

**Universidade Estadual de Campinas Instituto de Matemática,  
Estatística e Computação Científica**

**Modelos Matemáticos para previsão de inadimplência de Crédito**

**João Vitor Pires Camargo**

**Orientador: Prof Dr Laercio Luis Vendite**

## RESUMO

Atualmente todas as instituições brasileiras que trabalham com concessão de crédito utilizam-se de modelos matemáticos para avaliar o risco de inadimplência dos potenciais contratantes de produtos de créditos. Cada vez mais as instituições buscam aprimorar técnicas que resultem no aumento na precisão desses modelos, acarretando ganhos financeiros para a mesma.

Neste trabalho, primeiramente, são apresentados cenários de risco de crédito na conjuntura atual, posteriormente, a partir de uma amostra de dados de uma instituição financeira, foram aplicados três modelos para classificação de clientes como sendo inadimplentes (ou não): Regressão Logística, Redes Neurais e Árvores de Decisão. E finalmente são avaliadas e comparadas a qualidade e performance dos modelos desenvolvidos, onde é apontado qual modelo melhor se ajusta aos dados.

Os resultados obtidos pelos três modelos são satisfatórios, porém será mostrado que o modelo de regressão, apesar de possuir uma boa performance, apresenta uma variância maior de seus resultados, diferentemente das redes neurais e algoritmos genéticos.

A ideia principal desse trabalho é ilustrar os procedimentos que podem ser adotados por uma empresa para identificar o melhor modelo de concessão de crédito que se encaixe a sua base de dados. A adoção do melhor modelo permite um direcionamento estratégico por parte da empresa, que pode consequentemente aumentar a eficiência do seu negócio.

## 1.1 CENÁRIO

Após o fim do período inflacionário, percebeu-se a necessidade de se aumentarem as alternativas de investimento para substituir a rentabilidade do período de inflação. Desde de então as instituições tem se preocupado em aumentar suas carteiras de crédito. Entretanto, o empréstimo não poderia ser oferecido indiscriminadamente a todos os clientes que o solicitarem, sendo necessárias formas de avaliar o candidato ao crédito.

Há alguns anos ao fazer a solicitação crédito, o cliente preenchia uma proposta que seria avaliada por um ou mais analistas que apresentavam um parecer em relação ao pedido. Apesar de eficaz, era um processo lento, por não permitir a análise de muitos pedidos. Tendo isso em mente as instituições começaram a adotar modelos de análise de concessão de crédito com o objetivo de acelerar a avaliação das propostas.

Os modelos de análise de credito, conhecidos como modelos de credit scoring, baseiam-se em dados historicos da base de clientes existentes para avaliar se um futuro cliente terá mais chances de ser inadimplente ou não. Os modelos de credit scoring são implantados nos sistemas das instituições, com o forte crescimento da computação e meios de utilizar novas tecnologias afim de otimizar processos.

Os modelos de credit scoring são especificos para a aprovação em cada produto de crédito, sendo esses: crédito pessoal, cheque especial, emprestimos para financiamentos entre outros. Para esse trabalho, o produto em questão será o credito pessoal.

## **1.2 OBJETIVOS DO ESTUDO**

### **1.2.1 Objetivos Gerais**

Com base nos dados provenientes de uma amostra, pretende-se:

► Desenvolver três modelos de credit scoring, mediante o uso de três técnicas estatísticas/computacionais.

1. Regressão Logística;

2. Redes Neurais;

3. Árvores de Decisão;

► Comparar os modelos desenvolvidos em termos de indicadores de qualidade de ajuste e previsão;

► Propor um modelo para a classificação de clientes;

### **1.2.2 Objetivos Específicos**

Para o alcance dos objetivos gerais, são definidos especificamente os seguintes objetivos.

► Selecionar as variáveis a serem utilizadas em cada um dos três modelos;

► Definir critérios para comparação da eficiência dos modelos;

► Comparar os resultados obtidos pelos três modelos

## **1.3 JUSTIFICATIVA DO TRABALHO**

Modelos que avaliam o crédito são de vital importância para o negócio de uma instituição financeira. Um cliente mal classificado pode causar prejuízos (no caso de classificar um cliente mau como bom) ou então privar a instituição de ganhos (classificar um cliente bom como mau).

