



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
INSTITUTO DE MATEMÁTICA E ESTATÍSTICA

DEPARTAMENTO DE ESTATÍSTICA

**AVALIAÇÃO DE UMA METODOLOGIA DE SELEÇÃO DE VARIÁVEIS  
MULTICRITERIAL NO AMBIENTE DE CREDIT SCORING**

**ALESSANDRO KAHMANN**

Porto Alegre  
2018

**ALESSANDRO KAHMANN**

**AVALIAÇÃO DE UMA METODOLOGIA DE SELEÇÃO DE VARIÁVEIS  
MULTICRITERIAL NO AMBIENTE DE CREDIT SCORING**

Monografia submetida como requisito parcial  
para a obtenção do grau de Bacharel em  
Estatística

Orientador Metodológico  
Professora Dra. Liane Werner

Porto Alegre  
2018

Instituto de Matemática e Estatística  
Departamento de Estatística

**Avaliação de Uma Metodologia de Seleção de Variáveis Multicriterial no Ambiente de Credit Scoring**

Alessandro Kahmann

Banca examinadora:

Professora Dra. Liane Werner  
UFRGS

Bacharel em Estatística Jaimar de Barros Monteiro  
DETRAN-RS

## RESUMO

Após a crise financeira mundial de 2008, a análise de risco de crédito ganhou maior importância quando comparado a momentos anteriores. A predição do risco da concessão de crédito, chamado *credit scoring*, pode ser realizada através de métodos estatísticos multivariados específicos para tal situação. Dentro deste cenário, este trabalho tem como objetivo avaliar o método proposto em Kahmann et al. (2017) em um problema de *credit scoring*, de forma a identificar os atributos que melhor discriminam bons e maus clientes. Testando suas premissas em dois bancos de dados públicos de *credit scoring*, o subconjunto de variáveis selecionadas conduziu a melhores classificações quando comparado ao banco de dados completo. Complementarmente, quando comparados a outros estudos da área obteve piores classificações quando utilizado o banco de dados com desbalanço entre as observações das duas classes e a melhores classificações quando o banco de dados contém quantidades semelhantes de observações em cada classe. Tais resultados indicam que, sob as devidas condições, o método possui aplicabilidade em problemas de *credit scoring*.

**Palavras-chave:** *Credit Scoring*, Seleção de Variáveis, Métodos quantitativos.

## **ABSTRACT**

After the world financial crisis in 2008, the credit scoring gained more importance when compared to previous moments. The credit concession risk prediction can be made by suited multivariate statistical methods, specific to such situation. In such scenario, this paper aims to evaluate the method proposed in Kahmann et al. (2017) in a credit scoring problem, in order to identify the features that better discriminate good and bad clients. Testing its premises in two public credit scoring datasets, the selected subset of variables provided better classification when compared to the full dataset. Complementarily, when compared to other studies in the field the method provides worst results when the dataset presents unbalance between the number of observations in each class and better results when the data set has similar number of observations in each class. Such results indicates that under the right circumstances the method can be used in credit scoring problems.

**Keywords:** Credit Scoring, Variable Selection, Quantitative Methods.

## SUMÁRIO

1	INTRODUÇÃO.....	7
2	REFERENCIAL TEÓRICO.....	8
2.1	Seleção de variáveis.....	8
2.2	Ferramentas Quantitativas .....	12
2.2.1	Informação Mútua.....	12
2.2.2	Programação Quadrática .....	12
2.2.3	Máquina de Suporte Vetorial .....	13
2.2.4	Matriz de Confusão.....	14
3	MÉTODO.....	14
4	RESULTADOS .....	17
4.1	<i>German Credit Data</i> .....	18
4.2	<i>Australian Credit Approval</i> .....	20
4.3	Comparação dos resultados encontrados com a literatura.....	22
5	CONCLUSÃO.....	24
	REFERÊNCIAS .....	24
	APÊNCLIDE A – Resultados do <i>German Credit Data</i> .....	29
	APÊNCLIDE B – Resultados do Australian Credit Approval .....	41

# 1 Introdução

A crise do *subprime* em 2007 causou um efeito cascata ao longo da economia mundial, sendo o gatilho para a crise financeira mundial de 2008 (LONGSTAFF, 2010). Tal crise é considerada a pior crise financeira desde a Grande Depressão na década de 30 (ALMUNIA et al., 2012). Dentro deste contexto, a análise de risco de crédito ganhou importância quando comparado a momentos anteriores. Adicionalmente, desde a assinatura do acordo de Basel em 2004 as empresas supervisionadas são solicitadas a utilizar avaliações internas de risco de concessão de crédito (ABELLÁN; CASTELLANO, 2017).

A predição do risco da concessão de crédito pode ser executada através de procedimentos de *credit scoring*. O *credit scoring* pode ser definido como métodos estatísticos formais usados para classificar aspirantes a crédito nas classes de risco “bom”, quando o solicitante paga o empréstimo, e “ruim”, quando o solicitante não paga o crédito. Tais sistemas são de grande interesse de instituições financeiras não apenas pela mensuração do risco do crédito, mas por que as menores melhorias nas metodologias de concessão podem produzir grandes lucros, como a redução do custo de análise, retornos mais rápidos e mitigação dos riscos (HAND; HENLEY, 1997).

Houve uma grande evolução nas tecnologias para análise e monitoramento de informações de forma a gerar crescentes volumes de dados, oferecendo oportunidades para a identificação de padrões que prevejam o comportamento de pessoas. Porém, tais bancos são tipicamente compostos uma grande quantidade de dados, o que inviabiliza uma análise minuciosa das mesmas. Além disso, as tradicionais ferramentas de análise multivariadas perdem eficiência em bancos de dados de alta dimensionalidade e compostos por variáveis ruidosas (LIU; YU, 2005).

A seleção de variáveis é uma subárea da mineração de dados e tem como objetivo identificar as variáveis mais importantes do banco de dados, removendo as variáveis irrelevantes ou que prejudiquem a identificação de padrões. Dentre os benefícios desta redução destacam-se a geração de modelos mais parcimoniosos, melhor interpretação dos resultados, maior rapidez computacional na análise multivariada e aumento de precisão de técnicas de predição e classificação (GUYON; ELISSEEFF, 2003; HASTIE et al., 2009; SAEYS et al., 2007).

Este trabalho tem como objetivo avaliar uma metodologia multicriterial baseada nos conceitos de Kahmann et al. (2017) e adequada para o cenário do *credit scoring*, uma vez que tais situações utilizam variáveis contínuas e categóricas e são caracterizadas por desbalanço entre o número de observações das classes, diferentemente dos dados utilizados em Kahmann et al. (2017). Tal metodologia utiliza um problema de otimização quadrática para criar um cenário de mínima redundância entre as variáveis preditivas e máxima similaridade de tais variáveis com a variável resposta. O resultado desta otimização originará um índice de importância para as variáveis, quantificando o potencial preditivo de cada variável. Utilizando este índice as variáveis serão inseridas através de um procedimento *forward* em modelos de categorização gerados através da Máquina de Suporte Vetorial. O subconjunto com as varáveis originais que conduzir à melhor taxa de sensibilidade (bons pagadores classificados corretamente) e especificidade (maus pagadores classificados corretamente) é selecionado.

## 2 Referencial Teórico

Neste capítulo serão apresentados os conceitos que envolvem as metodologias de seleção de variáveis, assim como as ferramentas de análise quantitativa utilizadas neste trabalho.

### 2.1 Seleção de variáveis

Segundo Liu e Yu (2005), métodos de seleção de variáveis se baseiam em quatro passos básicos: geração de subconjuntos, avaliação dos subconjuntos, critério de parada e validação do resultado. A Figura 1 apresenta o fluxograma genérico de uma rotina de seleção de variáveis.

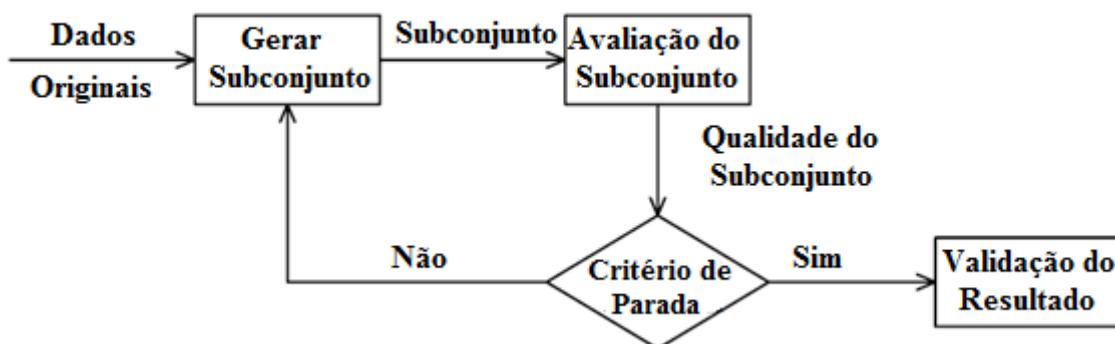


Figura 1 - Fluxograma para métodos de seleção de variáveis.

Fonte: Liu e Yu (2005)

Através de um processo de busca, a geração de subconjuntos se apoia em uma heurística, onde um novo subconjunto é criado a cada iteração. Tal processo de busca deve inicialmente definir um ponto de início e direção da busca, podendo iniciar com o conjunto original de variáveis e removê-las (*backward*), iniciar com um conjunto vazio e acrescentar variáveis (*forward*), ou iniciar em qualquer uma das duas opções e remover e adicionar variáveis simultaneamente (*stepwise*). Adicionalmente, o método de busca precisa ser determinado, podendo se dividir em três abordagens básicas: completo, verificando todas as combinações de subconjuntos de variáveis; sequencial, quando as variáveis são adicionadas ou removidas em grupos ou individualmente; ou ainda de forma aleatória, novamente em grupos ou individualmente. Segundo Guyon e Elisseeff (2003), muitos métodos de seleção de variáveis que utilizam abordagens sequenciais utilizam algum tipo de ordenação das variáveis, com o intuito de guiar a busca das variáveis que melhor descrevem o processo, devida sua simplicidade teórica e seus bons resultados empíricos. A utilização de algum ordenamento das variáveis é encontrada em diversos trabalhos como Hapfelmeier e Ulm (2013), Luts et al. (2010), Rakotomamonjy (2003) e Westad et al. (2003).

Os critérios para a avaliação dos subconjuntos dividem-se em dois: independentes e dependentes. Critérios dependentes baseiam-se nos resultados de técnicas estatísticas, tais como ferramentas de classificação e regressão. Dentre os critérios dependentes destacam-se erros de predição e acurácia de classificação. Critérios dependentes tipicamente levam a melhores previsões, porém, uma vez que é necessário aplicar a ferramenta em todos os subconjuntos gerados, necessitam de maior desempenho computacional. Por sua vez, critérios independentes baseiam em métricas oriundas diretamente dos dados, tais como medidas de distância, informação, dependência e consistência. (LIU; YU, 2005).

Antes de rodar alguma metodologia de seleção de variáveis é necessário definir um critério de parada, de forma a indicar o fim da busca dentre os subconjuntos. Os critérios mais utilizados são: atingir um número máximo de iterações, completar a busca, alcançar um subconjunto com resultados previamente definidos como suficientemente bons, ou ainda não apresentar melhora na avaliação do processo depois de uma quantidade de passos (DASH; LIU, 1997; LIU; YU, 2005). Em casos onde as variáveis são ordenadas por importância, Guyon e Elisseeff (2003) recomendam processos de busca da forma *forward*, de forma a possibilitar a

criação de um critério de parada que evite iterações desnecessárias, diminuindo custos computacionais.

O processo de validação não faz parte da metodologia de seleção de variáveis, mas deve ser realizada para justificar sua utilização (DASH; LIU, 1997). O conhecimento prévio do banco de dados pode ser utilizado com validação, porém tal conhecimento, na maioria das vezes, não existe. Uma alternativa é a comparação da acurácia gerada pelas variáveis selecionadas frente à acurácia obtida quando todas as variáveis são usadas ou com a acurácia obtida através da seleção utilizando outras abordagens (LIU; YU, 2005).

Não existe, atualmente, algum método de seleção de variáveis que seja considerado superior. Para identificar qual a abordagem mais adequada, Saeys et al. (2007) dividem as metodologias de seleção de variáveis em três tipos: *filter*, *wrapper* e *embedded*. A escolha da opção mais adequada varia de acordo com as características do banco de dados e objetivos da análise. Para auxiliar na escolha de qual tipo de metodologia utilizar, as vantagens e desvantagens de cada um destes três métodos são mostradas na Tabela 1.

Métodos do tipo *filter* avaliam os subconjuntos gerados através de critérios independentes, avaliando apenas propriedades intrínsecas dos dados, como por exemplo a correlação, a distância entre os centroides dos grupos de observações ou a informação mútua entre as variáveis (BLUM; LANGLEY, 1997; GUYON; ELISSEEFF, 2003; SAEYS et al. 2007).

Por sua vez, os modelos *wrapper* se assemelham aos modelos *filter*, porém ao invés de utilizar um critério independente para avaliação dos subconjuntos é utilizado um modelo de seleção baseado diretamente nos resultados da classificação. Como o número de subconjuntos possíveis aumenta exponencialmente conforme aumenta o número de variáveis, modelos *wrapper* tipicamente utilizam heurísticas para a criação de subconjuntos. Tais modelos tipicamente são mais propensos ao sobretreino, quando o modelo se adequa exageradamente aos dados históricos perdendo seu poder de generalização (GUYON; ELISSEEFF, 2003; SAEYS et al., 2007; LUTS et al., 2010).

Modelo	Vantagens	Desvantagens	Exemplos
<b>Filter</b>	<p>Univariado</p> <ul style="list-style-type: none"> <li>- Rápido</li> <li>- Escalável</li> <li>- Independente da ferramenta classificadora</li> </ul> <p>Multivariado</p> <ul style="list-style-type: none"> <li>- Modela dependência entre variáveis</li> <li>Independente da ferramenta classificadora</li> <li>- Menor complexidade computacional, comparado a modelos <i>embedded</i></li> </ul>	<ul style="list-style-type: none"> <li>- Ignora dependência entre variáveis</li> <li>- Ignora interação com ferramenta classificadora</li> </ul>	<ul style="list-style-type: none"> <li>- Qui-Quadrado</li> <li>- Distância Euclidiana</li> <li>- Teste <i>i</i></li> <li>- <i>Gain ratio</i> (Ben-Bassat, 1982)</li> </ul> <ul style="list-style-type: none"> <li>- Seleção de variáveis baseada na correlação (CFS) (Hall, 1999)</li> <li>- Filtro cobertor de Markov (MBF) (Koller e Sahamani, 1996)</li> <li>- Seleção de variáveis baseada na correlação veloz (FCBF) (Yu e Liu, 2004)</li> </ul>
<b>Wrapper</b>	<p>Determinístico</p> <ul style="list-style-type: none"> <li>- Simplicidade teórica</li> <li>- Interage com o classificador</li> <li>- Modela dependência entre variáveis</li> <li>- Menor custo computacional comparado a modelos aleatórios</li> </ul> <p>Aleatório</p> <ul style="list-style-type: none"> <li>- Menos inclinado a um ótimo local</li> <li>- Interage com o classificador</li> <li>- Modela dependência entre variáveis</li> </ul>	<ul style="list-style-type: none"> <li>- Risco de overfitting</li> <li>- Mais tendencioso a ficar preso em um ótimo local, quando comparado a modelos aleatórios</li> <li>- Seleção dependente da ferramenta classificadora</li> </ul> <ul style="list-style-type: none"> <li>- Alto custo computacional</li> <li>- Seleção dependente da ferramenta classificadora</li> <li>- Risco maior de overfitting em comparação a métodos determinísticos</li> </ul>	<ul style="list-style-type: none"> <li>- Seleção sequencial <i>forward</i> (SFS) (Kittler, 1978)</li> <li>- Eliminação sequencial <i>backward</i> (SBE) (Kittler, 1978)</li> <li>- Busca <i>Beam</i> (Siedlecky e Sklansky, 1988)</li> </ul> <ul style="list-style-type: none"> <li>- <i>Hill climbing</i> randomizado (Skalak, 1994)</li> <li>- Algoritmos genéticos (Holland, 1975)</li> <li>- Estimação de distribuição de algoritmos (Inza <i>et al.</i>, 2000)</li> </ul>
<b>Embedded</b>	<ul style="list-style-type: none"> <li>- Interage com o classificador</li> <li>- Menor custo computacional comparado a modelos <i>wrapper</i></li> <li>- Modela dependência entre variáveis</li> </ul>	<ul style="list-style-type: none"> <li>- Seleção dependente da ferramenta classificadora</li> </ul>	<ul style="list-style-type: none"> <li>- Árvores de decisão <i>Naive Bayes</i> ponderado (Duda <i>et al.</i>, 2001)</li> <li>- Seleção de variáveis utilizando o vetor peso da Máquina de Suporte Vetorial (Guyon <i>et al.</i>, 2002; Weston, 2003)</li> </ul>

Tabela 1 - Características dos modelos de seleção de variáveis

Fonte: Saeys *et al.* (2007)

O terceiro tipo de abordagem metodológica é chamado de *embedded*. Diferentemente de modelos *filter* ou *wrapper*, modelos *embedded* objetivam por imediatamente integrar a seleção de variáveis no processo de aprendizagem do algoritmo, chegando a uma solução mais rapidamente, evitando uma nova calibração do método a cada subconjunto avaliado (SAEYS *et al.*, 2007; LUTS *et al.*, 2010).

