



<http://ensaios.usf.edu.br/>

**FERRAMENTA PARA AUTOMATIZAÇÃO DO PROCESSO DE CONCESSÃO DE CRÉDITO UTILIZANDO DE CONCEITOS DE INTELIGÊNCIA ARTIFICIAL**  
*TOOL FOR AUTOMATION OF THE CREDIT CONCESSION PROCESS USING ARTIFICIAL INTELLIGENCE CONCEPTS*

DANTAS, Gustavo<sup>1</sup> GODOI, Lucas Felipe<sup>2</sup> NETO, Silvio Petroli<sup>3</sup>  
Universidade São Francisco

[dantas2509@gmail.com](mailto:dantas2509@gmail.com) / [lucasfelipegodoi@gmail.com](mailto:lucasfelipegodoi@gmail.com)

**RESUMO.** Tendo em vista o aumento da competitividade do mercado, as empresas estão cada vez mais oferecendo facilidades no pagamento dos títulos, com condições diferenciadas e prazos de pagamento maiores, com isso o risco de inadimplência também aumenta e o trabalho dos analistas no processo de concessão de crédito é dificultado. Este trabalho tem como objetivo apresentar uma ferramenta utilizando do conceito de redes neurais artificiais, mais especificamente baseadas no algoritmo Multilayer Perceptron (MLP), para auxiliar a tomada de decisão de analistas de crédito de empresas com um modelo de negócios baseado no Business to Business (B2B). Para isso, é utilizado um banco de informações contendo, não apenas o histórico de pagamento do cliente, mas sua representatividade no mercado em que se insere. Os resultados mostram que esse tipo de ferramenta tem um grande potencial para auxílio no processo de análise para concessão de crédito tendo em vista que mesmo com um número limitado de dados que foram utilizados para treinamento da rede neural a ferramenta desenvolvida neste trabalho apresentou uma precisão de mais de 90% de acerto e que, em um cenário real, o número de variáveis disponíveis para captação de informações tende a ser maior. Com isso pôde-se concluir que a implementação dessa ferramenta em uma empresa com uma disponibilidade maior de informações irá apresentar uma performance aceitável para os padrões de mercado.

**Palavras-chave:** redes neurais, inteligência artificial, concessão de crédito.


**ABSTRACT.** In order to increase the competitiveness of the market, companies are increasingly offering payment facilities with differentiated conditions and longer payment periods, thus increasing the risk of default and analysts' work in the process of credit is hampered. This paper aims to present a tool using the concept of artificial neural networks, more specifically based on the Multilayer Perceptron algorithm (MLP), to aid the decision making of business credit analysts with a business model based on Business to Business (B2B). For this, an information bank is used, containing not only the payment history of the client, but its representativeness in the market in which it is inserted. The results that this type of tool has a great potential to aid in the process of analysis for granting credit, considering that even with a limited number of data that were used for neural network training the tool developed in this work presented an accuracy of more than 90% accuracy and that, in a real scenario, the number of variables available for gathering information tends to be greater. With this, it was possible to conclude that the implementation of this tool in a company with a greater availability of information will present an acceptable performance to the market standards.

**Keywords:** neural networks, artificial intelligence, credit concession.

## INTRODUÇÃO

O grande crescimento da demanda de crédito nos últimos anos tem chamado atenção de analistas do setor financeiro, principalmente na área de contas a receber das organizações. Segundo Xavier (2011), empresas de diversos portes enfrentam dificuldades durante seu ciclo de vida, porém as menores são mais afetadas por não ter condições de se preparar com contingências assegurando o seu negócio, na Figura 1 é possível verificar o percentual de endividamento das empresas no ano de 2015.

Diante disso, as empresas vêm buscando, através de negociações, melhores condições de pagamento nas compras de produtos de matéria prima ou para revenda otimizando assim seu fluxo de caixa. Ainda neste contexto, os fornecedores dessas empresas também veem vantagens nessa forma de venda, levando em consideração que o crédito a pessoas jurídicas tem alavancado o faturamento das instituições, fazendo com que as perdas do valor do dinheiro no tempo sejam otimizadas e balanceadas com as oportunidades de venda que tiveram com esse novo modelo de cobrança.



**Figura 1** – Endividamento (mediana) de empresas em 2015. Adaptado de: Centro de Inteligência Padrão e Serasa Experian.

Nos dias de hoje, para sobrevivência de qualquer modelo de negócio, seja ele B2B (Business to Business) ou B2C (Business to Customer), a concessão de crédito, através de prazos mais flexíveis de pagamento, deixou de ser opcional e passou a ser indispensável, devido à concorrência estar cada vez mais atenta a essas formas de pagamento. Por isso, para não perder espaço no mercado, as organizações tiveram que reestruturar a sua política comercial.