Nenhum modelo consegue precisão absoluta, ou seja, acertar totalmente suas previsões. Então qualquer avanço em termos de acuracidade da previsão gera ganhos para a instituição. Dai o interesse em analisar diferentes tipos de modelos e apontar quais apresentam uma maior precisão.

## 2.1 DESCRIÇÃO DO ESTUDO

Uma instituição financeira deseja conceder empréstimo a seus clientes e, para isso, necessita uma ferramenta que avalie o grau de risco associado a cada empréstimo para auxiliar o processo de tomada de decisão. A instituição gostaria que todos os clientes fossem classificados como bons ou maus pagadores, para poder estimar a distribuição de perdas de sua carteira de crédito, e direcionar o gerenciamento das operações de acordo com o risco de inadimplência dos contratantes. Para esse projeto foi utilizado um banco de dados com informações do histórico de clientes que contrataram serviços de créditos.

## 2.2 AS VARIÁVEIS

**Tabela 1: Variáveis e descrição**

<b>Variável</b>	<b>Descrição</b>
RevolvingUtilizationOfUnsecuredLines	Saldo total em cartões de crédito e linhas pessoais de crédito, exceto imóveis, e nenhuma dívida parcelada, como empréstimos para carros divididos pela soma dos limites de crédito.
Age	Idade do contratante em anos
NumberOfTime30-59DaysPastDueNotWorse	Número de vezes que o tomador do empréstimo está com 30-59 dias de atraso, mas não pior nos últimos 2 anos.

DebtRatio	Pagamentos mensais da dívida, pensão alimentícia, custo de vida dividido pela renda bruta mensal
MonthlyIncome	Renda mensal
NumberOfOpenCreditLinesAndLoans	Número de empréstimos em aberto (parcelamento como empréstimo de carro ou hipoteca) e linhas de crédito (por exemplo, cartões de crédito)
NumberOfTimes90DaysLate	Número de vezes que o mutuário foi vencido há 90 dias ou mais.
NumberRealEstateLoansOrLines	Número de empréstimos hipotecários e imobiliários, incluindo linhas de crédito de home equity
NumberOfTime60-89DaysPastDueNotWorse Numberofdepends	Número de vezes que o tomador sofreu 60-89 dias de atraso, mas não piorou nos últimos 2 anos.
Numberofdepends	Número de dependentes na família excluindo-se (cônjuge, filhos etc.)
<b>SeriousDlqin2yrs</b>	<b>Pessoa experimentou 90 dias de inadimplência ou pior</b>

## 2.3 DEFINIÇÃO DA VARIÁVEL RESPOSTA

Para o desenvolvimento de um modelo de credit scoring é preciso definir, num primeiro momento, o que a instituição financeira considera como inadimplente ou não. Esta definição, da variável resposta, esta diretamente ligada à política de credito da instituição. Para o produto em estudo, clientes que experimentou 90 dias de inadimplencia ou pior (por motivos pessoais não quitaram suas dividas em 90 ou mais dias) sera considerado como inadimplente, já clientes com até 89 dias ainda serem considerados como bons pagadores (apesar desses casos precisarem de uma analise mais cuidadosa mas não sera abordada nesse estudo)

### 3.1 REGRESSÃO LOGÍSTICA

Regressão Logística é a técnica mais utilizada no mercado para o desenvolvimento de modelos de credit scoring. Apresenta vantagem à Análise Discriminante, pois não pressupõe que os dados de entrada tenham distribuição Normal, embora seja desejável que as variáveis tenham essa distribuição. A regressão logística prediz a probabilidade de um evento ocorrer, a qual pode estar entre 0 e 1. A relação entre as variáveis independentes e a variável dependente se assemelha a uma curva em forma de S conforme ilustra a figura 1, a seguir:




figura 1: relação das variáveis independentes com a variável resposta

#### 4.1.1 Conceitos

Em modelos de regressão logística, a variável dependente é geralmente uma variável binária (nominal ou ordinal) e as variáveis independentes podem ser categóricas (desde dicotomizadas após a transformação) ou contínuas.

A variável dependente binária Y pode assumir os valores

1, se o cliente estiver em default

$Y =$

0, se não.