## 2.2 Ferramentas Quantitativas

Agora serão apresentados os conceitos teóricos das ferramentas quantitativas utilizadas neste trabalho: Informação Mútua, Programação Quadrática, Máquina de Suporte Vetorial e a Matriz de Confusão.

### 2.2.1 Informação Mútua

A Informação Mútua (IM) quantifica a informação compartilhada entre duas variáveis através de uma medida simétrica e não negativa. A IM entre as variáveis  $X$  e  $Y$  é definida como mostrado na equação (1)

$$IM(V_1; V_2) = \sum_{v_2 \in V_2} \sum_{v_1 \in V_1} p(v_1, v_2) \log\left(\frac{p(v_1, v_2)}{p(v_1)p(v_2)}\right) \quad (1)$$

onde  $p(v_1, v_2)$  representa a distribuição de probabilidade conjunta de  $V_1$  e  $V_2$ ,  $p(v_1)$  e  $p(v_2)$  são as distribuições de probabilidade marginais de  $V_1$  e  $V_2$ , respectivamente (LONG *et al.*, 2013; RACHOW *et al.*, 2011; RODRÍGUEZ-ROSARIO *et al.*, 2008).

A equação (1) mostra o cálculo para variáveis discretas/categóricas, porém para o cálculo da IM de variáveis quantitativas tais distribuições podem ser discretizadas através da distribuição empírica dos dados históricos (DUDA *et al.*, 2001).

### 2.2.2 Programação Quadrática

Um problema de otimização busca determinar o ponto do domínio de uma função que atinge o menor, ou maior, valor que a função pode ter. A Programação Quadrática (PQ) é um tipo de otimização aplicada a funções quadráticas multivariadas sujeitas a restrições lineares (CHEN *et al.*, 2005; GILL; WONG, 2015). A formulação genérica da PQ é descrita na equação (2)

$$\underset{\mathbf{x} \in R^n}{\text{minimize}} \quad f(\mathbf{x}) = \left\{ \frac{1}{2} \mathbf{x}^t \mathbf{H} \mathbf{x} - \mathbf{f}^t \mathbf{x} \right\} \quad (2)$$

onde  $\mathbf{x}$  é um vetor representando uma variável  $N$ -dimensional,  $\mathbf{H}$  é uma matriz  $N \times N$  real e simétrica e  $\mathbf{f}$  é um vetor  $N$ -dimensional (RODRIGUEZ-LUJAN et al., 2010).

### 2.2.3 Máquina de Suporte Vetorial

Segundo Louzada et al. (2016), a técnica que produz melhores resultados em dados de *credit scoring*, quando comparada à outras técnicas tradicionais da literatura, é a Máquina de Suporte Vetorial (MSV). A MSV é uma técnica de aprendizagem computacional utilizada originalmente para problemas de classificação em dois grupos (CORTES; VAPNIK, 1995). Tal classificação é realizada através da estimação de um hiperplano que separe os grupos, utilizando para isso dois subplanos auxiliares, um em cada lado do hiperplano. Tais subplanos são compostos pelos chamados Suportes Vetoriais (SV), de forma que a distância dos dois subplanos ao hiperplano categorizador seja máxima. Uma vez que os subplanos são determinados apenas pelos SV, a categorização através da MSV é determinada por um pequeno conjunto de observações, tornando a MSV robusta à presença de *outliers* (ZOMER et al., 2004).

Definindo os grupos de análise como +1 e -1, para classificar uma observação  $x$  do banco de teste, Akay (2009) determina que deve ser examinado o resultado da equação (3)

$$f(x) = \text{sinal} \left( \sum_{i=1}^n \alpha_i * y_i * (x_i \cdot x) + b \right) \quad (3)$$

onde  $\alpha_i$  é o Multiplicador de Lagrange,  $y_i$  é a classe ( $\pm 1$ ) do SV correspondente,  $x_i$  são os suportes vetoriais e  $b$  é o deslocamento do hiperplano, determinado ao longo do processo de geração do hiperplano. A MSV tem como premissa a utilização de variáveis contínuas para a geração do hiperplano separado, sendo necessária a criação de variáveis *dummies* no caso de variáveis categóricas.

Em casos de grupos não separáveis é possível adicionar penalizações às observações separadas incorretamente (CHEN et al., 2011; LUTS et al., 2010). Abordagens complementares podem ser empregadas para a classificação em mais de duas classes, sendo a estratégia de classificação “um contra todos” (quando a fronteira de classificação é determinada através da comparação com as demais classes simultaneamente) a mais utilizada (BURGES, 1998; LUTS et al., 2010).

Em situações onde as classes não são linearmente separáveis, transformações através de funções podem ser executadas visando aumentar o poder de separação da MSV. Estas funções

são chamadas de *kernel* e são aplicadas no cálculo do produto interno utilizado para estimar o hiperplano separador, movendo os pontos no espaço original e facilitando a criação do limite de separação. As funções *kernel* mais utilizadas junto à MSV são a polinomial (que eleva o grau do espaço de observações de acordo com o grau do polinômio) e a RBF (*Radial Basis Function*, ou Gaussiana), considerada uma transformação de grau infinito (CHANG et al., 2010).

#### 2.2.4 Matriz de Confusão

Segundo Marquês et al. (2012), a avaliação de classificações de concessão de crédito pode ser realizada através das informações de uma matriz de confusão. Adicionalmente, se variável de resposta contém apenas duas categorias (bons e maus pagadores), todas as métricas de avaliação podem ser derivadas de uma matriz de confusão 2x2, conforme apresentada na Tabela 2.

		Classificado como bom pagador	Classificado como mau pagador
Bom pagador	Verdadeiro Positivo (VP)	Falso Negativo (FN)	
Mau pagador	Falso Positivo (FP)	Verdadeiro Negativo (VN)	

Tabela 2 – Matriz de Confusão

Da matriz, apresentada na Tabela 2, podem então ser calculadas a sensibilidade (taxa de positivos verdadeiros), especificidade (taxa de negativos verdadeiros) e a acurácia (taxa de classificações corretas) conforme a equação (4), equação (5) e a equação (6), respectivamente.

$$\text{Sensibilidade} = \text{VP}/(\text{VP}+\text{FN}) \quad (4)$$

$$\text{Especificidade} = \text{VN}/(\text{FP}+\text{VN}) \quad (5)$$

$$\text{Acurácia} = (\text{VP}+\text{VN})/(\text{VP}+\text{VN}+\text{FP}+\text{FN}) \quad (6)$$

## 3 Método

A metodologia avaliada neste estudo é uma adaptação do método de Kahmann et al. (2017) para o cenário de *Credit Scoring* e é composta por cinco etapas: *i*) dividir os dados em porções de treino, validação e teste; *ii*) utilizando as observações da porção de treino, estimar, através da IM, a redundância entre as variáveis independentes e a similaridade destas variáveis com a variável resposta; *iii*) criar um Índice de Importância das Variáveis (IIV), para estimar a relevância de cada variável para a categorização de observações, utilizando os resultados de *ii* em um problema de Programação Quadrática; *iv*) iterativamente classificar as observações da porção de validação utilizando um procedimento *forward* ordenado pelo IIV e identificar o subconjunto

que conduz ao melhor resultado; e v) classificar as observações da porção de teste, verificando o poder de generalização do método. Tais passos são detalhados na sequência.

i) Dividir os dados em porções de treino, validação e teste

Seja a matriz  $\mathbf{X}$  uma matriz composta por  $M$  observações descritas por  $N$  variáveis. Tal matriz tem então suas observações distribuídas aleatoriamente entre as matrizes  $\mathbf{Tr}$  (contendo 60% das observações),  $\mathbf{V}$  (contendo 20% das observações) e  $\mathbf{Ts}$  (contendo 20% das observações), que representam respectivamente as porções de treino, validação e teste, de forma que  $\mathbf{Tr} \cup \mathbf{V} \cup \mathbf{Ts} = \mathbf{X}$  e  $\mathbf{Tr} \cap \mathbf{V} \cap \mathbf{Ts} = \emptyset$ . A matriz  $\mathbf{Tr}$  contém os dados utilizados para gerar o modelo (chamada futuramente apenas como “porção de treino”), enquanto  $\mathbf{V}$  contém as observações utilizadas para validar o modelo gerado (chamada futuramente apenas como “porção de validação”) e  $\mathbf{Ts}$  representa observações alheias à calibração do modelo, sendo utilizadas então para verificar o poder de generalização do modelo (chamada futuramente apenas como “porção de teste”).

ii) Estimar a Informação Mútua entre as variáveis para criar a matriz de redundância e o vetor de similaridade

Quando variáveis são selecionadas para classificação, o objetivo é identificar um subconjunto de variáveis com baixa redundância, porém que preservem o máximo possível de informação a respeito da variável resposta (GUYON; ELISSEEFF, 2003; LIU; YU, 2005). Para tanto, no passo (ii) é utilizada a IM, descrita na equação (2), para a determinação de uma matriz  $\mathbf{R}$ , que descreve a informação compartilhada entre as variáveis preditoras, e um vetor  $\mathbf{s}$  que descreve a informação compartilhada entre as variáveis preditoras e a variável resposta. Portanto,  $\mathbf{R}$  é uma matriz ( $N \times N$ ) onde o elemento  $r_{ij}$  é a estimativa da IM entre a variável  $i$  e  $j$ . Por sua vez,  $\mathbf{s}$  é um vetor  $N$ -dimensional onde o  $i$ -ésimo elemento é definido como a estimativa da IM entre a variável  $i$  e a variável resposta.

iii) Gerar o Índice de Importância das Variáveis

Neste passo é gerado o IIV que vai guiar a inclusão de variáveis no processo realizado no passo (iv). Tal índice é gerado através das proposições de Rodriguez-Lujan et al. (2010) e consiste em resolver o problema de Programação Quadrática descrito pelas equações (7), (8) e (9). A função objetivo, descrita na equação (7), tem como objetivo criar o cenário de mínima

informação compartilhada entre as variáveis preditoras e máxima informação compartilhada entre estas variáveis com a variável resposta. A constante  $\alpha$  representa um termo de balanceamento, que visa impedir o desequilíbrio de magnitude entre os termos quadrático e linear (maiores informações a respeito do cálculo de  $\alpha$  podem ser encontrados em Rodriguez-Lujan et al. (2010)), uma vez que a IM não possui limite superior. Por sua vez, as restrições apresentadas nas equações (8) e (9) tem como objetivo limitar o domínio da resposta, neste caso mantendo os valores de  $\mathbf{x}$  no intervalo [0,1]. O resultado de  $\mathbf{x}$  no problema de Programação Quadrática representa o peso das variáveis  $x_i$  no cenário de mínima redundância e máxima similaridade, portanto uma variável com IIV maior é considerada mais importante para a construção do modelo quando comparada às variáveis com IIV menor.

$$\underset{\mathbf{x} \in \mathbb{R}^N}{\text{minimize}} \quad f(\mathbf{x}) = \left\{ \frac{1}{2} (1 - \alpha) \mathbf{x}^t \mathbf{R} \mathbf{x} - \alpha \mathbf{s}^t \mathbf{x} \right\} \quad (7)$$

Sujeito à

$$\mathbf{x}_i \geq 0 \quad (8)$$

$$\sum_{i=1}^N x_i = 1 \quad (9)$$

#### iv) Selecionar o melhor subconjunto de variáveis

No passo (iv) as observações da porção de treino são utilizadas para criar o modelo de classificação, através da MSV, enquanto as observações da porção de validação são utilizadas para validar o modelo. Através de um procedimento *forward*, ordenado pelo IIV, as variáveis são iterativamente incluídas no modelo onde a cada iteração as observações da porção de validação são classificadas e sua sensibilidade e especificidade são determinadas. Após todas as variáveis serem inseridas no modelo é identificado o subconjunto com os resultados mais próximos de um ponto ótimo (neste caso sensibilidade e especificidade iguais a 1), conforme a equação (10).

$$d_n = \sqrt{(1 - S_n)^2 + (1 - E_n)^2} \quad (10)$$

onde  $d_n$  é a distância dos resultados com  $n$  variáveis para o ponto ótimo, enquanto  $S_n$  e  $E_n$  são, respectivamente, a sensibilidade e a especificidade das previsões na porção de validação com um subconjunto de variáveis de tamanho  $n$ . O subconjunto de variáveis que apresentar o menor valor de  $d_n$  será retido. Tipicamente é encontrada na literatura a utilização da acurácia como métrica para determinar o melhor subconjunto de variáveis, porém tal abordagem pode esconder falsos

positivos (ou falsos negativos), o que pode prejudicar a tomada de decisão realizada a partir dos resultados. Desta forma a utilização da métrica apresentada na equação (9) não apenas se torna mais condizente com o objetivo como também é mais flexível, uma vez que se pode atribuir mais importância para a sensibilidade ou à especificidade através da ponderação de  $(1 - S_n)$  e  $(1 - E_n)$ .

v) Classificar as observações da porção de teste

Neste passo é utilizado o modelo gerado pelas observações da porção de treino, com apenas as  $n$  variáveis retidas, para classificar as observações da porção de teste. Desta forma, as observações da porção de teste representam novas observações não utilizadas na calibração do modelo, permitindo determinar o poder de generalização do método.

Dentre os três tipos de seleção de variáveis citados por Saeys et al. (2007), tal método é categorizado como *wrapper*, uma vez que a avaliação dos subconjuntos é realizada através dos resultados de classificação obtidos através da MSV. Tal abordagem é utilizada com o intuito de guiar a seleção de variáveis para a melhor categorização das observações, independentemente de outros critérios.

## 4 Resultados

O método é aplicado em dois bancos de dados públicos, o *German Credit Data* e o *Australian Credit Approval*, ambos disponíveis no site da *UCI Repository* (<https://archive.ics.uci.edu/ml/>). A escolha destes bancos de dados se dá pelo fato de diversos estudos utilizarem estes bancos de dados. Adicionalmente, Louzada et al. (2016) apresentam uma revisão da literatura com os estudos realizados em tais bancos de dados, os quais servirão para complementar a avaliação dos resultados obtidos através da metodologia estudada neste trabalho. Os parâmetros da MSV foram determinados através de validação cruzada (BARBON et al., 2016; ZHANG et al., 2015). Todos experimentos computacionais foram realizados através do *software Matlab® 2014a*, utilizando o *Statistics and Machine Learning Toolbox* e o *Optimization Toolbox*. O método foi replicado 100 vezes em cada banco de dados para evitar viés por conta da amostragem.

## 4.1 German Credit Data

Este banco de dados é composto por 1000 observações, sendo 700 que pagaram seus débitos e 300 clientes que foram maus pagadores. Tais observações são compostas por 20 variáveis, 7 contínuas e 13 categóricas, e a descrição das variáveis pode ser encontrada em [https://archive.ics.uci.edu/ml/datasets/statlog+\(german+credit+data\)](https://archive.ics.uci.edu/ml/datasets/statlog+(german+credit+data)). Dado o número de observações total do banco de dados, a porção de treino é composta por 600 observações e ambas porções de validação e teste são compostas por 200 observações. Junto à descrição do banco de dados é disponibilizada uma matriz de erro que sugere a utilização de um critério específico de avaliação das classificações, atribuindo penalidades 5 vezes maior aos FN quando comparado aos FP. Porém, como o método estudado avalia as classificações ao longo das iterações através da equação (10), tal critério não foi utilizado.

Os resultados referentes ao passo *iii*) de cada repetição, ou seja, os valores resultantes da otimização e a ordem de inclusão de cada variável são apresentados respectivamente na Tabela 3 e Tabela 4. Analisando os IIV ao longo das 100 repetições, nota-se que a variável 1 apresenta maior IIV médio, seguido das variáveis 3, 20, 6 e 2. Também é possível perceber que a variável 1 é ranqueada como a primeira a ser incluída no modelo em mais 72% das repetições, indicando que esta variável possui o melhor poder de discriminação. Não há dentre as demais variáveis alguma outra com tamanho destaque, porém as variáveis 3, 20, 6 e 2, também apresentam bom ranqueamento mediano (3, 5, 5 e 5, respectivamente). Apesar de possuir um IIV médio semelhante ao da variável 3, a variável 20 possui um desvio padrão maior, justificando um pior ranqueamento mediano.