Neste contexto, as empresas passaram a ofertar seus produtos no mercado, disponibilizando aos clientes diversas condições de pagamento, o que afetou diretamente o departamento de crédito dessas organizações, tornando o trabalho mais complexo em analisar as informações cadastrais e financeiras, que influenciam na capacidade de os clientes pagarem suas dívidas, obtidas através de sistemas de informações como o Serasa Experian e Cadim

para definir os riscos de inadimplência. Neste sentido, o processo de análise para concessão de crédito está se tornando a cada dia mais crítico para o sucesso dos negócios das empresas, fazendo com que o setor busque novas alternativas visando minimizar este risco.

Este trabalho tem como objetivo apresentar uma alternativa com ferramentas computacionais, em específico o uso de inteligência artificial com conceitos e técnicas de redes neurais artificiais para tratar da melhor forma os dados variados obtidos, criando padrões para que se tornem informações úteis que poderão auxiliar os gestores na tomada de decisão, agilizando o processo de análise de crédito, particularmente estimando a probabilidade do cliente proponente ao crédito se tornar inadimplente em determinado período.

Os principais conceitos utilizados neste trabalho foram divididos abaixo em três tópicos: a análise de crédito, redes neurais artificiais e redes neurais na concessão de crédito. Esses conceitos são fundamentais para a resolução do problema discutido aqui.

### *A Análise de Crédito*

A concessão de crédito visa propor uma solução financeira rápida para clientes, seja pessoa física ou jurídica, sendo uma forma de impulsionar a geração de negócios, fazendo com que ambas as partes tenham seus objetivos alcançados. Um plano de concessão garante créditos para que clientes possam realizar compras ou vendas sem que seja necessário possuir o capital inicial total (Blatt 1999). Os critérios para concessão de crédito referem-se às condições financeiras e ao histórico de crédito que um cliente precisa apresentar para estar apto a receber o crédito e são adotados por uma empresa através de seus padrões de crédito.

Se a empresa possui um plano de concessão de créditos que visa apenas impulsionar as vendas, o acontecimento do não recebimento pode inviabilizar o negócio da empresa. Mas, o inverso, ou seja, a excessiva preocupação com a segurança, acaba reduzindo lucros e vendas, diminuindo a rentabilidade, e pode dificultar a geração de novos negócios e recursos para satisfazer os custos e, da mesma forma, fragilizar a instituição.

Para uma concessão criteriosa é preciso atenção; segundo Blatt (1999), ao analisar a viabilidade da concessão de crédito, devem preocupar-se com três elementos fundamentais: segurança, liquidez e rentabilidade.

Também, segundo Blatt (1999), para uma análise precisa devem ser considerados os seguintes pontos:

- Informação creditícia – deve-se investigar a vida financeira do cliente, buscando informações confiáveis para adequar o limite de crédito;
- Histórico de pagamento – dados sobre o comportamento de pagamento do cliente em outras instituições.
- Identificação do cliente – É indispensável conhecer o cliente, bem como as pessoas vinculadas a ele;
- Análise das demonstrações financeiras – A análise creditícia se faz sobre a renda, os valores comprovados e declarados, bem como outras fontes de recursos;
- Qualidade de cobrança – a observação de toda documentação e garantias para concessão do crédito, garantirá uma a qualidade numa futura cobrança;
- Fortalecimento da venda a crédito – realizar a análise de crédito com o objetivo de fidelizar o cliente, fortalecendo o vínculo entre as partes do contrato.

A determinação do risco de crédito é realizada na etapa “análise de crédito” onde se procura determinar o risco de crédito do cliente. Segundo SCHRIKEL (1997) a análise de crédito envolve a habilidade de fazer uma decisão de crédito dentro de um cenário de incertezas, constantes mutações e transformações incompletas. Liberar créditos a alguém significa acreditar que esse alguém saberá usar convenientemente esse dinheiro, em proveito

próprio, de seus familiares ou membros da comunidade, dispondo da capacidade de devolvê-lo acrescido de juros, correção monetária e taxas fiscais que se fizerem necessárias, na data certa e determinada.

Dentre os diversos instrumentos disponíveis para avaliação de risco, este trabalho se constitui em uma só proposta: avaliação de risco de crédito para os gerentes de operações com base nos quatro “Cs” do crédito que, de acordo com Santi (2000), são:

a) **Caráter:** que verifica a intenção do proponente do crédito pagar o empréstimo obtido, tendo como base informações cadastrais do cliente, denominando-o risco técnico pois as informações obtidas indicam seguramente o que se precisa avaliar.

b) **Capacidade:** que verifica a habilidade do tomador do crédito a pagar suas dívidas, analisando sua competência empresarial, tempo de atividade e organização por exemplo.

c) **Condições:** que aborda as questões de mercado e competitividade dos produtos vendidos pelo cliente, analisando o ambiente ao qual o cliente está inserido.

d) **Capital:** que analisa a situação econômico-financeira da empresa como faturamento, rentabilidade e patrimônio líquido.