Seja  $X = (1, X_1, X_2, \dots, X_n)$  vetor onde o primeiro elemento é 1 (constante) e os outros representam as  $n$  variáveis independentes do modelo.

A função que caracteriza este modelo é dada por:

$$\ln \left( \frac{p(X)}{1-p(X)} \right) = \beta X = z, \text{ onde}$$

$\beta = (\beta_0, \beta_1, \dots, \beta_n)$  é o vetor dos parâmetros associados às variáveis.

$p(X) = E(Y = 1 | X)$ : probabilidade de o cliente ser classificado como padrão, dado o vetor  $X$ . Essa probabilidade é expressa por:

$$p(X) = E(Y) = \frac{e^{\beta X}}{1 + e^{\beta X}}$$

#### **4.1.3 Pontos Fortes e Fracos da Aplicação de Regressão Logística**

Fensterstock (2005, p, 48) aponta as seguintes vantagens na utilização de técnicas estatísticas na construção de modelos:

- ▶ O modelo gerado leva em consideração a correlação entre as variáveis, identificando relações que não seriam visíveis e eliminando variáveis redundantes;
- ▶ Consideram as variáveis individual e simultaneamente;



- ▶ O usuário pode verificar as fontes de erro e otimizar o modelo;

No mesmo texto, o autor também identifica desvantagens deste tipo de técnica:

- ▶ Em muitos casos a preparação das variáveis demanda muito tempo;
- ▶ No caso de muitas variáveis o analista deve fazer uma pré-seleção das mais importantes, baseando-se análises separadas;
- ▶ Alguns modelos resultantes são de difícil implementação.

## **4.2 REDES NEURAS ARTIFICIAIS**

Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento por intermédio de experiências.

Segundo Haykin (1999, p, 28):

Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela se assemelha ao cérebro em dois aspectos: 1) O conhecimento é adquirido pela rede por meio de um processo de aprendizagem; 2) Forças de conexão entre neuronios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

### **4.2.1 Histórico**

Segundo vários autores, entre eles, Haykin (1999, p. 63) e Fausett (1994, p. 22), o primeiro modelo de rede neural surgiu com o trabalho de McCulloch e Pitts. Warren McCulloch foi um psiquiatra e neuroanatomista que estudava uma representação para o sistema nervoso. Em 1942, ele se associou com o matemático Walter Pitts e no ano seguinte eles publicaram um artigo que propunha um modelo matemático para uma rede neural, artigo este que até hoje é uma referência no estudo de redes neurais. Um segundo estudo trabalho importante foi publicado por Hebb em 1949, no qual foram propostas as primeiras regras de aprendizado para redes neurais artificiais; este trabalho inspirou muitos estudiosos em pesquisas posteriores

Durante as décadas de 50 e 60 houve muitas pesquisas e estudos que permitiram avançar muito no campo das redes neurais. Estudos mostraram que a nova metodologia seria muito promissora; foram propostos novos tipos de rede, novas regras de aprendizado e as redes foram ficando mais complexas.

Foi somente nos anos 80 que, com o maior poder computacional, as redes neurais começaram a ser largamente estudadas e aplicadas. Fausett (1994, p. 25) destaca o desenvolvimento do algoritmo backpropagation (retroprogramação) como divisor de águas para a popularidade das redes neurais. Até os dias atuais as redes neurais vem sendo largamente empregadas e estudadas, sendo utilizadas em diferentes áreas de conhecimento como medicina, biologia, economia, administração e engenharia.


### 4.2.2 Conceitos

Um modelo de rede neural artificial processa certas características e produz respostas similarmente ao cérebro humano. Redes neurais artificiais são desenvolvidas por meio de modelos matemáticos, onde as seguintes suposições são feitas:

1. O processamento das informações ocorre dentro dos chamados neurônios;
2. Os estímulos são transmitidos pelos neurônios por meio de conexões;
3. Cada conexão tem associada a si um peso, que, numa rede neural padrão, multiplica-se ao estímulo recebido;
4. Cada neurônio contribui para a função de ativação (geralmente não linear) para determinar o estímulo de saída (resposta da rede).

