

LIFT *papers*

REVISTA DO LABORATÓRIO
DE INOVAÇÕES FINANCEIRAS
E TECNOLÓGICAS

2ª EDIÇÃO

LIFT Papers

Revista do Laboratório de Inovações Financeiras
e Tecnológicas

Volume 2 • Número 1 • Maio 2020

Editor-Chefe da Revista

André Henrique de Siqueira, PhD

Editor Adjunto da Revista

Aristides Andrade Cavalcante Neto, MSc
Rodrigo de Azevedo Henriques

Corpo Editorial da Revista

Marcus Vinicius Cursino Soares
Rafael Sarres de Almeida

Ficha catalográfica elaborada pela Biblioteca do Banco
Central do Brasil

LIFT Papers / Banco Central do Brasil. Vol. 2, n. 1,
(maio 2020). Brasília: Banco Central do Brasil, 2020.

Semestral

Disponível em:

https://www.liftlab.com.br/docs/lift_Red.pdf.

ISSN 2675-2859

1. Inovação Tecnológica – Brasil. 2. Sistema Financeiro –
Brasil. 3. Crédito. I. Banco Central do Brasil.

CDU 336.7:004.738.5

Presidente do Banco Central do Brasil

Roberto Campos Neto

Presidente da Fenabac

Paulo Renato Tavares Stein

Comitê-Executivo LIFT 2020

Aloisio Tupinambá Gomes Neto

André Henrique de Siqueira – Coordenação

Aristides Andrade Cavalcante Neto – Coordenação

Breno Santana Lobo

Hélio Fernando Siqueira Celidonio

Marcus Vinicius Cursino Soares

Rafael Sarres de Almeida

Reinaldo Lívio Wielewski

Rodrigo de Azevedo Henriques – Coordenação

Maria Aparecida Padilha Ribeiro – Coordenação

Representantes dos Parceiros de Tecnologia

AWS

Leandro Bennaton

Ana Motta

IBM

Fábio Luis Marras

Ludimila Salimena

Leonardo Guaraldi Couto

MICROSOFT

Ronan Damasco

João Paulo Fernandes

Cristiano Gomes

R3

Keiji Sakai

Luiz Jerônimo

MULTILEDGERS

Pedro Souza

Marcela Gonçalves

CIELO

Gustavo Burin

Watson Silva

WiP

Waldemar Neto e Eduardo Lemos***

O presente projeto verificou com sucesso a possibilidade de estimar a probabilidade de demissão do colaborador de uma empresa privada. Essa informação serve como insumo para a análise de crédito na modalidade consignado privado e outras modalidades, reduzindo o risco de *default*, consequentemente, a taxa de juros ofertada. A predição de demissão do colaborador também serve para seleção e políticas de manutenção de colaboradores pelo RH das empresas. O serviço será oferecido e disponibilizado por meio de uma API.

*waldemar@wip.vc

**eduardo.lemos@isgsa.com.br

.....Introdução

A WiP é uma *fintech* que oferece empréstimo consignado privado através de uma plataforma 100% *on-line*. Nosso propósito é tornar o mercado de crédito mais justo, de modo que ele possa impulsionar sonhos e melhorar a vida das pessoas.

Fundada por gestores e profissionais com experiência no mercado financeiro e empresarial, aliada a um time de notáveis da área de TI, a WiP desenvolveu uma plataforma própria, que realiza a análise de crédito de forma automatizada, valorizando agilidade, transparência, segurança e taxas justas para quem precisa de crédito. Estamos na nossa terceira versão, aperfeiçoando funcionalidades baseadas em recomendações de usuários.

Este relatório técnico se propõe a apresentar o projeto de pesquisa aplicada sobre a predição de demissão dos funcionários do grupo ISG e possui a seguinte estrutura: a seção *Objetivos* instrui como deve ser redigido o propósito do projeto; na seção *Fundamentação teórica* encontram-se as instruções de como enumerar e descrever as referências básicas utilizadas para o projeto; a seção *Visão geral* descreve como elaborar a declaração de visão do projeto em questão; a seção *Características inovadoras* delimita que características devem ser esclarecidas com detalhes para o projeto; essas mesmas características são contextualizadas na seção *Contribuição para o SFN*; a seção *Restrições* deve discutir quaisquer fatores que porventura impeçam a aplicação do projeto no SFN, sejam de ordem regulamentar sejam de ordem prática; e, por fim, a seção *Conclusão* sumariza o conteúdo deste documento.