Uma das técnicas para se administrar as várias informações é a análise objetiva de crédito que de acordo com Santos (2003), busca através de metodologias estatísticas, amparadas por pontuações de risco que são obtidas através de fórmulas desenvolvidas que tem como objetivo atestar a capacidade de pagamento do crédito obtido.

Para se obter acesso a alguns destes dados, Santi (2000) comenta que existe a possibilidade de se conveniar a empresas que se dedicam exclusivamente em levantar, processar e prestar informações sobre o assunto através de soluções inteligentes de mercados utilizando da análise objetiva de crédito para pontuar os diferentes aspectos citados anteriormente, como é o exemplo do Serasa Experian, Boa Vista SPC, Cadim – Cadastro de Inadimplentes da União e a CISP - Central de Informações São Paulo.

### *Redes Neurais Artificiais*

Para Bitencourt (2006), sistemas inteligentes que se auto aperfeiçoam eletronicamente, utilizando-se da capacidade do computador para processar símbolos, simulando a mente humana, são incluídos dentro da área da inteligência artificial.

Um dos ramos de destaque desta área são as Redes Neurais Artificiais, ou simplesmente RNAs, que são de acordo com Fausett (1994) definidas como um método de resolução de problemas dentro da inteligência artificial, simulando o cérebro humano e seu comportamento. São constituídos de modelos matemáticos baseados no funcionamento dos neurônios biológicos que adquirem conhecimento através da experiência. Oswald Ludwig (2009) também acrescenta que, uma rede neural consiste em um sistema computacional estruturado e interligado para formar uma única rede de informações. A maior vantagem é que na execução de tarefas numa rede neural não necessita armazenar instruções de comando e executá-las de forma lógica, como em um processo tradicional.

Esta é uma característica de importância primordial das Redes Neurais Artificiais: capacidade de aprender no ambiente em que está inserido e generalizar o problema encontrando uma melhor solução. Este processo é denominado treinamento, que consiste basicamente em um problema de minimização não linear, em que os pesos sinápticos da rede são iterativamente modificados para minimizar o erro entre a resposta desejada e a saída obtida.

Normalmente, o processo de treinamento é realizado a partir de casos reais conhecidos, quando a rede demonstra a capacidade de adquirir regras básicas a partir destes casos. (Santos et al, 2005).


Uma rede neural é especificada, principalmente pela sua formação, pelas particularidades dos nós e pelas regras de treinamento. São treinadas de acordo com as necessidades do usuário, podendo obter respostas mais rápidas e eficientes, determinando o modelo e arquitetura da rede neural.

O comportamento das conexões entre os neurônios é simulado por meio de seus pesos. Os valores de tais pesos podem ser negativos ou positivos, dependendo de as conexões serem inibitórias ou excitatórias. O efeito de um sinal proveniente de um outro neurônio é determinado pela multiplicação do valor (intensidade) do sinal recebido pelo peso da conexão correspondente. De uma forma simplificada, uma rede neural artificial pode ser vista como um grafo onde os nós são os neurônios e as ligações fazem a função das sinapses.

As redes neurais artificiais se diferenciam pela sua arquitetura e pela forma como os pesos associados às conexões são ajustados durante o processo de aprendizado. A arquitetura de uma rede neural restringe o tipo de problema no qual a rede poderá ser utilizada, e é definida pelo número de camadas (camada única ou múltiplas camadas), pelo número de nós em cada camada, pelo tipo de conexão entre os nós (feedforward ou feedback) e por sua topologia (HAYKIN, 2001).

Oswald Ludwig Jr (2009), ilustra uma rede neural conforme Figura 2 e a define com as seguintes características:

- Uma camada de entrada ou distribuição, com função é representar a distribuição dos dados de entrada para cada neurônio da camada seguinte;
- Uma, nenhuma ou várias camadas ocultas, cujo função é capacitar a rede a extrair estatísticas, além de possibilitar a representação de problemas que não sejam linearmente separáveis.
- Uma camada de saída que contém, necessariamente, um número de neurônios igual ao número de sinais de saída da rede.



**Figura 2** – Exemplo de RNA defendida por Oswald Ludwig Jr (2009) (Adaptado de: Fundamentos e Aplicações com Programas em C, 2007).

As Redes Neurais podem ser diferenciadas quanto à forma de aprendizagem, usando os seguintes paradigmas (BISHOP, 1995):

- **Aprendizado não supervisionado:** não existe um supervisor acompanhando o processo de aprendizagem. Diante disso, a RNA deve procurar algum tipo de correlação ou redundância nos dados de entrada.
- **Aprendizado supervisionado:** um supervisor externo fornece à RNA a saída desejada em relação a um padrão de entrada. Com isso, é possível comparar a saída da RNA com a saída desejada, obtendo-se o erro referente à resposta atual. A partir disso, os pesos sinápticos são ajustados de forma a minimizar o erro. A minimização do erro é incremental, pois a cada resposta gerada pela rede, são efetuados pequenos ajustes nos pesos das conexões.