O modelo para uma unidade de processamento (neurônio), pode ser resumido em:

- ▶ Sinais são apresentados à entrada;
- ▶ Cada sinal é multiplicado por um peso que indica sua influência na saída da unidade;
- ▶ É feita a soma ponderada dos sinais que produz um nível de atividade;
- ▶ Se este nível excede um limite, a unidade produz uma saída.



*Ilustração 1: Camadas de uma*

*rede neural*

Usualmente as camadas são divididas em tres grupos:

- ▶ Camada de Entrada: onde os padrões são apresentados à rede;
- ▶ Camadas Intermediárias ou Escondidas: onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- ▶ Camada de Saída: onde o resultado final é concluído e apresentado.

Uma rede neural é especificada, principalmente pela sua topologia, pelas características dos nós e pelas regras de treinamento. A seguir, serão analisados os processos de aprendizado.

### 4.2.2.1 Processos de Aprendizado

A propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

Existem basicamente tres tipos de aprendizado:

1. Aprendizado Supervisionado: Neste tipo de aprendizado, é indicada a uma rede qual a resposta esperada. Trata-se do exemplo deste trabalho onde a priori se sabe se o cliente é bom ou mau;
2. Aprendizado Não Supervisionado: Neste tipo de aprendizado, a rede deve basear-se apenas nos estímulos recebidos; a rede deve aprender a agrupar os estímulos;
3. Aprendizado por Reforço: Neste tipo de aprendizado, o comportamento da rede é avaliado por um crítico externo.

### 4.2.2.2 Funções de Ativação

Como já mencionado, cada neurônio contribui para o estímulo de saída. A função de ativação desempenha o papel de restringir a amplitude de saída de um neurônio, em geral  $[0,1]$  ou  $[-1,1]$ . Alguns exemplos de funções de ativação utilizadas são:

$$1, \text{ se } x < k$$

► Função Limiar:  $f(x) =$

$$0, \text{ se } x > k$$

▶ Função Logística:  $f(x) = 1 / (1 + \exp(-\mu x))$

▶ Função Tangente Hiperbólica:  $f(x) = \tanh(x)$

### **4.2.3 Pontos Fortes e Fracos**

▶ São versáteis: redes neurais podem ser usadas para a solução de diferentes tipos de problemas como previsão, agrupamento ou identificação de padrões;

▶ São capazes de identificar relações não lineares entre as variáveis;

▶ São largamente utilizadas, estando disponíveis em vários softwares.

No tocante as desvantagens:

▶ Os resultados não são explicáveis: não são produzidas regras explícitas, a análise é feita dentro da rede e só o resultado é fornecido pela “caixa preta”:

▶ A rede pode convergir para uma solução inferior: não há garantias de que a rede encontre a melhor solução possível: ela pode convergir para um máximo local.

## **4.3 ARVORE DE DECISÃO**

Uma árvore de decisão é uma representação de uma tabela de decisão sob a forma de uma árvore, porém pode haver outras aplicações. Tem a mesma utilidade da tabela de decisão. Trata-se de uma maneira alternativa de expressar as mesmas regras que são obtidas quando se constrói a tabela.

É uma abordagem comportamental que usa diagramas para mapear as várias alternativas e resultados de decisões de investimento, assim como as probabilidades de ocorrerem. Baseia-se em estimativas e probabilidades associadas aos resultados de cursos de ação que competem entre si. O resultado de cada curso de ação é ponderado pela probabilidade associada a ele; o resultado ponderado é somado e o valor esperado de cada curso de ação é, então determinado. A alternativa que proporciona o valor esperado mais alto é preferível. Essencialmente, árvores de decisões são diagramas que permitem representar e avaliar problemas que envolvem decisões sequenciais, colocando em destaque os riscos e os resultados financeiros identificados nos diversos cursos de ação. Para efectuar a representação gráfica da árvore de decisão são geralmente usadas linhas para identificar a decisão (por exemplo “sim” ou “não”) e nós para identificar as questões sobre as quais se deve decidir. Cada um dos ramos formado por linhas e nós termina numa espécie de folha que identifica a consequência mais provável da sequência de decisões tomadas.

### **4.3.1 Árvores de decisão e a tarefa de classificação**

O aprendizado indutivo de árvores de decisão é geralmente dividido em aprendizado supervisionado e não-supervisionado, embora o aprendizado semi-supervisionado também tem sido considerado ao longo dos últimos anos.