Variável	Índice de Importância das Variáveis									
	1	2	3	4	5	6	7	8	9	10
Média	0,29	0,07	0,13	0,05	0,06	0,07	0,02	0,01	0,02	0,03
Desv. Pad	0,07	0,05	0,05	0,03	0,04	0,05	0,02	0,02	0,02	0,05
Variável	11	12	13	14	15	16	17	18	19	20
Média	0	0,03	0,03	0,04	0,02	0	0,01	0	0	0,11
Desv. Pad	0,01	0,03	0,02	0,05	0,03	0	0,02	0,01	0,01	0,11

Tabela 3 – Resumo dos Índices de Importância das Variáveis no *German Credit Data*

Variável	Rankeamento									
	1	2	3	4	5	6	7	8	9	10
Mediana	1	5	3	8	6,5	5	10	14	12	13
Mínimo	1	1	1	2	3	2	3	6	3	2
Máximo	3	20	14	19	20	19	20	20	20	20
Variável	11	12	13	14	15	16	17	18	19	20
Mediana	18	10	9	11	11	20	17	16	16	5
Mínimo	9	3	3	1	2	9	4	8	5	1
Máximo	20	18	20	19	20	20	20	20	20	18

Tabela 4 – Resumo do ranqueamento das variáveis no *German Credit Data*

Os resultados do passo *iv*), as distâncias calculadas através da equação (10), são apresentadas na Tabela A3 do Apêndice A. É possível notar que o maior valor para estas distâncias é 1, ou seja, casos onde o modelo categoriza todas observações em apenas uma classe, resultando em 100% de sensibilidade e 0% de especificidade, ou vice e versa. Por sua vez, o menor valor é 0,5, resultado da repetição 19 que resultou em uma especificidade de 0,5849 e uma sensibilidade de 0,7273. Estes resultados enaltecem a utilização da equação (10) como forma de avaliação dos subconjuntos gerados, uma vez que evita a seleção de subconjuntos que tendem a gerar classificadores que categorizam as observações em apenas uma classe.

Para complementar a análise do passo *iv*), a Tabela 5 apresenta a porcentagem das vezes em que as variáveis aparecem no subconjunto selecionado. As variáveis 1 e 3 foram as com maior porcentagem de aparição no subconjunto retido, sendo selecionadas em todas as 100 repetições. Adicionalmente, as variáveis 2, 4, 5, 6, 7 e 20 também ganham destaque por serem selecionadas em mais de 80% das repetições. Apesar de não ter um ranqueamento mediano menor em relação à outras variáveis, a variável 4 é selecionada em 98% das repetições, indicando que apesar de não ter um IIV alto, tal variável é importante para a classificação das observações.

Variável	% de vezes retida	Variável	% de vezes retida
1	100	11	27
2	93	12	78
3	100	13	76
4	98	14	72
5	85	15	77
6	93	16	25
7	84	17	27
8	42	18	30
9	64	19	31
10	65	20	85

Tabela 5 – Frequência das variáveis retidas aplicando o método proposto no *German Credit Data*

Por fim, os resultados do passo v) são apresentados na Tabela 6, que contém a sensibilidade, especificidade e acurácia média nos dados de teste, utilizando apenas as variáveis retidas e também todas as variáveis originais. É possível notar um melhor equilíbrio entre a correta identificação de bons e maus pagadores quando a seleção de variáveis é executada. Porém, de acordo com Lee e Zhu (2011) o desbalanço entre as categorias (70% do banco de dados é composto por bons pagadores) comumente conduz à geração modelos que tendem a priorizar a correta categorização da classe com mais observações, neste caso classificando com maior precisão os bons pagadores. Por sua vez, quando a seleção de variáveis não é utilizada as observações tendem a ser classificadas como bons pagadores. Também ressalta-se a grande variabilidade da sensibilidade na porção de teste quando utilizada a seleção de variáveis, indicando que a amostragem possui bastante influência neste resultado.

Resultados médios na porção de teste utilizando as variáveis selecionadas	
Sensibilidade Teste	0,8867 (0,1075)
Especificidade Teste	0,3560 (0,0400)
Acurácia Teste	0,7442 (0,0076)
Resultados na porção de teste utilizando todas variáveis	
Sensibilidade Teste	0,9968 (0,0084)
Especificidade Teste	0,0034 (0,0011)
Acurácia Teste	0,6941 (0,0073)

Tabela 6 – Resultados do método proposto aplicado no *German Credit Data* (desvio padrão entre parêntesis)

## 4.2 Australian Credit Approval

Este banco de dados é composto por 690 observações, sendo 307 bons clientes e 383 maus clientes. Portanto, a porção de treino contém 414 observações e a porção de validação e de teste contém 138 observações cada. Tais observações são descritas por 14 variáveis, sendo 6 nominais e 8 contínuas. Diferentemente do *German Credit Data*, este banco de dados não possui descrição das variáveis e os valores das observações não são disponibilizados na forma original, de forma a manter o sigilo dos dados.

Os resultados do passo iii) quando utilizado o *Australian Credit Approval*, apresentados na Tabela 7, mostram que a variável 8 possui o maior IIV médio e é indicada como primeira variável a ser incluída em todas as repetições. As variáveis 10 e 9 também possuem um alto IIV médio, enquanto as demais variáveis possuem um IIV médio próximo de 0. Tais diferenças indicam que apenas estas três variáveis possuem bom poder de discriminação entre as classes, o

que é corroborado pelo ranqueamento mediano das variáveis apresentado na Tabela 8. O ranqueamento mediano das variáveis 8, 9 e 10 são 1, 3 e 2, respectivamente, ou seja, tais variáveis são comumente incluídas nas primeiras iterações.

Variável	Índice de Importância das Variáveis						
	1	2	3	4	5	6	7
Média	0	0	0	0	0,02	0	0,02
Desv. Pad	0	0	0	0	0,01	0	0,02
Variável	8	9	10	11	12	13	14
Média	0,77	0,08	0,12	0	0	0	0
Desv. Pad	0,07	0,05	0,04	0	0	0,01	0,01

Tabela 7 – Resumo dos Índices de Importância das Variáveis no *Australian Credit Approval*

Variável	Rankeamento						
	1	2	3	4	5	6	7
Mediana	13	10	9	9	4,5	8	4,5
Mínimo	11	4	5	6	3	5	2
Máximo	14	14	14	13	7	14	7
Variável	11	12	13	14	15	16	17
Mediana	1	3	2	13	12	6	8
Mínimo	1	2	2	10	8	4	4
Máximo	1	6	3	14	14	10	11

Tabela 8 – Resumo do ranqueamento das variáveis no *Australian Credit Approval*

Os resultados das 100 repetições do passo iv) quando utilizado o *Australian Credit Approval* são apresentados na Tabela B3 do Apêndice B. As maiores distâncias possuem valor igual a 1, quando todas observações são categorizadas em apenas uma classe, enquanto a menor distância foi 0,1819 (0,9124 de sensibilidade e 0,8405 de especificidade) na repetição 45. O valor médio das menores distâncias de cada repetição é de 0,23, indicando que os subconjuntos selecionados possuem baixos valores de sensibilidade e especificidade.

Combinando os resultados da Tabela 8 e da Tabela B3 é possível identificar a quantidade de vezes que cada variável apareceu no subconjunto de variáveis retidas. Tal resultado é apresentado na Tabela 9, que mostra que a variável 8 foi retida em 100% das repetições, enquanto a variável 10 foi retida em 79% das repetições. Complementarmente apenas as variáveis 7 e 9 foram também retidas (1% e 27% das repetições, respectivamente), indicando que a seleção das variáveis foi realizada de forma consistente. Estes resultados vão de

encontro com os resultados do passo *iii*), que indica que apenas as variáveis 8, 9 e 10 possuem bom poder de categorização.

Variável	% de vezes retida	Variável	% de vezes retida
1	0	8	100
2	0	9	27
3	0	10	79
4	0	11	0
5	0	12	0
6	0	13	0
7	1	14	0

Tabela 9 – Frequência das variáveis retidas aplicando o método proposto no *Australian Credit Approval*

Conforme descrito na Tabela 10, a seleção de variáveis melhorou os resultados quando comparados à classificação com modelos contendo todas as variáveis. Utilizando a seleção de variáveis, o número de bons pagadores foi melhor identificado quando comparado à categorização de maus pagadores, já utilizando todas as variáveis tal categorização é melhor distribuída, porém inferior. A baixa variabilidade nos resultados indica que a divisão das observações nas diferentes porções pouco influencia nos resultados finais.

Resultados médios na porção de teste utilizando as variáveis selecionadas	
Sensibilidade Teste	0,9644 (0,0278)
Especificidade Teste	0,8860 (0,0245)
Acurácia Teste	0,9234 (0,0115)
Resultados na porção de teste utilizando todas variáveis	
Sensibilidade Teste	0,8455 (0,0189)
Especificidade Teste	0,8661 (0,0118)
Acurácia Teste	0,8578 (0,0156)

Tabela 10 – Resultados do método proposto aplicado no *Australian Credit Approval* (desvio padrão entre parêntesis)

### 4.3 Comparação dos resultados encontrados com a literatura

Para melhor avaliar os resultados da metodologia utilizada neste estudo, foi realizado um levantamento de estudos anteriores que utilizam os bancos de dados usados neste trabalho. Tal levantamento foi realizado através da revisão da literatura realizada por Louzada et al. (2016), que contemplou 187 trabalhos publicados que tinham *credit scoring* como assunto principal. Destes 187 trabalhos, foram filtrados apenas aqueles que utilizam o *German Credit Data* ou o *Australian Credit Approval*, algum tipo de seleção de variáveis, resultados baseados em dados de uma matriz de confusão e que utilizem ferramentas de classificação clássicas (retirando, por

exemplo, classificadores em paralelo ou melhorados). Adicionalmente, alguns trabalhos foram publicados através de publicadoras que não são possíveis de serem acessadas através da rede da UFRGS, restando assim 8 trabalhos a serem comparados. Os resultados destes 8 trabalhos são apresentados na Tabela 11.

Trabalho	Ferramenta de Classificação	Acurácia (German)	Acurácia (Australian)
Tsai (2009)	Redes Neurais	0,7587	0,8927
Wang et al. (2012)	Regressão Logística	Não usou	0,8930
Vukovic et al. (2012)	k- Vizinhos Próximos	0,7740	0,8855
Sadatrasoul et al. (2015)	Árvore de Decisões	0,7351	0,8443
Chen e Li (2010)	MSV	0,7670	0,8652
Marqués et al. (2012)	MSV	0,6900	0,8600
Ping e Yongheng (2011)	MSV	0,7660	0,8752
Liang et al. (2014)	MSV	0,7654	0,8552
Estudo proposto	MSV	0,7442	0,9234

Tabela 11 – Comparação dos resultados do método avaliado com demais trabalhos encontrados na literatura

Quando comparado aos métodos que utilizam a MSV, o método avaliado neste trabalho produz resultados melhores no *Australian Credit Approval* e piores no *German Credit Data*. Tal relação também é encontrada quando os resultados do método deste trabalho são comparados aos resultados de abordagens propostas com diferentes ferramentas de classificação. Através de tais comparações é possível concluir que o método estudado produz resultados piores no banco de dados não balanceado, porém os resultados são superiores no banco de dados que possui classes com quantidades semelhantes de observações, o que é corroborado por Kahmann et al. (2017). O resultado inferior no *German Credit Data* pode ser atribuído ao fato de a metodologia buscar equilíbrio entre sensibilidade e especificidade, porém tal afirmação não pode ser confirmada uma vez que os artigos utilizados para a comparação baseiam seus resultados unicamente na acurácia.

Apesar de Louzada et al. (2016) indicar a MSV como a melhor ferramenta para a classificação de observações de *credit scoring*, os resultados apresentados na Tabela 11 indicam que uma vez realizada a seleção das variáveis mais importantes, ferramentas menos robustas como Regressão Logística e k-Vizinhos Próximos produzem resultados melhores. Isso pode ser explicado pelo fato de a seleção de variáveis remover informações que prejudiquem tais classificadores, conduzindo a melhores resultados.

## 5 Conclusão

Depois das crises que atingiram a economia mundial ao longo da última década, instituições financeiras têm dedicado cada vez mais esforços de forma a identificar previamente se um novo cliente trará retorno positivo ou prejuízos. Com o avanço de tecnologias tanto para a criação quanto para o armazenamento de dados, as abordagens para a modelagem de concessão de crédito têm se tornado cada vez mais importantes, identificando dentro de grandes bancos de dados as informações mais relevantes para identificar os clientes aptos a receberem crédito.

Dentro deste cenário, este trabalho avalia um método multicriterial para identificar se um novo cliente deve ou não receber crédito. O método foi aplicado em dois bancos de dados públicos, o *German Credit Data* e o *Australian Credit Approval*, atingindo uma acurácia média de 0,7442 (sensibilidade de 0,8867 e especificidade de 0,3560) e 0,9234 (sensibilidade de 0,9644 e especificidade de 0,8860), respectivamente. Tais resultados são superiores quando comparados aos resultados utilizando todas as variáveis, porém quando comparados a outros estudos os resultados são inferiores quando utilizado o *German Credit Data* e superiores quando utilizado o *Australian Credit Approval*. Estas comparações, juntamente com a análise dos resultados em cada passo do método permitiu avaliar a qualidade do método estudado, objetivo deste estudo.

Desdobramentos futuros deste estudo envolvem a utilização de diferentes técnicas de classificação, como Redes Neurais, Regressão Logística e combinações de classificadores, com o intuito de verificar qual possui melhor poder de categorização quando aliada à metodologia utilizada. Adicionalmente é sugerida a reavaliação dos resultados do *German Credit Data* quando utilizada a matriz de erros recomendada, com o intuito de verificar se tal abordagem melhora os resultados de especificidade, forma a identificar a influência de tal fator na prevenção de FP e FN. Por fim, sugere-se a junção da abordagem para seleção de variáveis deste estudo com o pré-processamento de dados proposto em Hsieh (2005) com o intuito de melhorar a categorização de dados voltados ao *credit scoring*.

## Referências

- ABELLÁN, J.; CASTELLANO, J. G. A comparative study on base classifiers in ensemble methods for credit scoring. *Expert Systems with Applications*, v. 73, p. 1–10, 2017.
- AKAY, M. F. Support vector machines combined with feature selection for breast cancer diagnosis. *Expert Systems with Applications*, v. 36, n. 2, p. 3240–3247, 2009.

- ALMUNIA, M.; BENETRIX, A.; EICHENGREEN, B.; O'ROURKE, K. H.; RUA, G. From Great Depression to Great Credit Crisis: Similarities, Differences and Lessons. **Economic Policy**, v. 25, n.62, p. 219-265, 2010.
- BARBON, A. P. A. C.; BARBON, S.; MANTOVANI, R.G.; FUZYI, E.M.; PERES, L.M.; BRIDI, A.M. Storage time prediction of pork by Computational Intelligence. **Computers and Electronics in Agriculture**, v. 127, p. 368–375, 2016.
- BEN-BASSAT, M. Pattern recognition and reduction of dimensionality. **Handbook of Statistics**, v. 2, p. 773-910, 1982.
- BLUM, A. L.; Langley, P. Selection of relevant features and examples in machine learning. **Artificial Intelligence**, v. 97, n. 1–2, p. 245–271, 1997.
- BURGES, C. C. J. C. A Tutorial on Support Vector Machines for Pattern Recognition. **Data Mining and Knowledge Discovery**, v. 2, n. 2, p. 121–167, 1998.
- CHANG, Y.-W.; HSIEH, C. J.; CHANG, K. W.; RINGGAARD, M.; LIN, C. J. Training and Testing Low-degree Polynomial Data Mappings via Linear SVM. **Journal of Machine Learning Research**, v. 11, p. 1471–1490, 2010.
- CHEN, F. L.; LI, F. C. Combination of feature selection approaches with SVM in credit scoring. **Expert Systems with Applications**, v. 37, n. 7, p. 4902–4909, 2010.
- CHEN, H. L.; YANG, B.; LIU, J.; LIU, D.Y. A support vector machine classifier with rough set-based feature selection for breast cancer diagnosis. **Expert Systems with Applications**, v. 38, n. 7, p. 9014–9022, 2011.
- CHEN, M. J.; CHEN, K. N.; LIN, C. W. Optimization on response surface models for the optimal manufacturing conditions of dairy tofu. **Journal of Food Engineering**, v. 68, n. 4, p. 471–480, 2005.
- CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, n. 3, p. 273–297, 1995.
- DASH, M.; LIU, H. Feature selection for classification. **Intelligent data analysis**, v.1, n.3, p.131-156, 1997.
- DUDA, R.O.; HART, P.E.; STORK, D.G. **Pattern classification**. 2a. Edição. New York, John Wiley, 2001.
- GILL, P. E.; WONG, E. Methods for convex and general quadratic programming. **Mathematical Programming Computation**, v. 7, n. 1, p. 71–112, 2015.
- GUYON, I.; WESTON, J.; BARNHILL, S.; VAPNIK, V. Gene selection for cancer classification using support vector machines. **Machine learning**, v.46, n.1-3, p.389-422, 2002.
- GUYON, I.; ELISSEEFF, A. An Introduction to Variable and Feature Selection. **Journal of Machine Learning Research**, v. 3, n. 3, p. 1157–1182, 2003.
- HALL, M. **Correlation-based feature selection for machine learning**, 1999. Tese (Doutorado em Ciências da computação), Waikato University, Nova Zelândia.
- HAND, D. J.; HENLEY, W. E. Statistical Classification Methods in Consumer Credit Scoring: a Review. **Royal Statistical Society**, v. 160, n. 3, p. 523–541, 1997.