Haykin (2001) destaca os seguintes algoritmos de aprendizagem: aprendizagem por retropropagação do erro ou backpropagation, aprendizagem baseada em memória, aprendizagem hebbiana, aprendizagem competitiva e aprendizagem de Boltzmann. A principal diferença entre elas é pela forma que cada ajusta o peso sináptico de um neurônio.

Para o desenvolvimento deste trabalho foi constatado que o treinamento supervisionado é a forma de aprendizagem ideal para trabalhar com redes neurais na concessão de crédito. Diante disso foi necessário captar informações inerentes aos riscos de crédito já explanadas anteriormente, formando assim um dataset de treinamento, testes e validação.

### *Redes Neurais para Concessão de Crédito*

Para a concessão de crédito, as redes neurais buscam reduzir a possibilidade do não-pagamento, mediante a análise de crédito, tornando-se cada vez mais crucial para bancos, financeiras, comércio e indústria. Um sistema inteligente para análise de crédito é hoje um sistema de grande utilidade para o mundo dos negócios.

Nesse contexto, especificamente nas áreas comercial e de finanças, destaca-se o uso de técnicas de rede neural na avaliação de riscos para a concessão de crédito, já que estas são adaptadas para trabalhar com várias entradas e várias saídas, sendo facilmente aplicáveis a sistemas com muitas variáveis. Envolvem, inclusive, inúmeras implicações estratégicas e organizacionais, podendo se destacar como uma ferramenta de suporte à decisão e como fonte de vantagem competitiva para as empresas

Desta forma, a rede neural destaca-se como uma ferramenta apropriada ao processo de análise de crédito, indicada para lidar com apoio à decisão, segmentação e otimização, permitindo, de maneira eficaz, trabalhar sobre uma base de dados com origem em diversas fontes, informações incompletas, ambíguas ou até mesmo parcialmente incorretas, oferecendo um suporte significativo nos termos de organizar, classificar e interpretar dados. Permite às empresas identificar bons e maus pagadores, pois aprendem de maneira sistemática com atualizações constantes, melhorando, portanto, seu desempenho. (BLATT, 1999).

Ribeiro et al (2005) ressalta que, por funcionar com um sistema de aprendizagem, a rede neural identifica o novo perfil do cliente, a partir de novas informações acrescentadas ao cadastro, sendo capaz de generalizar por exemplos anteriores, ou seja, responder corretamente a uma entrada jamais vista, por similaridade aos padrões já apresentados.

Neste contexto, foi utilizado o algoritmo de treinamento backpropagation, ou retropropagação do erro. Consiste de dois passos através de diferentes camadas de rede: um passo para frente, a propagação, e um passo para trás, a retropropagação. No passo para frente, um vetor de entrada é aplicado aos nós sensoriais da rede e seu efeito se propaga através dela, camada por camada. Um conjunto de saída então é produzido como a resposta real da rede. Durante a propagação, os pesos sinápticos da rede são todos fixos. Por outro lado, durante o passo de retropropagação, os pesos sinápticos são todos ajustados de acordo com a regra de correção de erro. A resposta real da rede é subtraída da resposta desejada para produzir um sinal de erro. Este sinal é então propagado para trás através da rede, contra a direção das conexões sinápticas. Os pesos reais novamente são ajustados para que a resposta real da rede se mova para mais perto da resposta desejada (HAYKIN, 2001).


A aplicação deste algoritmo requer a escolha de um conjunto de parâmetros (número de iterações do algoritmo, critério de parada, pesos iniciais, taxa de aprendizado), cuja influência pode ser decisiva para a capacidade de generalização da rede.

Segundo Biondi (2011), deve-se ter cuidado para não utilizar nem unidades demais, o que pode levar a rede a memorizar os dados de treinamento, ao invés de extrair as características gerais que permitirão a generalização, nem um número muito pequeno, que

pode forçar a rede a gastar tempo em excesso tentando encontrar uma representação ótima. O parâmetro taxa de aprendizado tem grande influência durante o processo de treinamento da rede neural, uma vez que, a taxa de aprendizado sendo muito baixa torna o aprendizado da rede muito lento, ao passo que uma taxa de aprendizado muito alta provoca oscilações no treinamento e impede a convergência do processo de aprendizado. Define o número de iterações do algoritmo, ou seja, o número de vezes em que o conjunto de treinamento é apresentado à rede. O método de parada do treinamento adotado é uma combinação dos parâmetros citados acima.

Para a rede neural desenvolvida, optou-se por utilizar o modelo conexionista perceptron de múltiplas camadas ou multilayer perceptron (MLP).