Na construção da árvore de decisão, procura-se associar a cada nó de decisão o atributo “mais informativo” entre aqueles ainda não utilizados no caminho desde a raiz da árvore.

No entanto, cada algoritmo tem a sua própria metodologia para distinguir o atributo mais informativo, fazendo com que a topologia da árvore e a qualidade da árvore variem em função do algoritmo utilizado

### **4.3.2 Principais conceitos vinculados à indução de árvores de decisão**

Uma vez construída uma árvore de decisão, seu uso é imediato e muito rápido computacionalmente. Além disso, a interpretabilidade da árvore de decisão é um de seus pontos fortes.

No entanto, a construção de uma árvore de decisão, chamado de processo de indução, pode ser uma tarefa de alta demanda computacional.

Embora a indução de uma árvore de decisão possa ser realizada de forma manual, numa abordagem top-down, as principais demandas por árvores de decisão geralmente recorrem a processos automáticos de indução, numa abordagem bottom-up, a partir de dados disponíveis.

Todo processo de indução possui um bias indutivo, associado à preferência de uma hipótese sobre outras, supondo a existência de hipóteses que são igualmente consistentes.

Há muitas maneiras de uma árvore de decisão ser estruturada a partir de um conjunto de atributos. De forma exaustiva, o número de árvores de decisão possíveis cresce fatorialmente à medida que o número de atributos aumenta.

Logo, torna-se impraticável definir a estrutura da árvore de decisão ótima para um determinado problema, devido ao elevado custo computacional envolvido nessa busca.

Nesse sentido, algoritmos baseados em heurísticas têm sido desenvolvidos para a indução de árvores de decisão. Mesmo que eles não garantam uma solução ótima, apresentam resultados satisfatórios em tempo factível.

### 4.3.3 Vantagens e desvantagens

Árvores de decisão continuam sendo usadas por motivos como estes:

- ▶ Facilidade de compreensão
- ▶ Podem ser úteis com ou sem dados concretos, e quaisquer dados requerem o mínimo de preparação
- ▶ Novas opções podem ser adicionadas às árvores existentes
- ▶ Seu valor em escolher o melhor dentre várias opções

▶ Como facilmente podem ser usadas com outras ferramentas de tomada de decisão

Mas também tem algumas desvantagens:

▶ Ao lidar com dados categóricos com vários níveis, o ganho de informação é tendencioso em favor dos atributos com mais níveis.

▶ Cálculos podem tornar-se complexos quando se lida com a incerteza e com muito resultados vinculados.

▶ Conjunções entre nós estão limitadas a “E”, enquanto gráficos de decisão permitem nós ligados por “OU”.

## 5.1 RESULTADOS

Os algoritmos foram desenvolvidos em linguagem python que possui uma fantástica biblioteca para análise de dados (pandas) e computação científica (numpy) e bibliotecas com sklearn que possui os modelos de descritos nesse trabalho já definidos.

### 5.1.1 Regressão Logística

Utilizando o modelo de regressão logística , encontramos os seguintes coeficientes para  $\beta$ :

Variavel	coeficiente
RevolvingUtilizationOfUnsecuredLines	1.32709511e+00
Age	-6.85717035e-02
NumberOfTime30-59DaysPastDueNotWorse	5.77879303e-01
DebtRatio	4.04285180e-03
MonthlyIncome	4.39034751e-05



NumberOfOpenCreditLinesAndLoans	1.17107255e-01
NumberOfTimes90DaysLate	5.44134570e-02
NumberRealEstateLoansOrLines	-2.58354379e-01
NumberOfTime60-89DaysPastDueNotWorse	1.85538343e-01
Numberofdepends	-3.45437168e-01

### 5.1.1.1 Matriz de confusão

Uma matriz de confusão, também conhecida como Tabela de Confusão, é uma matriz de dimensão 2 x 2, podendo ser maior dependendo da quantidade de classes que se deseja prever. É uma métrica voltada para modelos de classificação e tem como objetivo calcular a quantidade de falso positivo e falso negativo; e de verdadeiro positivo e verdadeiro negativo, além de te fornecer a acurácia e sensibilidade.