.....1 Objetivos

A WiP trabalha com oferta de crédito consignado privado para funcionários celetistas de empresas. O risco de *default* do crédito consignado em folha de pagamento é baixo, mas existe, por ocorrência da demissão ou falecimento do colaborador, por exemplo.

Atualmente, os modelos de análise de crédito não conseguem prever inúmeros acontecimentos que podem vir a ocorrer na vida dos tomadores, como a probabilidade dele(a) vir a ser demitido(a), e que poderiam ser identificados com algoritmos bem treinados e desenvolvidos. Essa falta de informação aumenta o risco da operação de crédito e, consequentemente, a taxa de juros cobrada do tomador.

Desse modo, o projeto busca utilizar um ou um conjunto de algoritmos e variáveis cadastrais, financeiras, comportamentais e de *performance* para prever a demissão dos funcionários e, assim, tornar mais precisa a análise de crédito e, por conseguinte, diminuir o risco de *default* e a taxa de juros ofertada.

.....2 Fundamentação teórica


A Pesquisa Perfil do Inadimplente do 3º trimestre de 2016, realizada pela Boa Vista SCPC (Serviço Central de Proteção ao Crédito), afirma que é o “desemprego – historicamente

a principal razão para o atraso no pagamento das contas – com 37%” sobre o total da inadimplência no país.

Em junho de 2019, a Serasa Experian divulgou os resultados de uma pesquisa sobre a inadimplência e relatou que o “número de brasileiros com dívidas atrasadas aumenta em 2 milhões e bate novo recorde”. E concluiu que “Isto significa que 40,4% da população adulta do país está com dívidas atrasadas e negativadas”.

Ainda segundo a pesquisa da Boa Vista SCPC “uma em cada quatro pessoas (25%) aponta o descontrole financeiro como responsável pela inadimplência”. O segundo principal motivo da inadimplência, apesar de muito influenciado pela descrição do inadimplente, já pode ser previsto pelos dados históricos do inadimplente. Já a perda do emprego e, conseqüentemente da renda, dificilmente pode ser previsto pelo inadimplente ou pelas instituições antes de oferecer o crédito.

De acordo com LeCun *et al.* (2015), diversas áreas como negócios, ciências e medicina têm apresentado sucesso na utilização dessa vasta disponibilidade de dados ao empregarem a tecnologia de *Machine Learning* (Aprendizado de Máquina) para análise de *Big Data*. Os autores relatam que *Machine Learning* tem aprimorado pesquisas realizadas na internet, recomendações de amizades nas redes sociais e predição de texto em *smartphones*. Sistemas utilizando *Machine Learning* também estão sendo usados, com alto grau de precisão, para identificação automatizada de objetos em imagens, processamento de linguagem natural e reconhecimento de padrões. Dentre as técnicas de aprendizado de máquina, os algoritmos de *Deep Learning* (Aprendizagem Profunda) demonstram grandes avanços na extração automatizada de representações com vários níveis de abstração a partir de dados complexos e são, portanto, aplicáveis a diferentes domínios da ciência. Tais algoritmos são capazes de detectar correlações existentes entre variáveis que não estão aparentemente visíveis, possibilitando indicar um padrão não observado quando as variáveis são analisadas isoladamente [LECUN *et al.* 2015].



.....3 Visão geral

O produto final do projeto preditivo de demissão é um índice de probabilidade de cada colaborador ser demitido em um curto intervalo de tempo.

O sistema funcionará com o *input* de dados das variáveis preditivas via API; em seguida, o algoritmo ou, melhor dizendo, o conjunto de algoritmos treinado para prever a probabilidade do indivíduo ser demitido realiza o cálculo, e finalmente retorna com o índice de probabilidade de demissão daquele indivíduo.

3.1 Casos de uso

3.1.1 Insumo para análise de crédito

O usuário: um banco, financeira ou mesmo varejista envia os dados necessários via API para serem calculados pelo algoritmo, e o sistema retorna o índice para o usuário. A partir do retorno, o usuário utiliza essa nova variável para avaliar o crédito para seu cliente final.

3.1.2 Seleção de colaboradores

O usuário: departamento de seleção de uma empresa envia os dados necessários do candidato via API para serem calculados pelo algoritmo, e o sistema retorna o índice para o usuário. A partir do retorno, o usuário utiliza essa nova variável para tomar decisão de contratar ou não o candidato.