Oswald Ludwig Jr (2009) define uma MLP como uma rede com uma camada sensorial ou camada de entrada, que possui tantos nós de entrada quantos forem os sinais de entrada, uma ou mais camadas ocultas de neurônios e uma camada de saída com um número de neurônios igual ao número de sinais de saída conforme ilustrado na Figura 3. O sinal de entrada se propaga para frente através das camadas até a camada de saída. Por ser uma generalização de rede perceptron, é treinada de forma supervisionada. O modelo do perceptron multicamadas utiliza uma topologia de três ou mais camadas. As conexões entre as unidades são do tipo intercamadas e são direcionadas da camada de entrada para a camada de saída. No modelo dos perceptrons multicamadas, entre uma camada e outra, existe uma matriz de pesos. A regra de propagação é a combinação entre as saídas de cada unidade e a matriz de pesos, sendo realizada através da soma ponderada de cada sinal que chega, via conexões, pelo respectivo peso. O estado de ativação assume valores contínuos e devido a isto a regra de ativação das unidades utiliza como função de ativação uma função do tipo sigmoide. A função sigmoide também se faz necessária pela regra de aprendizado que utiliza uma função de ativação contínua, não-decrescente e diferenciável.



**Figura 3** – Exemplo de um MLP. (Adaptado de: Fundamentos e Aplicações com Programas em C, 2007)

## METODOLOGIA

Uma vez entendido todos os conceitos principais relacionados a crédito e a concessão deste, bem como o funcionamento e teorias envolvidas nas redes neurais artificiais, é possível realizar de fato o desenvolvimento da ferramenta proposta.

Para o desenvolvimento deste trabalho, como já citado anteriormente, foi utilizado uma rede neural do tipo *multilayer perceptron* (MLP), tendo em vista que suas camadas intermediárias possibilitam uma melhor aproximação dos resultados esperados devido ao problema se tratar de uma seleção não-linear.

Para a parametrização do algoritmo são necessários seguir os seguintes passos: coleta e tratamento dos dados, codificação do algoritmo e representação dos resultados que serão detalhados ao decorrer deste tópico.

### *Coleta e Tratamento dos Dados*

Para o desenvolvimento deste trabalho foram utilizados dados de clientes que realizaram compras a prazo em uma empresa do setor industrial em um certo período. Após autorização da empresa para a captação de dados, foi necessário entender como é o processo de controle de pedidos da empresa e como são armazenados os dados no banco de dados afim de extrair somente os dados necessários para efetuar as simulações na rede neural.

Como citado e exemplificado anteriormente existem empresas que se dedicam exclusivamente na coleta e compilação de dados que são enviados a elas por parceiros e associados para montagem de um relatório de consulta detalhado que facilitam a tomada de decisão com segurança no processo de análise de crédito. A cedente dos dados é associada de uma dessas empresas e utiliza as informações compiladas para auxílio do trabalho dos analistas de crédito.

Dentre as diversas informações constantes neste relatório existe uma seção intitulada “Risco de Performance”, onde são apresentadas pontuações obtidas através de cálculos estatísticos referentes aos critérios de: crédito na praça, pontualidade no nível de atraso, relacionamento no mercado, ocorrências negativas e densidade comercial.

De acordo com os conceitos abordados por Santi (2000) os critérios de pontualidade, ocorrências negativas, relacionamento no mercado e crédito na praça, dentro dos C’s do crédito estão incluídos na dimensão de caráter do cliente, já a densidade comercial se encaixa na dimensão de condições

As notas estão representadas em uma escala de zero a cinco, onde zero significa baixo nível no quesito e cinco significa alto nível no quesito. Essas pontuações são calculadas e representadas mês a mês de acordo com as informações que os associados enviam duas vezes por semana tendo como resultado um histórico de performance dos clientes das empresas associadas. Abaixo, na Tabela 1, está um exemplo de como o histórico de pontuação é disponibilizado ao associado.

**Tabela 1** – Exemplo de risco de performance de um cliente aleatório.

	Set/17	ago/17	jul/17	jun/17	mai/17	abr/17	mar/17	fev/17	jan/17	dez/16	nov/16	out/16	set/16
<b>Classificação de Risco</b>	<b>B</b>	B	A	C	C	C	B	B	B	B	B	B	B
<b>Quesitos</b>													
<b>Pontualidade</b>	<b>2</b>	2	4	1	1	1	5	5	5	5	5	5	5
<b>Relac. no Mercado</b>	<b>5</b>	5	5	5	5	5	5	5	5	5	5	5	5
<b>Ocorrências Negativas</b>	<b>5</b>	5	5	5	5	5	5	5	5	5	5	5	5
<b>Crédito na Praça</b>	<b>3</b>	3	3	3	3	3	3	3	3	3	3	3	3
<b>Densidade Comercial</b>	<b>3</b>	3	3	3	3	2	2	2	2	2	2	2	2

Adaptado de: LeiteSol Indústria e Comércio S. A., 2017.

A seleção dos clientes foi feita aleatoriamente e foram considerados clientes que não efetuaram o pagamento de um ou mais dos títulos gerados até a data do vencimento, isto é, o critério de inadimplência utilizado foi o do primeiro dia, ou seja, caso o título não tinha sido quitado até a data de vencimento do mesmo, o cliente é considerado inadimplente. Na planilha de treinamento foi inserido uma coluna com essa informação, onde 1 significa que o



cliente efetuou o pagamento até a data limite e 0 significa que não foi identificado pagamento ou foi identificado após a data de vencimento do título.