► Verdadeiro Positivo ( true positive – TP): Ocorre quando no conjunto real, a classe que estamos buscando foi prevista corretamente.

► Falso Positivo (False positive – FP): Ocorre quando no conjunto real, a classe que estamos buscando prever foi prevista incorretamente.

► Verdadeiro Negativo (true negative- TN): Ocorre quando no conjunto real, a classe que não estamos buscando prever foi prevista corretamente.

► Falso Negativo ( False negative- FN): Ocorre quando no conjunto real, a classe real , a classe que não estamos procurando prever foi prevista incorretamente.

**Acuracia:** Diz quanto o modelo acertou das previsoes possíveis. E a razão entre o somatorio das previsões corretas (verdadeiros positivos com verdadeiros negativos) sobre o somatorio das previsões.

$$accuracy = \frac{TP + TN}{TP + FP + TN + FN} = \frac{\text{predições corretas}}{\text{todas as predições}}$$

**Recall:** Podemos ver que *recall* responde a seguinte pergunta: qual proporção de positivos foi identificados corretamente? Em outras palavras, quão bom meu modelo é para prever positivos, sendo positivo entendido como a classe que se quer prever.

$$recall = \frac{TP}{TP + FN}$$

**Precisão:** Definimos precisão como a resposta para a seguinte pergunta: Qual a proporção de identificações positivas foi realmente correta? Em outras palavras, o qual bem meu modelo trabalhou.

$$precision = \frac{TP}{TP + FP}$$

**F-score :** Já o *f-score* nos mostra o balanço entre a precisão e o *recall* de nosso modelo. Sua fórmula é:

$$2 * \frac{precision * recall}{precision + recall}$$

Para o modelo de regressão obtivemos os seguintes resultados:

	precision	recall	f1-score	support
0	0.87	0.92	0.90	669
1	0.35	0.24	0.28	119

Accuracy: 0.8197969543147208

Podemos notar que o modelo tem mais precisão em prever clientes bom do que maus clientes.

### 5.1.2 Redes Neurais

Para o modelo de redes neurais usando os mesmo parametros obtivemos os seguintes resultados:

	precision	recall	f1-score	support
0	0.84	1.00	0.92	665
1	0.00	0.00	0.00	123

Accuracy: 0.8439086294416244

Aki podemos observar um fenômeno que pode ocorrer em redes neurais chamado Superajuste ou overfitting, é quando o modelo fica “superajustado” aos dados de desenvolvimento, entretanto o modelo não sera bom para previsao de novos dados. Esse fenômeno apresenta alta precisão quando feitos ao seu conjunto de dados porem esse modelo não é uma boa representação da realidade então debes ser evitado. Esse problema pode ser contornado através da validação cruzada em que testamos o nosso modelo em relação a uma parte reservada do conjunto de dados que não foi utilizada no treino do modelo em questão, é possível se ter uma ideia de se o modelo sofre de sobre-ajuste ou não.

### 5.1.3 Arvore de Decisão

Agora testamos para Arvores de decisão:

	precision	recall	f1-score	support
0	0.87	0.91	0.89	665
1	0.35	0.28	0.31	123

Accuracy: 0.8071065989847716

## 5.2 Conclusões

Comparando os tres modelos podemos dizer que o melhor que representa uma predição melhor dos dados seria o de regressão logistica apresentando uma precisão aproximada de 82%, apesar do modelo de redes neurais ter tido uma maior precisão ele acabou se superajustando para os clientes bons, ou seja , não tinha uma boa predição quanto os clientes ruins.

## 6. REFERENCIAS

HAYKIN, S (1999) *Redes Neurais e Pratica*, Porto Alegre: Bookman.

FIGUEIREDO, R. P. (2001) *Gestão de Risco Operacionais em Instituições Financeiras*.

CARVALHO, A. P. L. F. *Redes Neurais Artificiais*  
[www.icmc.usp.br/~andre/research/neural/](http://www.icmc.usp.br/~andre/research/neural/)

<https://medium.com/data-hackers/entendendo-o-que-%C3%A9-matriz-de-confus%C3%A3o-com-python-114e683ec509>

ROSA, P.T.M (2000) *Modelos de credit scoring: Regressão Logistica*.