- HAPFELMEIER, A.; ULM, K. A new variable selection approach using Random Forests. **Computational Statistics and Data Analysis**, v. 60, n. 1, p. 50–69, 2013.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. The Elements of Statistical Learning. Elements, v. 1, p. 337–387, 2009.
- HOLLAND, J.H. **Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence**. U Michigan Press, 1975.
- HSIEH, N. C. Hybrid mining approach in the design of credit scoring models. **Expert Systems with Applications**, v. 28, n. 4, p. 655–665, 2005.
- INZA, I.; LARRAÑAGA, P.; EXTEBERRÍA, R.; SIERRA, B. Feature subset selection by Bayesian networks based optimization. **Artificial Intelligence**, v.123, p.157–184, 2000.
- KAHMANN, A; ANZANELLO, M. J.; MARCELO, M. C. A.; POZEBON, D. Near infrared spectroscopy and element concentration analysis for assessing yerba mate (*Ilex paraguariensis*) samples according to the country of origin. **Computers and Electronics in Agriculture**, v. 140, p. 348–360, 2017.
- KITTNER, J. **Pattern Recognition and Signal Processing**, Chapter Feature Set Search Algorithms Sijthoff and Noordhoff, Alphen aan den Rijn, Netherlands, p.41–60, 1978.
- KOLLER, D.; SAHAMÍ, M. **Toward optimal feature selection**. In Proceedings of the Thirteenth International Conference on Machine Learning, Bari, Italy, p.284–292, 1996.
- LEE, J. S.; ZHU, D. When costs are unequal and unknown: A subtree grafting approach for unbalanced data classification. **Decision Sciences**, v. 42, n. 4, p. 803–829, 2011.
- LIANG, D.; TSAI, C. F.; WU, H. T. The effect of feature selection on financial distress prediction. **Knowledge-Based Systems**, v. 73, n. 1, p. 289–297, 2014.
- LIU, H.; YU, L. Toward integrating feature selection algorithms for classification and clustering. **Ieee Transactions on Knowledge and Data Engineering**, v. 17, n. 4, p. 491–502, 2005.
- LONG, X.-X.; LI, H.-D.; FAN, W.; XU, Q.-S.; LIANG, Y.-Z. A model population analysis method for variable selection based on mutual information. **Chemometrics and Intelligent Laboratory Systems**, v. 121, p. 75–81, 2013.
- LONGSTAFF, F. A. The subprime credit crisis and contagion in financial markets. **Journal of Financial Economics**, v. 97, n. 3, p. 436–450, 2010.
- LOUZADA, F.; ARA, A.; FERNANDES, G. B. Classification methods applied to credit scoring: Systematic review and overall comparison. **Surveys in Operations Research and Management Science**, v. 21, n. 2, p. 117–134, 2016.
- LUTS, J.; OJEDA, F.; Van de PLAS, R.; De MOOR, B.; Van HUFFEL, S.; SUYKENS, J.A. A tutorial on support vector machine-based methods for classification problems in chemometrics. **Analytica Chimica Acta**, v. 665, n. 2, p. 129–145, 2010.
- MARQUÉS, A. I.; GARCÍA, V.; SÁNCHEZ, J. S. Two-level classifier ensembles for credit risk assessment. **Expert Systems with Applications**, v. 39, n. 12, p. 10916–10922, 2012.
- PING, Y.; YONGHENG, L. Neighborhood rough set and SVM based hybrid credit scoring classifier. **Expert Systems with Applications**, v. 38, n. 9, p. 11300–11304, 2011.

RACHOW, T. ; BERGER, S.; BOETTGER, M.K.; SCHULZ, S.; GUINJOAN, S.; YERAGANI, V.K.; VOSS, A.; BÄR, K.J. Nonlinear relationship between electrodermal activity and heart rate variability in patients with acute schizophrenia. **Psychophysiology**, v. 48, n. 10, p. 1323–1332, 2011.

RAKOTOMAMONJY, A. Variable selection using SVM based criteria. **The Journal of Machine Learning Research**, v.3, n.1, p.1357-1370, 2003.

RODRIGUEZ-LUJAN, I.; HUERTA, R.; ELKAN, C.; SANTA CRUZ, C. Quadratic Programming Feature Selection. **Journal of Machine Learning Research**, v. 11, p. 1491–1516, 2010.

RODRÍGUEZ-ROSARIO, C. A.; MODI, K.; KUAH, A.; SHAJI, A.; SUDARSHAN, E.C.G. Completely positive maps and classical correlations. **Journal of Physics A: Mathematical and Theoretical**, v. 41, n. 20, p. 205301, 2008.

SADATRASOUL, S.; GHOLAMIAN, M.; SHAHANAGHI, K. Combination of feature selection and optimized fuzzy apriori rules: The case of credit scoring. **International Arab Journal of Information Technology**, v. 12, n. 2, p. 138–145, 2015.

SAEYS, Y.; INZA, I.; LARRAÑAGA, P. A review of feature selection techniques in bioinformatics. **Bioinformatics**, v. 23, n. 19, p. 2507–2517, 2007.

SIEDELECKY, W.; SKLANSKY, J. On automatic feature selection. **International Journal of Pattern Recognition**, v.2, n.2, p.197–220, 1998.

SKALAK, D. **Prototype and feature selection by sampling and random mutation hill climbing algorithms**. In Proceedings of the Eleventh International Conference on Machine Learning, p.293–301, 1994.

TSAI, C. F. Feature selection in bankruptcy prediction. **Knowledge-Based Systems**, v. 22, n. 2, p. 120–127, 2009.

VUKOVIC, S.; Delibasic, B.; Uzelac, A.; Suknovic, M. A case-based reasoning model that uses preference theory functions for credit scoring. **Expert Systems with Applications**, v. 39, n. 9, p. 8389–8395, 2012.

WANG, J.; Hedar, A. R.; Wang, S.; Ma, J. Rough set and scatter search metaheuristic based feature selection for credit scoring. **Expert Systems with Applications**, v. 39, n. 6, p. 6123–6128, 2012.

WESTAD, F.; HERSLETH, M.; MARTENS, H. Variable selection in PCA in sensory descriptive and consumer data. **Food Quality and Preference**, v. 14, n. 5–6, p. 463–472, 2003.

WESTON, J.; ELISSEEFF, A.; SCHÖLKOPF, B.; TIPPING, M. Use of the zero norm with linear models and kernel methods. **The Journal of Machine Learning Research**, n.3, p.1439-1461, 2003.

YU, L.; LIU, H. Efficient feature selection via analysis of relevance and redundancy. **The Journal of Machine Learning Research**, v.5, p.1205–1224, 2004.

ZHANG, Y.; ZHENG, L.; LI, M.; DENG, X.; JI, R. Predicting apple sugar content based on spectral characteristics of apple tree leaf in different phenological phases. **Computers and Electronics in Agriculture**, v. 112, p. 20–27, 2015.

ZOMER, S.; DEL NOGAL SÁNCHEZ, M.; BRERETON, R. G.; PÉREZ PAVÓN, J. L. Active learning support vector machines for optimal sample selection in classification. **Journal of Chemometrics**, v. 18, n. 6, p. 294-305, 2004.

## APÊNDICE A – Resultados do *German Credit Data*

Tabela A1 – Índice de Importância das Variáveis

Repetição	Variável																			
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	0,23	0,11	0,10	0,01	0,06	0,00	0,02	0,00	0,08	0,00	0,00	0,00	0,06	0,00	0,01	0,00	0,00	0,00	0,01	0,29
2	0,30	0,07	0,13	0,06	0,09	0,07	0,03	0,00	0,04	0,00	0,00	0,00	0,04	0,02	0,03	0,00	0,00	0,00	0,00	0,13
3	0,24	0,06	0,13	0,05	0,11	0,05	0,00	0,02	0,00	0,04	0,00	0,01	0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,27
4	0,32	0,05	0,14	0,07	0,05	0,04	0,09	0,00	0,00	0,03	0,00	0,04	0,00	0,01	0,05	0,00	0,00	0,00	0,00	0,10
5	0,18	0,13	0,15	0,06	0,03	0,06	0,00	0,02	0,00	0,05	0,00	0,06	0,01	0,03	0,10	0,00	0,00	0,00	0,00	0,12
6	0,38	0,21	0,13	0,07	0,00	0,10	0,02	0,05	0,00	0,00	0,00	0,03	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00
7	0,27	0,03	0,14	0,02	0,03	0,11	0,02	0,00	0,00	0,00	0,00	0,02	0,04	0,00	0,02	0,00	0,00	0,00	0,00	0,28
8	0,17	0,00	0,18	0,03	0,13	0,11	0,01	0,01	0,08	0,03	0,00	0,00	0,08	0,01	0,00	0,00	0,00	0,00	0,00	0,16
9	0,26	0,06	0,16	0,00	0,07	0,05	0,04	0,00	0,00	0,02	0,00	0,00	0,00	0,03	0,01	0,00	0,00	0,00	0,00	0,30
10	0,28	0,00	0,13	0,04	0,18	0,02	0,04	0,00	0,01	0,00	0,00	0,00	0,00	0,29	0,00	0,00	0,00	0,00	0,00	0,00
11	0,19	0,07	0,16	0,00	0,07	0,16	0,03	0,03	0,09	0,00	0,00	0,06	0,00	0,09	0,00	0,00	0,00	0,00	0,00	0,03
12	0,29	0,11	0,07	0,02	0,03	0,08	0,03	0,01	0,00	0,00	0,01	0,05	0,00	0,06	0,00	0,00	0,00	0,00	0,00	0,24
13	0,38	0,04	0,13	0,06	0,03	0,04	0,03	0,00	0,03	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,26
14	0,29	0,11	0,14	0,00	0,02	0,00	0,04	0,00	0,00	0,04	0,00	0,06	0,06	0,00	0,03	0,00	0,00	0,00	0,00	0,20
15	0,24	0,14	0,22	0,04	0,02	0,06	0,01	0,00	0,00	0,00	0,00	0,05	0,04	0,09	0,00	0,00	0,02	0,02	0,00	0,05
16	0,40	0,09	0,09	0,04	0,06	0,08	0,05	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,00	0,00	0,00	0,00	0,16
17	0,23	0,01	0,19	0,03	0,09	0,10	0,01	0,00	0,01	0,00	0,00	0,10	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,21
18	0,35	0,04	0,15	0,04	0,04	0,08	0,03	0,00	0,02	0,00	0,00	0,02	0,05	0,00	0,02	0,00	0,00	0,00	0,00	0,14
19	0,31	0,00	0,12	0,00	0,08	0,04	0,04	0,03	0,01	0,08	0,00	0,01	0,02	0,03	0,00	0,00	0,00	0,00	0,00	0,23
20	0,36	0,12	0,13	0,07	0,00	0,00	0,03	0,00	0,00	0,00	0,00	0,05	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,25
21	0,29	0,04	0,16	0,07	0,10	0,13	0,03	0,01	0,03	0,00	0,00	0,04	0,00	0,00	0,03	0,00	0,00	0,01	0,00	0,07
22	0,32	0,07	0,16	0,04	0,05	0,21	0,03	0,00	0,03	0,00	0,00	0,01	0,00	0,03	0,00	0,00	0,00	0,00	0,00	0,06
23	0,26	0,01	0,14	0,04	0,13	0,08	0,05	0,00	0,05	0,00	0,00	0,05	0,02	0,00	0,04	0,00	0,00	0,00	0,00	0,11
24	0,26	0,13	0,00	0,04	0,06	0,02	0,00	0,00	0,00	0,00	0,03	0,03	0,04	0,10	0,05	0,00	0,07	0,00	0,00	0,18
25	0,46	0,06	0,11	0,00	0,03	0,05	0,04	0,00	0,00	0,00	0,00	0,00	0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,21

26	0,28	0,07	0,05	0,01	0,09	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,03	0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,41
27	0,12	0,11	0,12	0,07	0,04	0,04	0,03	0,00	0,07	0,04	0,00	0,00	0,08	0,08	0,07	0,00	0,02	0,00	0,01	0,09		
28	0,38	0,06	0,09	0,06	0,09	0,00	0,00	0,01	0,06	0,04	0,00	0,01	0,01	0,15	0,01	0,00	0,00	0,00	0,00	0,00	0,01	
29	0,27	0,11	0,11	0,04	0,10	0,05	0,00	0,01	0,02	0,00	0,00	0,10	0,01	0,03	0,00	0,00	0,02	0,05	0,00	0,08		
30	0,23	0,00	0,20	0,04	0,06	0,12	0,06	0,00	0,00	0,08	0,02	0,06	0,01	0,00	0,06	0,00	0,04	0,00	0,00	0,01		
31	0,32	0,05	0,15	0,07	0,03	0,14	0,00	0,03	0,00	0,03	0,00	0,04	0,04	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,09	
32	0,29	0,08	0,03	0,03	0,09	0,21	0,01	0,00	0,00	0,02	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,22	
33	0,39	0,03	0,11	0,01	0,10	0,01	0,07	0,00	0,00	0,08	0,00	0,09	0,02	0,04	0,00	0,00	0,00	0,00	0,00	0,00	0,06	
34	0,34	0,10	0,24	0,05	0,04	0,07	0,03	0,02	0,00	0,02	0,01	0,02	0,01	0,00	0,00	0,00	0,02	0,02	0,00	0,00		
35	0,39	0,08	0,11	0,01	0,02	0,04	0,04	0,00	0,01	0,00	0,00	0,06	0,04	0,03	0,07	0,00	0,00	0,00	0,00	0,00	0,10	
36	0,40	0,15	0,15	0,00	0,03	0,08	0,05	0,02	0,00	0,00	0,00	0,05	0,01	0,03	0,00	0,00	0,00	0,01	0,00	0,02		
37	0,38	0,08	0,05	0,09	0,05	0,08	0,00	0,03	0,02	0,00	0,00	0,04	0,01	0,00	0,10	0,00	0,00	0,00	0,00	0,00	0,06	
38	0,36	0,02	0,08	0,06	0,09	0,08	0,02	0,00	0,06	0,03	0,00	0,00	0,04	0,00	0,10	0,00	0,00	0,00	0,00	0,00	0,06	
39	0,29	0,10	0,17	0,06	0,04	0,09	0,03	0,03	0,05	0,06	0,00	0,02	0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,02	
40	0,28	0,00	0,10	0,06	0,06	0,09	0,01	0,04	0,09	0,09	0,00	0,00	0,07	0,10	0,00	0,00	0,00	0,00	0,00	0,00	0,02	
41	0,31	0,10	0,12	0,03	0,09	0,09	0,00	0,00	0,08	0,00	0,02	0,01	0,00	0,01	0,02	0,00	0,07	0,00	0,00	0,03		
42	0,28	0,01	0,13	0,00	0,01	0,04	0,02	0,00	0,03	0,19	0,00	0,01	0,05	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,22	
43	0,32	0,04	0,13	0,04	0,09	0,03	0,04	0,01	0,02	0,05	0,00	0,01	0,04	0,06	0,03	0,00	0,00	0,00	0,01	0,08		
44	0,23	0,10	0,33	0,02	0,05	0,10	0,04	0,00	0,00	0,00	0,02	0,04	0,00	0,00	0,03	0,00	0,00	0,00	0,00	0,00	0,04	
45	0,24	0,00	0,08	0,04	0,08	0,07	0,10	0,01	0,00	0,07	0,00	0,00	0,02	0,00	0,06	0,00	0,00	0,00	0,00	0,00	0,22	
46	0,29	0,05	0,17	0,04	0,08	0,15	0,00	0,01	0,01	0,07	0,00	0,04	0,00	0,04	0,02	0,00	0,00	0,00	0,00	0,00	0,02	
47	0,41	0,09	0,12	0,01	0,00	0,10	0,02	0,00	0,01	0,00	0,00	0,03	0,02	0,16	0,01	0,00	0,00	0,00	0,00	0,00	0,00	
48	0,27	0,05	0,11	0,02	0,05	0,05	0,00	0,00	0,00	0,00	0,06	0,04	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,30	
49	0,41	0,04	0,22	0,02	0,00	0,06	0,02	0,00	0,03	0,02	0,00	0,04	0,00	0,13	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
50	0,25	0,12	0,18	0,02	0,07	0,05	0,01	0,00	0,03	0,00	0,00	0,02	0,09	0,12	0,00	0,00	0,00	0,00	0,00	0,00	0,05	
51	0,26	0,13	0,13	0,09	0,07	0,06	0,05	0,00	0,01	0,02	0,00	0,02	0,00	0,02	0,01	0,00	0,00	0,05	0,01	0,07		
52	0,27	0,08	0,17	0,09	0,00	0,10	0,03	0,01	0,00	0,08	0,00	0,00	0,04	0,11	0,00	0,00	0,00	0,00	0,00	0,00	0,02	
53	0,26	0,13	0,01	0,04	0,06	0,06	0,00	0,00	0,00	0,22	0,00	0,02	0,03	0,16	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
54	0,31	0,01	0,12	0,07	0,05	0,13	0,02	0,03	0,00	0,03	0,00	0,05	0,01	0,02	0,11	0,00	0,00	0,00	0,00	0,00	0,05	
55	0,36	0,01	0,15	0,01	0,06	0,06	0,00	0,00	0,04	0,21	0,00	0,00	0,02	0,05	0,00	0,00	0,00	0,00	0,00	0,00	0,03	
56	0,40	0,07	0,15	0,02	0,05	0,00	0,00	0,00	0,05	0,00	0,03	0,00	0,06	0,14	0,00	0,00	0,00	0,00	0,00	0,00	0,00	

