decrease by the specified amount as of 31 December 2024.

Reieșind din funcționalitățile aplicației, poate fi formulată următoarea concluzie: deoarece data introdusă reprezintă sfârșitul ultimului trimestru al anului 2024, se atestă o ușoară reducere a activității de creditare, întrucât, din punct de vedere statistic, orice bancă comercială acordă mai puține credite în perioadele de finalizare a ultimului trimestru. Drept motiv, acestea, de regulă, își evaluează performanțele financiare aferente întregului an și, în funcție de rezultate, pot decide să fie mai prudente în acordarea de credite, fapt ce contribuie la optimizarea a bilanțurilor și la atingerea obiectivelor financiare stabilite. De asemenea, în această perioadă, băncile adoptă o atitudine mai conservatoare din perspectiva gestionării riscurilor, dorind să minimizeze expunerile

Based on the functionality of the application, the following conclusion can be drawn: Since the entered date marks the end of the final quarter of 2024, the forecast suggests a slight decline in loan issuance. Statistically, commercial banks tend to grant fewer loans during the closing period of the last quarter. The primary reason is that banks typically evaluate their annual financial performance during this period and, depending on the results obtained, may choose to adopt a more cautious lending approach. This strategy helps them optimise balance sheets and achieve financial targets. In addition, during this period banks become more conservative in risk management, seeking to minimise financial exposures that could affect their stability. Consequently, clients who already hold loans continue

financiare care ar putea afecta stabilitatea acestora. În mod evident, clienții care dețin credite, efectuează achitarea ratelor lunare, fapt care generează într-o măsură mai mare, intrări de fonduri pentru bancă decât ieșiri de fonduri.

Concluzii

În urma efectuării acestui studiu, poate fi dedus cu certitudine faptul că Inteligența Artificială reprezintă o relevanță majoră în prognozarea performanței datelor și a produselor bancare, în cazul dat, a portofoliilor de credite. Prin analizarea unor volume mari de date, Inteligența Artificială este capabilă să identifice modele și tendințe ce pot scăpa observației specialiștilor responsabili pentru analiza datelor. Acest lucru facilitează o evaluare mai exactă a riscurilor, optimizează deciziile de creditare și îmbunătățește administrarea portofoliilor. În plus, tehnologiile bazate pe Inteligența Artificială, pot contribui la o evaluare mai eficientă a bonității clienților, la creșterea capacității de anticipare a situațiilor de nerambursare a creditelor și la personalizarea ofertelor de creditare. Totuși, este important ca instituțiile financiare să abordeze aceste tehnologii cu o bună înțelegere a limitărilor lor, asigurând, în același timp, transparență și etică în utilizarea acestora. Astfel, integrarea Inteligenței Artificiale în prognozarea portofoliilor de credite nu doar că oferă o oportunitate valoroasă pentru îmbunătățirea performanței financiare și reducerea riscurilor, dar implică și necesitatea unei gestionări atente și responsabile, astfel încât să se maximizeze beneficiile fără a compromite integritatea proceselor financiare.

making their monthly payments, resulting in a stronger inflow of funds to the bank rather than an outflow.

Conclusions

Following the completion of this study, it can be firmly concluded that Artificial Intelligence (AI) plays a highly significant role in forecasting the performance of financial indicators and banking products, in this case the loan portfolios. By analysing large volumes of data, AI is capable of detecting patterns and trends that may escape the attention of those responsible for data analysis. This capability enables more accurate risk assessment, optimises lending decisions, and enhances portfolio management. Moreover, AI-based technologies can contribute to more efficient assessments of client creditworthiness, increase the predictability of defaults, and allow for the personalisation of credit offers. Nevertheless, it is essential for financial institutions to approach these technologies with an awareness of their limitations, while ensuring transparency and ethical use. Thus, the integration of Artificial Intelligence into loan portfolio forecasting not only provides a valuable opportunity to improve financial performance and reduce risk, but also necessitates careful and responsible management to maximise benefits without compromising the integrity of financial processes.

Bibliografie/ Bibliography

1. DANSANA, D.; S. G. K. PATRO; B. K. MISHRA; V. PRASAD; A. RAZAK et al. Analyzing the impact of loan features on bank loan prediction using Random Forest algorithm. *Engineering Reports*. Online. 2024, vol. 6, no. 2. Disponibil: <https://doi.org/10.1002/eng2.12707> [accesat 2026-06-02].
2. WANG, H. and Z. XIE. Analyze the influence of various factors on personal loans. *Advances in Economics, Management and Political Sciences*. Online. 2023, vol. 6, no.1, pp. 448–459. Disponibil: <https://doi.org/10.54254/2754-1169/6/2022186> [accesat 2026-06-02].
3. GAUR, P. Advantages and Risks of AI Technologies. *EDU Journal of International Affairs and Research*. Online. 2023, vol. 2, issue 1. Disponibil: <https://edupublications.com/index.php/ejiar> [accesat 2026-06-02].
4. ROUSTAEI, N. Application and interpretation of linear-regression analysis. *Medical Hypothesis, Discovery, and Innovation in Ophthalmology*. Online. 2024, vol. 13, no. 3, pp. 151–159. Disponibil: <https://doi.org/10.51329/mehdiophthal1506> [accesat 2026-06-02].
5. NIKOLOVSKI, F.; I. STOJKOVSKA; K. H.-V. SANEVA and Z. HADZI-VELKOV. Gradient Descent Methods for Regularized Optimization. Online. 2024. Disponibil: <http://arxiv.org/abs/2412.20115> [accesat 2026-06-02].
6. RAMCHOUN, H.; M. AMINE; J. IDRISI; Y. GHANOU and M. ETTAOUIL. Multilayer Perceptron: Architecture Optimization and Training. *International Journal of Interactive Multimedia and Artificial Intelligence*. Online. 2016, vol. 4, no. 1, 26. Disponibil: <https://doi.org/10.9781/ijimai.2016.415> [accesat 2026-06-02].
7. WANG, C.-N.; K.-M. TRAN; F.-C. YANG; T.-T. DANG and N. N. HIEP. Forecasting and Measuring Financial Performance in Banking Sector. *Computer Systems Science and Engineering*. Online. 2022. Disponibil: <https://doi.org/10.32604/csse.2023.032016> [accesat 2026-06-02].