Para o modelo da rede neural apresentado neste trabalho foi coletado esse histórico de performance dos últimos doze meses contando a partir da data em que o pedido do cliente foi submetido à análise de crédito da empresa juntamente com as informações de débitos a vencer e débitos vencidos a cinco, quinze e trinta dias referente a compras que foram realizadas anteriormente em todos os associados.

Para utilização desses dados na rede neural, como as pontuações já são representados de forma numéricas e limitadas não foi necessário nenhum tipo de tratamento com relação às informações, porém como foi utilizado a biblioteca Pandas, que é um projeto open source desenvolvido por pessoas de diferentes países ao redor do globo que busca facilitar o trabalho de análise de estruturas de dados com alta performance, foi necessário realizar o processamento dos dados coletados e transformar a planilha em um arquivo com formato CSV (*Comma-separated values*), disponibilizando as informações separadas por vírgulas para posteriormente possibilitar a conversão desses dados em estrutura de arranjos comumente chamados de *arrays*, que facilitaram o uso das informações no modelo da rede neural.

Com a utilização de um algoritmo MLP, é recomendado por parte dos desenvolvedores da biblioteca utilizada a realização de um processo de normalização no *dataset* já convertido através da biblioteca Panda. É recomendado pois a utilização de um *dataset* grande pode resultar em uma predição incorreta, devido a implementação utilizada pelo algoritmo. A fim de garantirmos uma predição mais acurada, foi utilizado o *StandardScaler*, processo onde é subtraído a média dos valores afim de garantir uma variância unitária sob os dados analisados, assim, trabalhando com uma variância pequena entre os valores.

### *Codificação do Algoritmo*

O desenvolvimento do algoritmo da rede neural para análise do perfil do cliente foi realizado utilizando a linguagem de programação *Python* (v3.6.2), com o auxílio da plataforma *PyCharm* da *JetBrains*© (v.2017.2.2).

No algoritmo desenvolvido, foi utilizada a biblioteca *scikit-learn* (v0.19.1). Esta é uma biblioteca de aprendizado de máquina *open-source* para *Python*, incluindo algoritmos já implementados para classificação, regressão e agrupamento incluindo máquina de vetores de suporte e florestas aleatórias. A escolha da biblioteca para o desenvolvimento do algoritmo foi motivada pela facilidade que a mesma traz, uma vez que todos os algoritmos necessários para a construção da rede neural já estão previamente implementados, e seu funcionamento garantido pela ampla utilização da biblioteca em diferentes aplicações.

Uma vez tendo os dados previamente processados através das ferramentas de compatibilização e normalização descritas anteriormente, é realizado o processo de treinamento da rede neural. Para isso, é utilizado o objeto *MLPClassifier*, disponibilizado na biblioteca. Este objeto encapsula todas as implementações necessárias para o funcionamento da rede neural desenvolvida, a exemplo a rede MLP e o algoritmo de treinamento *Backpropagation*. No momento que é instanciado o objeto, é possível informar diversos parâmetros, responsáveis pelos comportamentos que os algoritmos irão ter durante a execução. Para o projeto de análise de créditos, foi utilizado apenas dois parâmetros: a configuração das camadas (*hidden\_layer\_sizes*), responsável por definir a quantidade de neurônios por camada utilizada, e o parâmetro de limite de iterações (*max\_iter*), responsável por definir um limite máximo de iterações por camada analisada. A escolha dos valores utilizados se deu baseado em diversos testes executados, onde foi se medindo a eficácia dos

resultados baseados nos parâmetros definidos. Esta análise será abordada logo a frente deste artigo.

Após a execução dos treinamentos, é possível então realizar a predição dos dados. Para isto, é utilizado o método *predict()*, também disponível através do objeto *MLPClassifier*. Ao executar, baseado nos resultados obtidos pelo treinamento realizado, é retornado o valor estimado relacionado aos dados de entrada do método. Os dados de entrada devem ser os mesmos utilizados para o treinamento, bem como, estar na mesma ordem. Para o algoritmo de análise de crédito, o resultado esperado é a determinação se o devido cliente solicitador de crédito irá realizar o pagamento de forma efetiva, sendo representado através do valor 1 quando o cliente deverá pagar o crédito recebido ou 0, quando existe maior possibilidade de o cliente não realizar o pagamento. É possível analisar N modelos em uma única predição.

### Representação dos resultados

Uma vez tendo o algoritmo implementado, é necessário ajustar os parâmetros estabelecidos para o objeto de treinamento utilizado. Estes parâmetros influenciam diretamente nos resultados obtidos pela rede neural, sendo então necessário dedicar e estudar as possíveis variâncias das predições realizadas diante dos dados de entrada.