57	0,40	0,05	0,17	0,02	0,04	0,11	0,01	0,02	0,02	0,00	0,00	0,05	0,02	0,06	0,01	0,00	0,00	0,00	0,00	0,02
58	0,26	0,08	0,04	0,13	0,03	0,11	0,05	0,02	0,00	0,06	0,00	0,03	0,06	0,12	0,00	0,01	0,00	0,01	0,00	0,01
59	0,19	0,09	0,14	0,01	0,06	0,05	0,00	0,00	0,11	0,00	0,07	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,25	
60	0,24	0,00	0,18	0,15	0,13	0,08	0,03	0,00	0,01	0,04	0,01	0,06	0,00	0,05	0,01	0,00	0,00	0,00	0,00	0,01
61	0,26	0,11	0,19	0,01	0,06	0,04	0,04	0,00	0,03	0,07	0,00	0,00	0,02	0,00	0,08	0,00	0,00	0,00	0,00	0,08
62	0,32	0,08	0,22	0,02	0,03	0,08	0,00	0,00	0,04	0,03	0,00	0,04	0,05	0,00	0,01	0,00	0,01	0,00	0,00	0,07
63	0,23	0,27	0,04	0,10	0,00	0,03	0,05	0,00	0,06	0,00	0,00	0,01	0,00	0,01	0,02	0,00	0,00	0,00	0,00	0,18
64	0,27	0,08	0,08	0,08	0,04	0,05	0,01	0,00	0,08	0,00	0,00	0,05	0,06	0,00	0,00	0,00	0,00	0,00	0,00	0,21
65	0,37	0,12	0,12	0,06	0,00	0,06	0,00	0,00	0,03	0,03	0,02	0,01	0,04	0,00	0,06	0,00	0,06	0,00	0,00	0,03
66	0,26	0,12	0,08	0,09	0,08	0,04	0,01	0,03	0,00	0,00	0,00	0,04	0,02	0,11	0,00	0,00	0,00	0,00	0,00	0,12
67	0,28	0,06	0,13	0,10	0,02	0,06	0,07	0,06	0,00	0,05	0,00	0,01	0,00	0,13	0,02	0,00	0,01	0,00	0,00	0,00
68	0,34	0,05	0,10	0,03	0,07	0,03	0,02	0,00	0,00	0,04	0,00	0,10	0,06	0,08	0,07	0,00	0,00	0,00	0,00	0,00
69	0,24	0,05	0,20	0,07	0,08	0,04	0,02	0,00	0,00	0,00	0,01	0,02	0,07	0,15	0,00	0,00	0,00	0,05	0,00	0,00
70	0,33	0,09	0,12	0,08	0,08	0,03	0,00	0,00	0,02	0,09	0,02	0,05	0,02	0,06	0,00	0,00	0,00	0,00	0,00	0,00
71	0,30	0,04	0,21	0,05	0,00	0,09	0,05	0,00	0,01	0,09	0,04	0,03	0,04	0,00	0,02	0,00	0,00	0,00	0,00	0,04
72	0,26	0,03	0,15	0,01	0,08	0,07	0,00	0,00	0,00	0,07	0,00	0,01	0,06	0,13	0,07	0,00	0,02	0,00	0,00	0,04
73	0,24	0,11	0,14	0,02	0,01	0,21	0,01	0,03	0,00	0,00	0,00	0,02	0,01	0,17	0,00	0,00	0,02	0,00	0,00	0,00
74	0,19	0,08	0,17	0,04	0,04	0,03	0,00	0,00	0,00	0,00	0,00	0,04	0,00	0,05	0,00	0,00	0,00	0,00	0,00	0,35
75	0,26	0,08	0,11	0,08	0,08	0,05	0,01	0,00	0,00	0,04	0,00	0,02	0,01	0,00	0,01	0,00	0,00	0,00	0,00	0,27
76	0,28	0,00	0,24	0,02	0,05	0,12	0,03	0,03	0,00	0,00	0,00	0,03	0,04	0,02	0,09	0,00	0,00	0,00	0,00	0,04
77	0,32	0,08	0,10	0,01	0,03	0,06	0,03	0,00	0,02	0,14	0,00	0,00	0,03	0,15	0,02	0,00	0,00	0,00	0,00	0,00
78	0,33	0,11	0,17	0,05	0,01	0,07	0,00	0,04	0,00	0,00	0,00	0,05	0,01	0,01	0,01	0,00	0,10	0,00	0,00	0,05
79	0,27	0,06	0,09	0,05	0,04	0,17	0,04	0,02	0,09	0,07	0,00	0,05	0,01	0,05	0,00	0,00	0,00	0,00	0,00	0,01
80	0,25	0,07	0,14	0,04	0,01	0,09	0,01	0,02	0,02	0,04	0,01	0,05	0,05	0,00	0,09	0,00	0,02	0,00	0,00	0,07
81	0,28	0,09	0,14	0,07	0,05	0,08	0,05	0,01	0,01	0,00	0,00	0,04	0,01	0,12	0,02	0,00	0,00	0,02	0,00	0,00
82	0,25	0,07	0,20	0,01	0,08	0,08	0,01	0,00	0,00	0,00	0,00	0,01	0,04	0,06	0,03	0,00	0,00	0,00	0,00	0,16
83	0,30	0,03	0,16	0,03	0,03	0,12	0,03	0,00	0,02	0,00	0,00	0,00	0,06	0,01	0,09	0,00	0,00	0,00	0,00	0,12
84	0,24	0,05	0,29	0,03	0,04	0,03	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,00	0,00	0,00	0,03	0,00	0,00	0,26
85	0,39	0,14	0,10	0,05	0,00	0,08	0,04	0,02	0,03	0,00	0,00	0,01	0,05	0,02	0,00	0,00	0,00	0,08	0,00	
86	0,23	0,09	0,19	0,00	0,10	0,00	0,00	0,01	0,00	0,00	0,00	0,07	0,00	0,03	0,00	0,00	0,00	0,00	0,00	0,26
87	0,30	0,03	0,12	0,08	0,04	0,27	0,04	0,00	0,00	0,01	0,03	0,02	0,00	0,02	0,00	0,03	0,00	0,00	0,00	

88	0,29 0,07 0,08 0,04 0,06 0,07 0,01 0,06 0,00 0,08 0,00 0,03 0,08 0,07 0,00 0,00 0,00 0,00 0,00 0,00 0,04
89	0,43 0,10 0,18 0,04 0,02 0,13 0,02 0,00 0,02 0,00 0,00 0,01 0,00 0,00 0,02 0,00 0,00 0,00 0,00 0,00 0,03
90	0,25 0,00 0,11 0,12 0,09 0,02 0,09 0,02 0,01 0,00 0,01 0,04 0,05 0,00 0,05 0,03 0,00 0,00 0,00 0,00 0,10
91	0,28 0,08 0,03 0,07 0,04 0,03 0,00 0,00 0,04 0,00 0,00 0,03 0,03 0,00 0,02 0,00 0,00 0,00 0,00 0,00 0,35
92	0,42 0,08 0,12 0,08 0,01 0,01 0,00 0,03 0,02 0,00 0,00 0,02 0,05 0,02 0,01 0,00 0,00 0,00 0,00 0,03 0,10
93	0,14 0,00 0,11 0,07 0,13 0,14 0,05 0,00 0,00 0,10 0,00 0,01 0,04 0,00 0,02 0,00 0,00 0,00 0,00 0,00 0,18
94	0,39 0,02 0,06 0,06 0,09 0,13 0,08 0,01 0,00 0,03 0,00 0,06 0,00 0,00 0,03 0,00 0,01 0,00 0,00 0,02
95	0,24 0,08 0,13 0,17 0,07 0,08 0,01 0,00 0,00 0,02 0,00 0,00 0,05 0,01 0,00 0,00 0,03 0,00 0,00 0,00 0,10
96	0,32 0,08 0,12 0,03 0,00 0,02 0,03 0,01 0,00 0,00 0,00 0,00 0,04 0,00 0,00 0,00 0,00 0,00 0,00 0,00 0,35
97	0,34 0,11 0,10 0,03 0,03 0,01 0,04 0,00 0,03 0,00 0,00 0,00 0,00 0,00 0,02 0,00 0,00 0,00 0,00 0,00 0,28
98	0,18 0,12 0,11 0,10 0,08 0,04 0,00 0,10 0,00 0,00 0,00 0,04 0,00 0,07 0,00 0,00 0,00 0,01 0,00 0,14
99	0,30 0,06 0,09 0,02 0,07 0,04 0,02 0,00 0,00 0,00 0,00 0,05 0,06 0,07 0,00 0,00 0,00 0,00 0,00 0,00 0,23
100	0,30 0,00 0,19 0,01 0,07 0,07 0,02 0,00 0,00 0,02 0,00 0,00 0,08 0,00 0,00 0,00 0,00 0,00 0,00 0,00 0,24
Média	0,29 0,07 0,13 0,05 0,06 0,07 0,02 0,01 0,02 0,03 0,00 0,03 0,03 0,04 0,02 0,00 0,01 0,00 0,00 0,11
Desv. Pad	0,07 0,05 0,05 0,03 0,04 0,05 0,02 0,02 0,02 0,05 0,01 0,03 0,02 0,05 0,03 0,00 0,02 0,01 0,01 0,11

Tabela A2 – Ranking das Variáveis

Repetição	Variável																			
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	2	3	4	10	7	19	8	17	5	16	20	13	6	12	9	15	14	18	11	1
2	1	6	3	7	4	5	11	18	8	15	13	14	9	12	10	20	17	16	19	2
3	2	5	3	6	4	7	12	10	17	8	14	11	9	16	13	20	15	18	19	1
4	1	8	2	5	7	10	4	15	16	11	20	9	13	12	6	14	19	18	17	3
5	1	3	2	8	11	6	14	12	16	9	18	7	13	10	5	20	19	17	15	4
6	1	2	3	5	12	4	8	6	10	14	17	7	9	19	20	13	11	18	16	15
7	2	6	3	11	7	4	10	12	13	16	19	8	5	14	9	20	15	17	18	1
8	2	13	1	9	4	5	12	11	6	8	14	16	7	10	15	20	19	18	17	3
9	2	5	3	14	4	6	7	20	12	9	19	11	13	8	10	15	16	17	18	1
10	2	9	4	6	3	7	5	16	8	15	18	13	12	1	11	20	19	14	17	10
11	1	7	2	15	6	3	10	9	5	13	19	8	12	4	14	20	18	17	16	11
12	1	3	5	10	9	4	8	12	19	14	11	7	13	6	17	18	20	16	15	2
13	1	6	3	4	7	5	8	14	9	17	13	11	12	10	15	20	19	18	16	2
14	1	4	3	11	10	13	8	15	18	7	16	5	6	14	9	20	19	17	12	2
15	1	3	2	9	11	5	13	14	20	15	18	7	8	4	17	19	10	12	16	6
16	1	4	3	8	6	5	7	19	15	14	20	10	18	11	9	12	16	17	13	2
17	1	9	3	7	6	5	10	19	8	15	13	4	18	12	11	20	17	14	16	2
18	1	8	2	6	7	4	9	14	10	16	20	12	5	13	11	17	15	19	18	3
19	1	13	3	14	4	6	7	9	12	5	15	11	10	8	17	20	16	18	19	2
20	1	4	3	5	16	8	13	7	17	19	11	10	6	18	15	14	12	20	9	2
21	1	7	2	6	4	3	10	13	11	14	19	8	17	15	9	20	18	12	16	5
22	1	4	3	7	6	2	8	18	9	14	12	11	19	10	13	17	20	15	16	5
23	1	12	2	9	3	5	6	13	7	17	19	8	11	14	10	15	20	16	18	4
24	1	3	14	9	6	12	15	16	19	13	11	10	8	4	7	18	5	17	20	2
25	1	4	3	15	8	5	6	16	13	19	20	10	7	11	12	9	18	17	14	2
26	2	4	5	9	3	10	11	15	8	18	19	12	7	6	13	20	17	16	14	1
27	1	3	2	8	10	11	13	17	7	12	20	18	6	5	9	19	14	16	15	4
28	1	7	3	6	4	15	14	9	5	8	18	10	11	2	12	20	19	16	17	13

29	1	2	3	9	4	7	20	13	11	15	18	5	14	10	17	19	12	8	16	6
30	1	15	2	9	5	3	8	14	18	4	11	6	13	17	7	20	10	16	19	12
31	1	6	2	5	9	3	20	10	18	11	19	8	7	17	12	13	15	14	16	4
32	1	5	6	7	4	3	10	19	11	8	20	12	9	13	17	15	16	18	14	2
33	1	9	2	12	3	11	6	19	14	5	15	4	10	8	13	20	17	16	18	7
34	1	3	2	5	6	4	7	9	20	12	14	10	13	15	16	19	11	8	17	18
35	1	4	2	13	11	8	9	14	12	15	20	6	7	10	5	18	19	16	17	3
36	1	3	2	19	8	4	5	10	15	13	17	6	11	7	16	20	18	12	14	9
37	1	4	7	3	8	5	14	10	11	15	19	9	12	13	2	20	18	16	17	6
38	1	12	5	7	3	4	11	17	6	10	19	18	9	13	2	14	20	15	16	8
39	1	3	2	6	8	4	9	11	7	5	18	12	10	17	14	20	19	15	16	13
40	1	16	3	8	9	5	12	10	6	4	15	14	7	2	13	20	18	19	17	11
41	1	3	2	8	5	4	18	20	6	14	10	12	16	13	11	19	7	15	17	9
42	1	11	4	12	9	6	8	13	7	3	19	10	5	17	14	20	15	16	18	2
43	1	7	2	9	3	12	8	16	13	6	17	14	10	5	11	20	19	18	15	4
44	2	3	1	11	5	4	6	16	19	18	10	7	14	15	9	20	13	17	12	8
45	1	20	5	9	4	7	3	11	16	6	18	12	10	13	8	14	19	17	15	2
46	1	6	2	8	4	3	18	12	13	5	19	9	14	7	10	20	16	15	17	11
47	1	5	3	9	12	4	8	13	10	17	20	6	7	2	11	19	18	14	16	15
48	2	6	3	10	5	8	7	11	18	16	15	4	9	13	17	19	20	12	14	1
49	1	5	2	9	13	4	8	15	7	10	14	6	11	3	16	20	17	19	12	18
50	1	4	2	10	6	7	12	19	9	13	20	11	5	3	16	17	18	14	15	8
51	1	3	2	4	6	7	8	18	15	12	16	11	17	10	13	19	20	9	14	5
52	1	6	2	5	13	4	9	11	12	7	15	14	8	3	16	20	19	18	17	10
53	1	4	10	7	5	6	15	16	11	2	20	9	8	3	13	19	14	17	18	12
54	1	13	3	5	7	2	11	9	15	10	20	6	14	12	4	19	16	17	18	8
55	1	11	3	10	5	4	12	18	7	2	19	14	9	6	13	20	15	16	17	8
56	1	4	2	9	6	15	17	19	10	7	14	8	16	5	3	20	18	13	12	11
57	1	6	2	8	7	3	14	12	11	19	17	5	9	4	13	20	15	18	16	10
58	1	5	9	2	11	4	8	12	16	6	20	10	7	3	18	13	19	15	17	14
59	2	5	3	10	7	8	11	17	12	4	16	6	13	14	9	20	15	18	19	1