3.1.2 Avaliação de colaboradores

O usuário: departamento de RH de uma empresa envia os dados necessários do colaborador via API para serem calculados pelo algoritmo, e o sistema retorna o índice para o usuário. A partir do retorno, o usuário utiliza essa nova variável para avaliar o candidato.

.....4 Escopo do protótipo

1. Dados e pré-processamento
 - a) extração dos dados;
 - b) seleção dos atributos;
 - c) análise dos dados.
2. Algoritmos de *Machine Learning*
 - a) levantamento dos principais algoritmos de aprendizado supervisionado;
 - b) avaliação dos algoritmos;
 - c) construção dos modelos de aprendizado de máquina.

3. Análises e resultados
 - a) detalhar *performance*;
 - b) disponibilização de API para uso comercial.

.....5 Características inovadoras

Os modelos de análise de crédito tradicionais avaliam a probabilidade do cliente pagar ou não o empréstimo usando, para isso, dados financeiros disponíveis no mercado, como SCR, receita federal, *bureaus* de crédito... e dados do próprio banco de dados, como os cadastrais. O foco é avaliar o crédito para o maior número de pessoas utilizando o modelo mais moderno, ou melhor dizendo, mais condizente com o momento atual.

O que propomos é ampliar o modelo tradicional, ou seja, não somente utilizar as variáveis já contempladas nos modelos tradicionais, mas também incluir variáveis comportamentais e de *performance*, cujos dados podem ser obtidos no modelo de crédito consignado em folha de pagamento por meio da empresa empregadora.

Prever a demissão do funcionário mitiga o maior risco de *default* para instituições de crédito, melhorando, assim, a taxa ofertada, e permitindo às empresas selecionar melhor seus colaboradores e tentar recuperar os colaboradores que estão com alto índice de probabilidade de demissão.

.....6 Contribuição para o SFN

Ao mensurar a expectativa do colaborador ser desligado da empresa onde trabalha, é possível ofertar crédito com taxas de juros menores, uma vez que o risco de demissão torna-se conhecido e sua probabilidade quantificável, atendendo ao pilar Crédito mais barato, da Agenda BC+.

.....7 Restrições

Empresas com falta de dados íntegros e confiáveis podem levar a uma restrição para a adoção deste algoritmo, visto que a eficácia do produto depende da qualidade dos insumos.

Outro fator de restrição é a implantação da nova Lei Geral de Proteção de Dados (LGPD), que pode limitar o acesso das empresas às informações necessárias ao pleno funcionamento do algoritmo.

.....8 Conclusão

A assimetria de dados sobre os colaboradores das empresas privadas, em especial a probabilidade do indivíduo permanecer ou não na empresa, gera incerteza para instituições financeiras interessadas em ofertar crédito. Essa incerteza termina refletida na taxa de juros oferecida na modalidade de crédito consignado privado, elevando-a.

Nosso projeto, propôs, através de um conjunto de algoritmos e variáveis cadastrais, financeiras, comportamentais e de *performance*, prever a probabilidade de demissão dos funcionários e, assim, tornar mais precisa a análise de crédito e, por conseguinte, diminuir o risco de *default* e a taxa de juros ofertada.

O que concluímos após extrair os dados e processá-los é que é possível averiguar, com boa acurácia, se o indivíduo vai permanecer ou não na empresa e, portanto, utilizar essa informação no modelo ou mesmo na política de crédito da carteira.

Também identificamos oportunidades para melhorar a acurácia do conjunto de algoritmos, como melhoria no formato e repositório dos dados e novas variáveis.



Referências

G1 Economia. 2016. 1 em cada 4 casos de inadimplência vem do descontrole financeiro. Disponível em: <http://g1.globo.com/economia/noticia/2016/10/1-em-cada-4-casos-de-inadimplencia-vem-do-descontrole-financeiro.html>. Acesso em: 9 de agosto de 2019.

LECUN, Y., BENGIO, Y., AND HINTON, G. 2015. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444.

SERASA EXPERIAN. 2019. Número de brasileiros com dívidas atrasadas aumenta em 2 milhões e bate novo recorde. Disponível em: <https://www.serasaexperian.com.br/sala-de-imprensa/numero-de-brasileiros-com-dividas-atrasadas-aumenta-em-2-milhoes-e-bate-novo-recorde-revela-serasa-experian>. Acesso em: 9 de Agosto de 2019.