A biblioteca *scikit-learn* facilita esta medição de eficácia e assertividade do algoritmo, provendo duas visualizações dos resultados obtidos: através da *ConfusionMatrix* e *ClassificationReport*. A *ConfusionMatrix* tem como objetivo evidenciar o quanto seu modelo de classificação está “confuso” no momento de realizar predições. O resultado desta visualização de eficiência evidencia duas informações importantes para qualquer análise: além de informar a quantidade de itens classificados de forma correta, exibe ao interessado a quantidade de itens classificados de forma incorreta, informando para qual classificação aquele dado acabou sendo identificado. Com isto, é possível não só analisar o quanto a rede neural está errando, mas auxilia na identificação de qual informação leva a rede neural a classificar de forma incorreta. Uma *ConfusionMatrix* tem o seguinte formato (Figura 4).

		Resultados obtidos	
		Evento 1	Evento 2
Resultados esperados	Evento 1	3	0
	Evento 2	1	4

**Figura 4** – Exemplo de uma *ConfusionMatrix* (Fonte: Próprio autor).

Analisando a *ConfusionMatrix* exemplificada, podemos perceber que no momento da análise do E1(Evento 1), se obteve 100% quando analisado o *recall* (sensibilidade dos dados), uma vez que, observando a linha do E1, somente temos três registros classificados como E1 e zero classificados como E2. Entretanto, quando analisado a *precision* (precisão dos dados analisados), observamos que, para E1, foi obtido a taxa de 75%, uma vez que houve 1 dado que deveria pertencer ao E1, foi classificado como E2. Para a análise da coluna E2, obtemos um *recall* de 80%, uma vez que a rede neural identificou um único registro como E1 o que

deveria ser identificado como E2, e uma precisão de 100%, uma vez que todos os elementos observados pertencem a E2. Desta forma, podemos chegar na conclusão que, para uma rede neural com cujo a precisão seja igual a 100%, é necessário que a *ConfusionMatrix* seja igual a uma matriz diagonal, onde todos os itens que não pertencem a diagonal da matriz são iguais a zero.

A outra visualização obtida através da biblioteca é a chamada *ClassificationReport*, que nada mais é que uma visão matemática dos resultados obtidos através da *ConfusionMatrix*, conforme exemplo abaixo (Tabela 2).

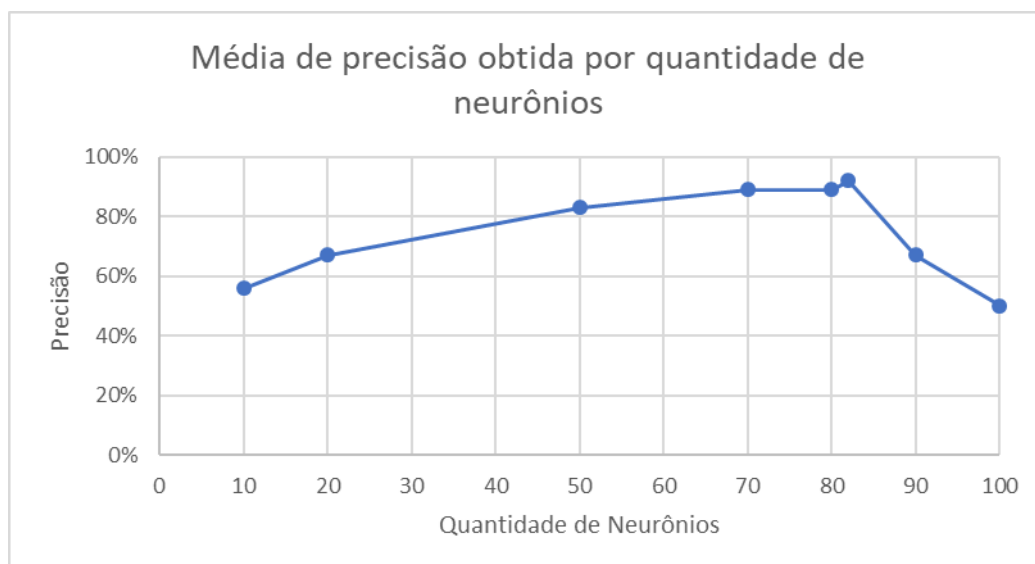
**Tabela 2** – Exemplo de resultado obtido através da ferramenta *ClassificationReport* (Fonte: Próprio autor).

	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>	<i>Support</i>
Evento 1	0.75	1.00	0.86	3
Evento 2	1.00	0.80	0.89	5
Avg/Total	0.87	0.90	0.87	8

Os valores obtidos pela coluna *Precision* indicam o quanto os resultados obtidos são úteis, enquanto os valores obtidos pela coluna *Recall* indicam o quão completo os dados estão. *F1-score* é a média harmônica entre *Precision* e *Recall*, obtendo um valor único para análise. A média harmônica é obtida através divisão dos números de membros pela soma dos inversos dos membros considerados. *Support* indica a quantidade de dados avaliados por evento ocorrido.