60	1	18	2	3	4	5	9	19	11	8	10	6	16	7	13	20	17	14	15	12
61	1	3	2	12	7	8	9	17	10	6	19	13	11	14	5	20	18	15	16	4
62	1	4	2	11	9	3	15	17	8	10	19	7	6	14	12	20	13	18	16	5
63	2	1	7	4	14	8	6	17	5	15	18	10	16	11	9	12	13	20	19	3
64	1	5	6	3	10	9	11	13	4	12	15	8	7	18	14	19	16	20	17	2
65	1	2	3	4	15	7	19	14	11	10	12	13	8	16	5	20	6	18	17	9
66	1	3	6	5	7	8	12	10	13	16	15	9	11	4	20	18	19	14	17	2
67	1	8	2	4	11	6	5	7	19	9	17	12	20	3	10	18	13	16	15	14
68	1	8	2	11	6	10	12	16	17	9	20	3	7	4	5	19	18	13	14	15
69	1	7	2	6	4	9	11	19	14	13	12	10	5	3	20	17	18	8	16	15
70	1	4	2	6	5	9	13	18	11	3	10	8	12	7	20	17	14	19	16	15
71	1	8	2	6	14	3	5	15	13	4	9	11	7	17	12	20	19	18	16	10
72	1	10	2	13	4	5	17	18	14	7	19	12	8	3	6	20	11	15	16	9
73	1	5	4	8	11	2	12	6	19	15	18	9	10	3	14	20	7	16	17	13
74	2	4	3	7	6	9	12	19	10	14	16	13	8	11	5	20	15	18	17	1
75	2	4	3	6	5	7	12	15	18	8	19	9	10	13	11	20	14	16	17	1
76	1	13	2	11	5	3	9	8	17	18	14	10	7	12	4	20	19	16	15	6
77	1	5	4	12	7	6	8	20	11	3	14	15	9	2	10	13	17	19	18	16
78	1	3	2	8	11	5	15	9	17	16	18	6	13	10	12	20	4	14	19	7
79	1	6	4	8	10	2	11	12	3	5	18	9	14	7	17	20	19	15	16	13
80	1	6	2	10	15	4	14	12	11	9	16	8	7	17	3	20	13	18	19	5
81	1	4	2	6	7	5	8	12	14	18	19	9	13	3	10	17	20	11	16	15
82	1	6	2	10	4	5	12	13	17	20	16	11	8	7	9	19	18	15	14	3
83	1	7	2	8	10	4	9	13	11	14	17	18	6	12	5	20	19	16	15	3
84	3	4	1	7	5	6	17	13	19	14	18	10	9	12	11	20	8	16	15	2
85	1	2	3	6	20	4	8	10	9	13	18	12	7	11	14	17	19	16	5	15
86	2	5	3	16	4	18	14	8	12	13	19	6	11	7	9	20	10	15	17	1
87	1	7	3	4	6	2	5	15	16	17	12	9	10	18	11	19	20	8	13	14
88	1	7	4	10	8	6	13	9	20	2	18	12	3	5	15	17	19	14	16	11
89	1	4	2	5	8	3	7	15	9	16	20	11	19	18	10	17	12	13	14	6
90	1	20	3	2	5	11	6	12	14	18	13	9	8	16	7	10	19	15	17	4

91	2	3	8	4	5	7	16	14	6	13	12	10	9	15	11	20	17	19	18	1
92	1	5	2	4	12	14	16	8	9	17	19	10	6	11	13	15	20	18	7	3
93	2	20	5	7	4	3	8	14	12	6	19	11	9	16	10	13	18	15	17	1
94	1	11	7	5	3	2	4	12	15	9	18	6	14	17	8	20	13	16	19	10
95	1	6	3	2	7	5	11	17	15	14	10	13	19	8	12	20	18	9	16	4
96	2	4	3	7	20	8	6	9	16	14	18	13	5	12	17	19	10	15	11	1
97	1	3	4	8	7	10	5	12	6	19	15	11	13	16	9	20	18	17	14	2
98	1	3	4	5	7	10	15	6	17	18	16	9	13	8	14	12	20	11	19	2
99	1	6	3	11	5	9	10	19	17	18	15	8	7	4	12	13	16	14	20	2
100	1	14	3	9	5	6	7	13	12	8	20	11	4	10	18	17	19	15	16	2
Mediana	1	5	3	8	6,5	5	10	14	12	13	18	10	9	11	11	20	17	16	16	5
Mínimo	1	1	1	2	3	2	3	6	3	2	9	3	3	1	2	9	4	8	5	1
Máximo	3	20	14	19	20	19	20	20	20	20	20	18	20	19	20	20	20	20	20	18

Tabela A3 – Distância dos Resultados ao Ponto Ótimo

Repetição	Número de Variáveis Adicionadas ao Subconjunto																			
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	0,95	0,59	0,69	1,00	0,73	0,82	0,97	1,00	0,60	0,52	0,73	0,63	0,77	0,76	0,64	0,68	0,94	0,84	0,92	0,94
2	0,72	0,94	0,92	0,99	0,83	0,73	0,77	1,00	0,77	0,66	1,00	1,00	0,93	0,71	0,65	0,88	0,76	0,93	0,74	0,69
3	0,97	0,69	0,83	0,98	0,65	0,84	0,81	0,66	0,80	0,92	0,72	0,57	0,65	0,96	0,82	1,00	0,65	0,81	0,66	0,70
4	0,60	1,00	0,94	0,78	0,90	0,55	0,99	0,59	0,76	0,85	1,00	0,66	0,78	0,66	0,88	0,74	0,70	0,84	1,00	0,95
5	0,65	1,00	0,88	0,98	0,64	0,84	0,68	1,00	0,63	0,73	0,98	0,94	0,82	1,00	0,69	0,76	0,85	0,89	0,65	0,64
6	0,59	0,63	1,00	0,84	1,00	0,96	0,95	0,85	0,87	1,00	0,82	1,00	0,55	0,72	0,96	0,66	0,85	0,86	1,00	0,59
7	0,96	0,65	0,60	0,80	0,81	0,64	0,98	1,00	1,00	1,00	0,50	0,89	0,76	0,75	0,69	0,72	0,83	0,72	0,95	0,66
8	1,00	0,61	0,97	0,97	0,82	1,00	0,80	0,69	0,99	0,64	0,95	0,57	0,57	0,92	1,00	0,75	0,62	0,87	0,82	0,66
9	0,97	0,61	0,67	1,00	0,64	0,87	0,68	1,00	0,90	0,60	0,73	1,00	0,82	0,60	0,60	1,00	0,90	0,65	0,93	0,96
10	1,00	0,67	0,97	1,00	0,69	1,00	0,84	0,66	0,66	0,96	0,65	0,85	0,71	0,90	0,70	0,90	0,72	0,90	0,77	0,69
11	0,67	1,00	0,87	1,00	0,66	0,98	0,68	0,73	0,95	0,67	0,96	0,79	0,71	0,66	0,65	0,83	0,89	1,00	0,92	0,68
12	0,65	0,97	0,59	0,74	1,00	0,69	0,75	0,72	1,00	0,95	0,95	0,97	0,89	0,86	0,73	0,86	0,58	0,66	0,65	0,80
13	0,58	0,96	1,00	0,76	0,81	0,55	0,97	1,00	0,80	1,00	0,72	0,84	0,90	0,95	0,63	0,64	0,66	0,88	1,00	0,55
14	0,63	0,94	1,00	0,73	0,74	0,77	1,00	1,00	1,00	0,98	0,87	0,72	0,92	0,62	0,95	0,92	0,89	0,80	0,83	0,63
15	0,65	1,00	0,81	1,00	0,88	0,96	0,98	0,81	0,70	1,00	0,99	0,85	0,63	0,90	0,64	0,69	0,59	0,91	0,66	1,00
16	0,69	0,93	1,00	0,67	0,84	0,96	0,81	1,00	0,63	0,74	1,00	0,61	0,71	1,00	0,75	1,00	0,85	0,85	0,95	0,94
17	0,68	0,99	1,00	0,72	1,00	0,99	0,76	0,69	0,72	1,00	1,00	0,74	0,91	0,82	0,66	0,69	0,82	0,81	0,91	0,72
18	0,70	1,00	0,96	0,86	0,79	1,00	0,96	0,66	0,69	0,76	0,60	0,71	0,61	0,91	1,00	0,69	0,69	0,77	0,81	0,90
19	0,63	0,97	1,00	1,00	1,00	0,81	1,00	1,00	0,96	0,78	1,00	0,74	0,59	0,50	0,93	0,82	1,00	0,89	0,70	0,61
20	0,65	0,94	0,83	0,73	0,85	0,81	0,94	0,83	0,69	0,75	0,92	1,00	0,63	0,64	0,66	0,96	0,62	0,74	0,66	0,90
21	0,62	1,00	0,77	0,96	0,94	0,70	0,64	1,00	0,59	0,71	0,66	0,86	0,94	1,00	1,00	0,79	0,79	0,72	0,90	0,63
22	0,70	0,80	1,00	0,68	0,96	0,96	0,67	1,00	0,70	1,00	0,69	0,93	0,64	0,67	0,84	0,72	0,69	0,96	0,77	1,00
23	0,67	1,00	0,98	0,97	0,79	0,79	0,62	0,72	0,51	0,62	0,79	0,67	0,95	0,97	0,71	0,82	1,00	0,76	0,94	1,00
24	0,74	0,95	0,66	1,00	0,78	0,98	0,61	0,79	1,00	0,73	0,89	0,93	1,00	0,95	0,56	0,92	0,88	0,67	1,00	0,70
25	0,65	0,97	0,70	0,69	0,91	1,00	0,82	0,97	0,62	0,95	0,68	1,00	0,65	0,73	0,61	0,94	0,89	0,88	0,63	0,92
26	0,95	0,64	0,98	0,72	1,00	1,00	0,75	1,00	0,93	0,87	0,62	1,00	0,58	0,68	0,95	0,86	0,83	0,70	0,93	0,66
27	0,70	1,00	0,69	0,96	1,00	0,83	0,66	1,00	0,65	1,00	1,00	0,72	0,68	1,00	0,80	0,83	0,94	0,71	0,73	0,89
28	0,64	0,71	1,00	0,99	1,00	1,00	0,68	0,65	0,94	1,00	0,79	1,00	0,94	1,00	0,80	0,83	0,66	0,91	1,00	0,64

29	0,68	0,84	0,99	0,99	0,72	0,96	0,90	0,89	0,90	1,00	1,00	1,00	0,93	0,80	0,97	0,68	1,00	0,92	0,66	0,80
30	0,65	1,00	0,85	1,00	0,99	0,72	0,60	0,66	0,64	0,80	0,91	0,96	0,78	0,94	0,66	0,89	1,00	1,00	0,82	0,57
31	0,63	1,00	0,77	0,96	0,70	0,66	0,82	0,71	0,97	0,94	1,00	0,61	0,65	0,90	0,77	0,70	1,00	1,00	0,89	0,68
32	0,63	0,95	0,80	0,97	0,67	0,69	1,00	0,64	0,77	0,70	1,00	0,71	1,00	0,70	0,62	0,67	0,66	0,77	0,92	0,91
33	0,69	1,00	0,98	0,76	0,68	0,84	0,94	0,70	0,68	0,83	0,88	1,00	1,00	0,77	0,91	0,86	1,00	0,68	0,96	0,65
34	0,58	1,00	0,65	0,84	0,99	0,97	1,00	0,83	0,93	0,73	1,00	0,70	0,83	0,92	0,65	0,55	0,74	0,96	0,66	1,00
35	0,56	0,99	0,97	0,70	0,62	0,74	0,81	0,82	1,00	1,00	0,99	0,68	0,56	0,91	1,00	0,88	0,77	0,71	0,83	0,90
36	0,69	1,00	0,65	0,89	0,93	0,68	1,00	0,98	0,93	0,91	0,79	0,84	0,62	0,72	0,75	0,59	0,89	0,89	1,00	0,63
37	0,68	0,78	0,66	0,94	0,86	0,97	0,99	0,98	0,74	0,96	1,00	0,83	1,00	1,00	0,66	0,84	0,65	1,00	0,90	0,65
38	0,62	0,69	0,99	0,84	0,60	1,00	1,00	0,96	0,82	0,65	0,67	0,59	0,62	0,74	0,90	0,70	0,96	0,69	0,94	0,71
39	0,69	1,00	0,65	0,83	0,71	0,68	1,00	0,98	0,64	0,72	0,95	0,72	0,95	1,00	0,87	0,75	0,76	0,89	1,00	0,67
40	0,66	1,00	1,00	0,62	0,83	1,00	0,84	1,00	0,99	0,96	0,97	0,79	0,58	0,91	0,89	0,59	0,71	1,00	0,85	0,57
41	0,61	1,00	0,71	0,81	0,99	0,64	0,83	1,00	0,96	0,92	0,60	0,69	1,00	1,00	0,84	0,83	0,75	0,64	0,68	0,94
42	0,64	0,96	0,70	0,56	0,83	0,89	0,72	0,58	0,98	0,71	0,54	1,00	0,92	0,60	1,00	0,90	0,71	0,70	0,94	0,69
43	0,63	1,00	0,98	0,95	0,60	0,73	0,63	0,61	1,00	0,87	0,58	0,94	0,74	0,72	0,67	0,97	0,91	0,90	1,00	0,62
44	1,00	0,67	0,67	0,79	0,97	0,70	0,74	0,94	0,64	0,93	0,96	0,75	0,76	0,80	0,63	0,96	0,83	1,00	1,00	0,71
45	0,66	0,94	1,00	0,98	1,00	1,00	0,89	1,00	0,67	0,73	0,90	0,65	1,00	0,68	0,71	0,72	0,87	0,92	0,74	0,69
46	0,63	0,78	0,96	0,98	0,70	0,70	0,82	0,52	0,75	0,66	0,96	0,93	0,74	0,80	0,89	1,00	0,80	0,76	0,92	0,72
47	0,65	1,00	1,00	0,77	0,74	0,75	0,79	1,00	0,89	0,63	0,72	0,96	0,94	0,88	0,95	0,70	0,65	0,75	0,66	0,93
48	0,94	0,67	0,90	0,70	0,97	0,66	1,00	0,98	0,75	1,00	0,93	0,84	0,66	0,75	0,90	0,65	1,00	1,00	0,63	1,00
49	0,57	1,00	1,00	0,87	0,64	0,72	1,00	0,75	0,52	0,67	0,76	0,70	0,98	0,89	0,93	0,65	1,00	0,99	0,87	0,66
50	0,62	1,00	1,00	0,65	0,84	0,96	0,91	0,94	1,00	0,86	0,72	0,66	0,60	0,84	0,71	0,68	0,65	0,82	0,93	0,90
51	0,69	1,00	0,72	1,00	0,95	0,98	0,94	0,72	0,86	0,68	0,73	1,00	0,64	0,67	0,66	0,89	0,87	0,91	0,68	1,00
52	0,62	0,99	0,70	1,00	1,00	0,60	0,60	0,84	0,64	0,95	0,93	0,73	0,98	0,71	0,91	0,75	0,77	0,85	1,00	0,67
53	0,67	1,00	0,66	0,66	0,98	0,92	1,00	0,80	1,00	1,00	1,00	0,95	0,65	1,00	0,64	0,95	0,86	0,76	0,65	0,93
54	0,62	0,75	1,00	0,69	1,00	0,74	0,98	0,97	0,94	0,83	0,62	1,00	0,61	0,83	0,76	0,73	0,88	0,63	0,65	0,90
55	0,60	0,75	1,00	0,78	0,99	0,64	1,00	0,97	0,80	1,00	0,70	1,00	0,58	1,00	1,00	0,83	0,69	0,92	0,90	0,67
56	0,69	1,00	1,00	0,75	0,86	0,97	0,71	0,73	0,83	0,63	0,94	0,78	0,79	0,92	0,79	0,75	1,00	1,00	0,93	0,76
57	0,67	0,77	0,87	0,75	0,71	0,68	0,98	0,55	0,84	0,96	0,70	0,91	0,63	0,72	0,80	0,82	0,94	0,82	0,71	0,64
58	0,58	0,79	0,67	0,96	0,65	0,68	0,82	0,71	0,53	0,65	0,98	0,95	0,65	0,96	0,86	1,00	0,83	0,87	0,78	0,94
59	0,95	0,62	1,00	0,93	0,68	0,72	0,96	0,78	0,66	0,82	0,65	0,69	0,83	0,60	0,75	0,91	0,93	0,84	0,69	0,71

60	0,67	0,83	1,00	0,99	0,84	0,76	0,73	0,69	0,70	0,89	0,82	0,94	0,64	0,87	0,70	0,87	1,00	0,72	0,94	0,70
61	0,61	1,00	0,69	0,96	0,68	0,69	0,96	0,77	0,85	0,82	0,85	0,59	0,72	1,00	0,79	0,73	0,90	0,74	0,90	0,69
62	0,69	0,68	0,80	0,70	0,97	0,83	0,76	1,00	0,99	0,68	0,78	0,62	1,00	0,64	0,62	0,71	0,95	0,88	0,94	0,66
63	0,63	0,57	0,94	1,00	0,68	0,70	1,00	0,80	0,56	0,67	1,00	0,64	1,00	0,98	0,71	0,84	0,96	0,93	0,71	0,84
64	0,66	0,97	0,70	0,85	0,70	1,00	0,82	1,00	0,80	0,99	0,75	0,70	0,89	1,00	0,93	0,79	0,78	1,00	0,65	0,83
65	0,64	0,66	0,93	0,90	0,71	0,80	0,82	0,87	0,96	0,68	0,62	0,94	0,67	0,91	0,98	0,68	0,75	0,82	0,67	0,65
66	0,70	0,97	0,66	1,00	1,00	0,77	0,97	0,84	0,69	0,96	0,79	0,78	1,00	0,91	0,90	1,00	0,73	0,66	0,80	0,89
67	0,65	1,00	1,00	1,00	0,75	1,00	0,90	0,62	0,57	0,61	0,98	0,72	1,00	0,96	0,83	0,86	0,92	0,67	0,76	0,82
68	0,61	1,00	1,00	1,00	0,97	0,80	0,61	0,67	0,82	0,54	0,75	0,92	0,73	0,95	0,92	1,00	0,83	0,70	0,92	
69	0,64	0,93	0,66	0,97	0,79	0,64	0,66	0,85	1,00	1,00	0,60	0,91	0,74	1,00	0,99	0,72	0,68	0,82	0,92	0,66
70	0,64	1,00	1,00	0,73	0,99	0,99	1,00	0,75	0,83	0,90	0,81	0,79	1,00	0,70	0,97	0,67	0,62	0,92	0,86	0,80
71	0,69	1,00	0,79	1,00	1,00	1,00	0,78	0,64	0,92	0,95	1,00	0,61	1,00	0,99	0,94	0,71	0,67	0,80	0,78	0,68
72	0,65	1,00	0,71	0,98	0,78	1,00	1,00	0,83	0,95	0,68	0,87	0,66	1,00	1,00	0,75	0,67	0,62	0,88	0,91	0,69
73	0,66	0,91	0,73	1,00	0,75	0,96	1,00	1,00	1,00	0,78	0,98	0,67	0,94	0,61	1,00	0,84	0,68	0,92	0,77	0,66
74	0,96	0,66	1,00	0,99	0,66	0,98	0,87	0,80	1,00	1,00	0,72	1,00	0,64	1,00	0,93	0,79	0,83	0,89	0,66	
75	0,96	0,64	0,70	0,63	0,99	0,99	1,00	0,65	0,71	0,82	0,65	0,59	1,00	1,00	0,93	0,87	0,67	1,00	0,90	0,68
76	0,69	0,84	1,00	0,66	0,95	0,95	0,83	0,91	1,00	0,74	0,81	1,00	0,65	0,93	0,72	0,80	1,00	0,67	0,91	0,71
77	0,60	1,00	0,60	1,00	0,62	0,98	0,98	0,67	0,82	1,00	0,64	0,60	0,72	0,90	0,73	0,96	0,78	0,73	0,86	0,93
78	0,61	0,88	0,84	1,00	0,79	1,00	0,96	0,52	0,95	1,00	0,96	0,76	0,77	0,91	1,00	0,64	0,79	0,93	0,68	0,65
79	0,60	0,84	1,00	0,83	1,00	0,60	0,62	0,69	0,72	0,98	0,77	0,95	0,94	0,83	0,88	0,65	0,56	0,92	1,00	0,62
80	0,65	1,00	0,60	0,77	1,00	0,68	0,82	1,00	0,75	0,73	0,78	0,94	0,79	1,00	0,99	0,90	0,59	0,90	0,76	0,69
81	0,69	1,00	0,67	0,62	0,85	0,95	0,97	1,00	1,00	0,90	0,90	0,82	0,61	0,96	0,73	0,71	0,58	0,89	1,00	
82	0,62	1,00	0,96	0,97	0,98	0,62	0,62	0,81	1,00	1,00	0,69	1,00	0,92	0,71	0,92	0,89	0,68	0,71	0,59	0,61
83	0,66	1,00	0,96	0,82	0,64	0,83	0,66	0,84	0,73	0,95	0,64	1,00	0,94	1,00	0,76	0,92	0,90	0,83	0,79	0,65
84	1,00	0,95	0,66	0,62	1,00	0,85	0,75	0,74	0,78	0,70	0,61	1,00	0,96	1,00	0,76	0,85	0,64	0,91	1,00	0,61
85	0,69	0,65	1,00	0,92	0,72	0,65	0,82	1,00	0,64	0,92	1,00	0,96	0,70	0,70	0,95	0,78	0,64	0,94	0,76	0,98
86	0,97	0,60	1,00	0,99	0,65	0,72	1,00	0,93	1,00	1,00	0,88	1,00	0,65	0,66	0,82	0,54	0,78	0,81	0,91	0,69
87	0,66	0,82	1,00	1,00	1,00	0,99	0,63	0,77	0,94	0,80	0,61	0,97	0,73	0,94	0,97	0,72	0,70	1,00	0,71	1,00
88	0,65	0,61	0,80	1,00	0,71	0,92	0,67	0,99	0,97	0,92	0,94	0,72	1,00	0,90	0,77	0,72	0,55	0,95	1,00	1,00
89	0,64	1,00	1,00	0,62	0,91	0,97	0,65	1,00	0,62	1,00	1,00	1,00	0,86	0,76	0,94	0,62	0,59	1,00	0,83	0,93
90	0,73	1,00	1,00	1,00	0,96	0,65	1,00	0,84	0,68	0,70	0,95	1,00	0,91	1,00	0,81	0,62	0,71	1,00	1,00	0,64

91	0,93	0,61	0,63	1,00	0,99	1,00	0,87	0,82	0,80	0,70	0,66	0,92	1,00	0,89	0,60	0,70	0,76	0,72	0,82	0,71
92	0,58	0,81	0,96	0,78	0,69	0,78	0,78	0,96	0,74	0,72	0,57	0,98	0,62	0,93	0,70	1,00	0,64	0,90	0,87	1,00
93	0,97	0,65	0,85	0,96	1,00	0,66	0,91	1,00	0,80	0,65	0,96	0,74	0,63	0,91	0,91	1,00	0,67	0,69	0,94	0,74
94	0,68	0,76	0,98	0,66	0,78	0,71	1,00	1,00	0,67	0,97	0,64	0,91	1,00	0,84	0,79	0,86	0,77	0,92	0,69	0,69
95	0,70	0,76	1,00	0,94	0,82	0,68	0,98	0,71	0,90	0,91	0,67	0,66	0,71	0,68	1,00	0,69	0,93	0,74	0,79	0,70
96	0,96	0,65	1,00	0,66	0,80	0,66	0,61	0,85	0,94	1,00	0,74	0,59	0,70	0,64	0,88	1,00	1,00	0,91	0,92	0,99
97	0,67	0,95	0,76	1,00	1,00	1,00	0,98	1,00	1,00	0,76	0,75	0,94	0,79	0,66	0,91	1,00	0,89	0,72	1,00	0,68
98	0,67	0,96	0,83	1,00	1,00	0,96	0,99	1,00	0,70	0,81	0,85	0,62	0,84	0,62	0,74	0,93	1,00	0,83	0,65	0,85
99	0,61	0,96	0,61	1,00	0,98	0,64	0,80	1,00	0,77	0,72	0,93	0,59	0,71	0,86	0,97	0,72	1,00	0,72	0,91	0,77
100	0,60	0,95	1,00	0,85	0,96	0,92	1,00	0,65	0,88	1,00	0,69	0,65	0,93	0,69	0,84	0,72	0,56	0,60	1,00	0,91

## APÊNDICE B – Resultados do Australian Credit Approval

Tabela B1 – Índice de Importância das Variáveis

Repetição	Variável													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0,00	0,00	0,01	0,00	0,00	0,00	0,06	0,69	0,12	0,12	0,00	0,00	0,00	0,00
2	0,00	0,00	0,00	0,00	0,01	0,00	0,02	0,72	0,09	0,15	0,00	0,00	0,00	0,00
3	0,00	0,00	0,00	0,00	0,01	0,00	0,02	0,76	0,06	0,15	0,00	0,00	0,01	0,00
4	0,00	0,00	0,00	0,00	0,04	0,00	0,05	0,72	0,05	0,14	0,00	0,00	0,00	0,00
5	0,00	0,00	0,00	0,00	0,02	0,00	0,03	0,71	0,15	0,08	0,00	0,00	0,00	0,01
6	0,00	0,00	0,00	0,00	0,04	0,00	0,02	0,76	0,06	0,12	0,00	0,00	0,00	0,00
7	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,83	0,09	0,05	0,00	0,00	0,00	0,00
8	0,00	0,00	0,00	0,00	0,03	0,00	0,06	0,74	0,06	0,11	0,00	0,00	0,00	0,00
9	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,73	0,13	0,14	0,00	0,00	0,00	0,00
10	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,80	0,11	0,10	0,00	0,00	0,00	0,00
11	0,00	0,00	0,00	0,00	0,03	0,00	0,05	0,70	0,04	0,13	0,00	0,00	0,00	0,04
12	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,85	0,05	0,10	0,00	0,00	0,00	0,00
13	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,77	0,12	0,10	0,00	0,00	0,00	0,00
14	0,00	0,00	0,00	0,00	0,03	0,00	0,00	0,66	0,06	0,25	0,00	0,00	0,00	0,00
15	0,00	0,00	0,00	0,00	0,01	0,00	0,02	0,65	0,15	0,16	0,00	0,00	0,00	0,00
16	0,00	0,00	0,00	0,00	0,03	0,00	0,03	0,72	0,08	0,15	0,00	0,00	0,00	0,00
17	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,69	0,12	0,16	0,00	0,00	0,00	0,00
18	0,00	0,00	0,00	0,00	0,01	0,00	0,06	0,77	0,05	0,11	0,00	0,00	0,00	0,00
19	0,00	0,00	0,00	0,00	0,05	0,00	0,00	0,74	0,08	0,10	0,00	0,00	0,01	0,01
20	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,83	0,00	0,16	0,00	0,00	0,00	0,00
21	0,00	0,00	0,00	0,00	0,00	0,00	0,05	0,64	0,15	0,16	0,00	0,00	0,02	0,00
22	0,00	0,00	0,00	0,00	0,01	0,00	0,02	0,79	0,06	0,11	0,00	0,00	0,00	0,00
23	0,00	0,00	0,00	0,00	0,03	0,00	0,03	0,65	0,10	0,19	0,00	0,00	0,00	0,00
24	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,91	0,02	0,06	0,00	0,00	0,00	0,00

25	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,83	0,05	0,11	0,00	0,00	0,00	0,00
26	0,00	0,00	0,00	0,00	0,00	0,00	0,05	0,78	0,08	0,09	0,00	0,00	0,00	0,00
27	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,77	0,10	0,09	0,00	0,00	0,00	0,00
28	0,00	0,00	0,00	0,00	0,01	0,00	0,05	0,75	0,07	0,13	0,00	0,00	0,00	0,00
29	0,00	0,00	0,00	0,00	0,04	0,00	0,00	0,71	0,09	0,15	0,00	0,00	0,00	0,00
30	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,87	0,00	0,13	0,00	0,00	0,00	0,00
31	0,00	0,00	0,00	0,00	0,02	0,00	0,03	0,77	0,06	0,11	0,00	0,00	0,00	0,00
32	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,71	0,13	0,15	0,00	0,00	0,00	0,00
33	0,00	0,00	0,00	0,00	0,04	0,00	0,02	0,72	0,11	0,11	0,00	0,00	0,00	0,00
34	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,75	0,14	0,10	0,00	0,00	0,00	0,00
35	0,00	0,00	0,00	0,00	0,03	0,00	0,00	0,81	0,07	0,09	0,00	0,00	0,00	0,00
36	0,00	0,00	0,00	0,00	0,03	0,00	0,00	0,82	0,05	0,10	0,00	0,00	0,00	0,00
37	0,00	0,00	0,00	0,00	0,02	0,00	0,08	0,81	0,04	0,05	0,00	0,00	0,00	0,00
38	0,00	0,00	0,00	0,00	0,05	0,00	0,02	0,69	0,10	0,10	0,00	0,00	0,02	0,00
39	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,77	0,12	0,06	0,00	0,00	0,02	0,00
40	0,00	0,00	0,00	0,00	0,01	0,00	0,03	0,76	0,06	0,14	0,00	0,00	0,00	0,00
41	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,86	0,06	0,06	0,00	0,00	0,00	0,00
42	0,00	0,00	0,00	0,00	0,02	0,00	0,03	0,89	0,00	0,07	0,00	0,00	0,00	0,00
43	0,00	0,00	0,00	0,00	0,02	0,00	0,03	0,73	0,13	0,08	0,00	0,00	0,00	0,00
44	0,00	0,00	0,00	0,00	0,04	0,00	0,04	0,78	0,00	0,14	0,00	0,00	0,00	0,00
45	0,00	0,00	0,00	0,00	0,05	0,00	0,02	0,78	0,05	0,09	0,00	0,00	0,00	0,00
46	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,82	0,06	0,12	0,00	0,00	0,00	0,00
47	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,91	0,01	0,06	0,00	0,00	0,00	0,00
48	0,00	0,00	0,00	0,00	0,03	0,00	0,00	0,81	0,01	0,15	0,00	0,00	0,00	0,00
49	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,72	0,15	0,09	0,00	0,00	0,02	0,00
50	0,00	0,00	0,00	0,00	0,03	0,02	0,02	0,68	0,15	0,10	0,00	0,00	0,00	0,00
51	0,00	0,00	0,00	0,00	0,03	0,00	0,03	0,65	0,18	0,10	0,00	0,00	0,00	0,00
52	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,77	0,05	0,16	0,00	0,00	0,00	0,00
53	0,00	0,00	0,00	0,00	0,01	0,00	0,01	0,80	0,00	0,19	0,00	0,00	0,00	0,00
54	0,00	0,00	0,00	0,00	0,03	0,00	0,01	0,72	0,13	0,11	0,00	0,00	0,00	0,00
55	0,00	0,00	0,00	0,00	0,02	0,00	0,07	0,67	0,14	0,09	0,00	0,00	0,01	0,00