## RESULTADOS E DISCUSSÃO

Uma vez possuindo o entendimento do funcionamento da biblioteca utilizada, bem como das métricas e análises disponíveis pela mesma, é possível ajustar a rede neural desenvolvida, com o intuito de maximizar a precisão obtida. Para as análises a seguir, utilizamos o mesmo *dataset*, tanto para treinamento quanto para predição da rede neural.



**Figura 5** –Variação de média de precisão obtida para quantidade de neurônios parametrizados (Fonte: Próprio autor).

Como podemos observar na Figura 5, a parametrização inicial de quantidade de neurônios por camada realizada na instanciação da MLP é extremamente importante,

influenciando diretamente na precisão obtida pela rede neural após a execução do treinamento. Vale pontuar que estas variações não são relacionáveis, ou seja, não existe uma função linear que poderá prever o comportamento quando alterado qualquer que seja o parâmetro de entrada.

Conforme também visto na Figura 5, foi possível chegar a um resultado de 90% de precisão com o algoritmo desenvolvido, ou seja, é garantido a prevenção de forma incorreta 1 em cada 10 clientes solicitantes de créditos, assim podendo admitir que com a utilização do algoritmo, a empresa responsável por conceder os créditos pode realizar tal atitude com maior segurança, e o cliente, terá maiores oportunidades de crescimento, na medida que for atingindo as expectativas do mercado em que se insere e honrando quaisquer espécie de dívida e pagamento que lhe acarreta.

## CONCLUSÃO

O projeto teve como objetivo a construção de algoritmo de análise de concessão de créditos baseado em redes neurais artificiais. A partir de uma base de dados real fornecida por uma importante empresa de laticínios brasileira, identificou-se que o algoritmo baseado no *MLP* conduziu a resultados satisfatórios na predição de perfil de pagadores. Os resultados mostraram que o modelo criado consegue identificar corretamente com mais de 90% de precisão os clientes proponentes a crédito que se tornaram inadimplentes, porém, é importante ressaltar que, como qualquer rede neural, a falta do *insight* no resultado obtido pode acabar levando o responsável a uma tomada de decisão diferente, uma vez que a rede não consegue lidar com variáveis mais complexas, principalmente aquelas que não possuem qualquer relação linear.

É necessário salientar também que o *dataset* que foi usado para treinamento segue somente alguns dos princípios dos quatro C's do crédito explanados neste trabalho, em um cenário real, os analistas de crédito possuem mais informações para trabalhar, como por exemplo balanço anual, informações de faturamento e algumas vezes acesso até ao fluxo de caixa dos clientes dependendo da situação. Por isso pode-se concluir que em uma implantação dessa ferramenta em uma empresa, tendo acesso a todas as informações que os analistas utilizam a precisão da solução tende a ser maior.

Considerando que a concessão de crédito dentro do mercado empresarial possui grande influência na sobrevivência de uma empresa, buscou-se apresentar uma ferramenta baseada em redes neurais, que possibilita auxiliar a tomada de decisão, uma vez que a mesma indica a tendência maior de recebimento do cliente. A ferramenta pode garantir ao responsável pela concessão de créditos uma agilidade e subsídios na tomada de decisão.

O responsável pela concessão de créditos deve utilizar a ferramenta como um facilitador, e não verdade absoluta para sua decisão, pois em alguns casos ainda será necessária uma análise mais profunda e menos automatizada, levando em consideração também o risco que a empresa considera aceitável balanceando o relacionamento comercial e sua política de crédito. Apesar da rede desenvolvida ter obtido uma boa média quando observada a precisão de acertos, não é possível garantir a sua acuracidade total, pois como qualquer estimativa, é passível de erros.

## REFERÊNCIAS

BIONDI NETO, L. B. **Introdução a Redes Neurais Artificiais**. 2011. 65 f. Rio de Janeiro.

BISHOP, C. **Neural Networks for Pattern Recognition**. Oxford University Press, 1995.

BLATT, Adriano. **Avaliação de risco e decisão de crédito: um enfoque prático**. São Paulo: Nobel, 1999.

BITENCOURT, Guilherme. **Inteligência artificial - Ferramentas e teorias**. 3ª ed. Santa Catarina: UFSC, 2006.

FAUSETT, Laurene V. **Fundamentals of neural networks: architectures, algorithms, and applications**. USA: Prentice-Hall, 1994.

FILHO, SANTI, Armando de. **Avaliação de riscos de crédito: para gerentes de operações**. São Paulo: Atlas, 12/2000.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**, 2nd edição. Porto Alegre: Bookman, 2007.

LUDWIG JR. O. e COSTA, Eduard Montgomery M. **Redes Neurais: Fundamentos e Aplicações com Programas em C**. Rio de Janeiro: Editoria Ciência Moderna Ltda. 2007.

SELAU, Lisiane Priscila Roldão; RIBEIRO, Jose Luis Duarte. **Construção de modelos de previsão de risco de crédito**. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2008.

XAVIER, C. G. **Risco na análise de crédito**. Florianópolis: UFSC, 2011.