56	0,00	0,00	0,00	0,00	0,04	0,00	0,00	0,84	0,02	0,09	0,00	0,00	0,00	0,00
57	0,00	0,00	0,00	0,00	0,01	0,00	0,03	0,81	0,09	0,05	0,00	0,00	0,00	0,00
58	0,00	0,00	0,00	0,00	0,03	0,00	0,01	0,73	0,13	0,10	0,00	0,00	0,00	0,00
59	0,00	0,00	0,00	0,00	0,03	0,00	0,00	0,65	0,22	0,10	0,00	0,00	0,00	0,00
60	0,00	0,00	0,00	0,00	0,02	0,00	0,04	0,78	0,03	0,13	0,00	0,00	0,00	0,00
61	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,78	0,06	0,15	0,00	0,00	0,00	0,00
62	0,00	0,00	0,00	0,00	0,01	0,00	0,02	0,81	0,08	0,08	0,00	0,00	0,00	0,00
63	0,00	0,00	0,00	0,00	0,02	0,00	0,03	0,77	0,07	0,12	0,00	0,00	0,00	0,00
64	0,00	0,00	0,00	0,00	0,03	0,00	0,01	0,77	0,08	0,11	0,00	0,00	0,00	0,00
65	0,00	0,00	0,00	0,00	0,01	0,00	0,03	0,81	0,08	0,06	0,00	0,00	0,00	0,00
66	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,86	0,01	0,11	0,00	0,00	0,00	0,00
67	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,73	0,11	0,13	0,00	0,00	0,00	0,01
68	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,83	0,03	0,12	0,00	0,00	0,02	0,00
69	0,00	0,00	0,00	0,00	0,01	0,00	0,03	0,63	0,22	0,12	0,00	0,00	0,00	0,00
70	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,90	0,00	0,10	0,00	0,00	0,00	0,00
71	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,80	0,08	0,10	0,00	0,00	0,00	0,00
72	0,00	0,00	0,00	0,00	0,03	0,00	0,04	0,72	0,07	0,13	0,00	0,00	0,01	0,00
73	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,83	0,07	0,06	0,00	0,00	0,01	0,00
74	0,00	0,00	0,00	0,00	0,02	0,00	0,02	0,80	0,02	0,14	0,00	0,00	0,00	0,00
75	0,00	0,00	0,00	0,00	0,04	0,00	0,02	0,77	0,03	0,15	0,00	0,00	0,00	0,00
76	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,83	0,03	0,12	0,00	0,00	0,00	0,00
77	0,00	0,00	0,00	0,00	0,02	0,00	0,04	0,81	0,03	0,10	0,00	0,00	0,00	0,00
78	0,00	0,00	0,00	0,00	0,01	0,00	0,02	0,69	0,15	0,12	0,00	0,00	0,00	0,00
79	0,00	0,00	0,00	0,00	0,03	0,00	0,02	0,84	0,06	0,05	0,00	0,00	0,00	0,00
80	0,00	0,00	0,00	0,00	0,04	0,00	0,03	0,68	0,16	0,08	0,00	0,00	0,01	0,00
81	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,79	0,12	0,09	0,00	0,00	0,00	0,00
82	0,00	0,00	0,00	0,00	0,00	0,00	0,08	0,69	0,07	0,15	0,00	0,00	0,00	0,00
83	0,00	0,00	0,00	0,00	0,04	0,00	0,05	0,82	0,03	0,06	0,00	0,00	0,00	0,00
84	0,00	0,00	0,00	0,00	0,01	0,00	0,08	0,76	0,06	0,08	0,00	0,00	0,01	0,00
85	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,77	0,07	0,15	0,00	0,00	0,00	0,00
86	0,00	0,00	0,00	0,00	0,03	0,01	0,00	0,73	0,14	0,10	0,00	0,00	0,00	0,00

87	0,00	0,00	0,00	0,00	0,01	0,00	0,03	0,77	0,01	0,18	0,00	0,00	0,00	0,00
88	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,85	0,00	0,14	0,00	0,00	0,00	0,00
89	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,84	0,07	0,07	0,00	0,00	0,00	0,00
90	0,00	0,00	0,00	0,00	0,03	0,00	0,05	0,70	0,08	0,14	0,00	0,00	0,00	0,00
91	0,00	0,00	0,00	0,00	0,01	0,00	0,01	0,82	0,08	0,08	0,00	0,00	0,00	0,00
92	0,00	0,00	0,00	0,00	0,02	0,00	0,00	0,72	0,05	0,22	0,00	0,00	0,00	0,00
93	0,00	0,00	0,00	0,00	0,02	0,00	0,04	0,70	0,05	0,19	0,00	0,00	0,00	0,00
94	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,74	0,10	0,13	0,00	0,00	0,00	0,00
95	0,00	0,00	0,00	0,00	0,05	0,00	0,00	0,75	0,07	0,13	0,00	0,00	0,00	0,00
96	0,00	0,00	0,00	0,00	0,03	0,00	0,00	0,80	0,00	0,15	0,00	0,00	0,00	0,03
97	0,00	0,00	0,00	0,00	0,01	0,00	0,01	0,83	0,03	0,12	0,00	0,00	0,00	0,00
98	0,00	0,00	0,00	0,00	0,01	0,00	0,03	0,65	0,13	0,17	0,00	0,00	0,00	0,00
99	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,86	0,02	0,12	0,00	0,00	0,00	0,00
100	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,77	0,08	0,14	0,00	0,00	0,00	0,00
Média	0,00	0,00	0,00	0,00	0,02	0,00	0,02	0,77	0,08	0,12	0,00	0,00	0,00	0,00
Desv. Pad	0,00	0,00	0,00	0,00	0,01	0,00	0,02	0,07	0,05	0,04	0,00	0,00	0,01	0,01

Tabela B2 – Ranking das Variáveis

Repetição	Variável													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	11	10	5	7	6	12	4	1	3	2	14	13	8	9
2	13	12	10	9	5	8	4	1	3	2	14	11	6	7
3	14	7	11	10	6	9	4	1	3	2	13	12	5	8
4	12	13	10	7	5	8	3	1	4	2	11	14	6	9
5	13	11	10	9	5	8	4	1	2	3	14	12	7	6
6	14	11	8	9	4	10	5	1	3	2	12	13	6	7
7	12	9	8	11	4	10	7	1	2	3	13	14	5	6
8	13	10	7	6	5	11	3	1	4	2	14	12	8	9
9	14	4	11	10	7	8	6	1	3	2	13	12	5	9
10	13	8	11	9	4	7	5	1	2	3	14	12	6	10
11	12	14	9	10	6	11	3	1	5	2	13	8	7	4
12	13	12	9	10	4	8	5	1	3	2	14	11	7	6
13	13	11	5	12	4	6	7	1	2	3	14	10	8	9
14	13	8	11	10	4	7	5	1	3	2	14	12	6	9
15	13	9	11	10	5	7	4	1	3	2	12	14	6	8
16	12	11	9	8	5	7	4	1	3	2	13	14	6	10
17	11	9	14	7	6	8	4	1	3	2	13	12	5	10
18	11	10	14	7	5	9	3	1	4	2	12	13	6	8
19	12	11	9	10	4	8	7	1	3	2	13	14	5	6
20	12	7	8	13	3	10	5	1	4	2	14	11	6	9
21	13	12	10	8	6	7	4	1	3	2	14	11	5	9
22	12	11	10	8	5	7	4	1	3	2	13	14	6	9
23	14	12	11	8	4	7	5	1	3	2	13	10	9	6
24	13	7	8	9	5	12	4	1	3	2	14	11	6	10
25	13	10	11	8	4	9	5	1	3	2	14	12	6	7
26	13	8	9	10	5	7	4	1	3	2	14	12	6	11
27	14	10	12	8	6	7	4	1	2	3	13	11	5	9
28	13	11	8	10	5	9	4	1	3	2	14	12	6	7

29	12	5	10	8	4	11	7	1	3	2	13	14	6	9
30	13	8	11	10	4	9	5	1	3	2	14	12	7	6
31	12	11	7	9	5	10	4	1	3	2	13	14	6	8
32	13	11	10	9	4	7	5	1	3	2	14	12	8	6
33	12	11	10	9	4	6	5	1	3	2	13	14	7	8
34	13	11	8	10	4	7	6	1	2	3	14	12	5	9
35	13	8	9	7	4	11	5	1	3	2	12	14	6	10
36	13	11	9	8	4	7	5	1	3	2	14	12	6	10
37	12	6	8	11	5	9	2	1	4	3	13	14	7	10
38	13	14	10	9	4	8	5	1	3	2	12	11	6	7
39	12	7	9	10	5	11	6	1	2	3	13	14	4	8
40	12	9	7	10	5	11	4	1	3	2	13	14	6	8
41	12	10	6	11	4	8	5	1	2	3	14	13	7	9
42	11	14	13	9	4	6	3	1	5	2	12	10	7	8
43	13	11	8	10	5	7	4	1	2	3	14	12	6	9
44	13	9	8	12	3	10	4	1	5	2	14	11	6	7
45	12	9	8	11	4	10	5	1	3	2	13	14	7	6
46	13	10	9	11	4	8	5	1	3	2	14	12	7	6
47	14	11	10	7	3	8	6	1	4	2	13	12	5	9
48	13	14	11	9	3	5	6	1	4	2	12	10	7	8
49	13	11	6	9	4	8	7	1	2	3	14	12	5	10
50	14	7	10	11	4	6	5	1	2	3	13	12	9	8
51	12	14	10	7	5	9	4	1	2	3	11	13	6	8
52	12	11	6	10	4	9	7	1	3	2	13	14	5	8
53	13	9	10	11	3	8	4	1	5	2	12	14	6	7
54	14	8	7	11	4	9	5	1	2	3	13	12	6	10
55	14	9	11	10	5	7	4	1	2	3	13	12	6	8
56	12	11	9	8	3	14	6	1	4	2	13	10	5	7
57	12	7	10	9	5	6	4	1	2	3	14	13	8	11
58	12	10	6	8	4	11	5	1	2	3	13	14	9	7
59	12	11	10	9	4	7	5	1	2	3	13	14	6	8

60	13	14	10	8	5	9	3	1	4	2	12	11	6	7
61	14	10	11	7	5	8	4	1	3	2	13	12	6	9
62	12	8	7	10	5	11	4	1	3	2	14	13	6	9
63	13	9	10	11	5	8	4	1	3	2	14	12	7	6
64	13	6	9	10	4	11	5	1	3	2	14	12	7	8
65	13	12	10	9	5	7	4	1	2	3	14	11	6	8
66	13	10	7	9	6	8	3	1	4	2	14	12	5	11
67	13	11	7	9	6	12	5	1	3	2	14	10	8	4
68	13	9	8	7	5	10	6	1	3	2	12	14	4	11
69	13	11	9	7	5	6	4	1	2	3	14	12	10	8
70	12	14	7	9	3	10	4	1	6	2	13	11	5	8
71	14	9	10	11	4	8	5	1	3	2	13	12	6	7
72	14	7	11	9	5	8	4	1	3	2	13	12	6	10
73	12	8	6	9	4	11	7	1	2	3	13	14	5	10
74	13	11	6	10	4	7	5	1	3	2	14	12	9	8
75	14	12	8	11	3	9	5	1	4	2	13	10	6	7
76	13	7	10	11	6	9	4	1	3	2	12	14	5	8
77	14	7	10	11	5	9	3	1	4	2	13	12	6	8
78	14	12	9	10	5	6	4	1	2	3	13	11	7	8
79	13	9	7	10	4	11	5	1	2	3	14	12	8	6
80	13	7	11	9	4	8	5	1	2	3	12	14	6	10
81	12	10	6	9	5	8	7	1	2	3	13	14	4	11
82	13	10	11	8	5	7	3	1	4	2	12	14	6	9
83	11	13	14	7	4	8	3	1	5	2	10	12	6	9
84	12	11	7	9	5	10	3	1	4	2	13	14	6	8
85	12	11	10	7	4	8	6	1	3	2	14	13	5	9
86	13	9	10	11	4	5	6	1	2	3	12	14	7	8
87	14	11	9	10	5	8	3	1	4	2	13	12	7	6
88	12	8	10	9	5	11	3	1	4	2	13	14	6	7
89	14	11	8	10	4	9	5	1	2	3	13	12	6	7
90	11	14	7	9	5	6	4	1	3	2	12	13	10	8

91	14	13	8	11	4	10	5	1	2	3	12	9	6	7
92	13	10	8	11	4	5	6	1	3	2	14	12	7	9
93	13	12	11	6	5	9	4	1	3	2	14	10	7	8
94	13	10	8	11	6	9	4	1	3	2	14	12	5	7
95	11	14	10	9	4	8	6	1	3	2	13	12	5	7
96	13	9	14	8	3	10	6	1	5	2	12	11	7	4
97	13	10	12	9	5	7	4	1	3	2	14	11	6	8
98	14	7	10	8	5	9	4	1	3	2	13	12	6	11
99	13	9	7	12	5	8	4	1	3	2	14	11	6	10
100	14	10	13	9	4	5	7	1	3	2	12	11	6	8
Mediana	13	10	9	9	4,5	8	4,5	1	3	2	13	12	6	8
Mínimo	11	4	5	6	3	5	2	1	2	2	10	8	4	4
Máximo	14	14	14	13	7	14	7	1	6	3	14	14	10	11

Tabela B3 – Distância dos Resultados ao Ponto Ótimo

Repetição	Número de Variáveis Adicionadas ao Subconjunto													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	1,00	0,24	0,24	1,00	0,46	1,00	0,73	0,89	0,97	0,65	0,62	1,00	0,90	0,42
2	1,00	0,21	1,00	1,00	1,00	0,90	0,98	1,00	0,77	0,50	0,75	0,66	0,66	1,00
3	0,70	0,27	0,27	1,00	0,89	1,00	0,59	1,00	1,00	0,69	0,54	0,89	1,00	0,60
4	0,70	0,23	1,00	0,23	1,00	0,87	0,92	1,00	0,98	0,54	0,40	0,63	0,65	1,00
5	0,69	0,24	0,24	1,00	1,00	0,98	0,89	1,00	0,69	0,54	0,61	0,90	0,67	0,41
6	0,70	0,23	1,00	1,00	1,00	0,89	0,99	0,51	0,79	0,91	0,64	0,40	0,90	0,55
7	1,00	0,26	0,26	1,00	0,88	0,98	1,00	0,44	0,63	1,00	0,66	0,59	0,42	1,00
8	0,72	0,22	1,00	0,22	1,00	0,79	0,50	0,87	0,99	0,63	1,00	0,88	0,67	0,38
9	1,00	0,24	0,24	0,66	0,86	1,00	1,00	1,00	0,98	0,80	0,53	0,77	0,44	0,69
10	0,99	0,24	0,24	1,00	1,00	0,88	1,00	0,62	0,66	0,99	0,48	0,89	0,62	0,44
11	0,68	0,19	1,00	0,98	1,00	1,00	0,92	1,00	0,46	0,75	1,00	0,61	0,37	0,64
12	0,69	0,28	1,00	1,00	1,00	0,98	0,87	1,00	0,51	0,83	1,00	0,60	0,64	0,42
13	0,70	0,24	0,24	1,00	0,51	0,92	1,00	0,88	0,98	0,89	0,62	0,78	0,67	0,44
14	1,00	0,21	0,21	1,00	1,00	0,86	1,00	0,62	0,99	0,76	0,52	1,00	0,66	0,38
15	1,00	0,19	0,19	1,00	1,00	0,86	1,00	0,98	0,69	0,77	0,59	0,48	0,69	1,00
16	1,00	0,23	0,23	1,00	1,00	0,89	1,00	0,73	0,54	0,97	0,65	0,59	0,38	1,00
17	0,72	0,23	1,00	1,00	0,92	1,00	0,79	1,00	0,62	1,00	0,72	0,92	0,35	0,41
18	1,00	0,23	1,00	0,23	1,00	0,87	0,76	0,99	0,73	0,62	0,71	0,38	1,00	0,50
19	1,00	0,23	0,23	1,00	0,88	0,98	1,00	1,00	0,56	0,67	0,62	0,61	0,42	0,89
20	1,00	0,25	1,00	0,25	1,00	0,86	0,66	0,57	0,98	1,00	1,00	0,61	0,59	1,00
21	1,00	0,19	0,19	1,00	0,89	1,00	1,00	0,77	1,00	0,48	1,00	0,64	0,70	1,00
22	1,00	0,24	0,24	1,00	1,00	0,86	1,00	0,57	0,99	0,49	0,59	0,65	1,00	1,00
23	0,66	0,22	0,22	1,00	1,00	0,98	1,00	0,73	0,90	0,91	0,54	0,65	0,38	0,70
24	1,00	0,24	1,00	1,00	1,00	0,88	0,70	0,49	0,59	0,99	1,00	1,00	0,75	0,40
25	1,00	0,24	0,24	1,00	1,00	0,90	0,99	1,00	0,81	0,66	0,48	1,00	0,62	0,41
26	0,74	0,25	1,00	1,00	1,00	0,89	1,00	0,68	0,56	0,71	0,99	0,80	0,68	1,00
27	0,75	0,22	0,22	1,00	0,88	1,00	1,00	0,73	0,99	0,60	0,69	0,53	0,39	0,62
28	0,71	0,23	1,00	1,00	1,00	0,88	0,98	0,54	1,00	0,68	0,58	1,00	0,63	0,40

29	0,72	0,24	0,24	1,00	0,67	0,87	1,00	0,69	0,99	0,45	0,82	0,70	0,38	0,88
30	0,72	0,27	0,27	1,00	1,00	0,99	0,86	0,58	1,00	0,74	0,53	1,00	0,57	0,38
31	1,00	0,26	1,00	1,00	1,00	0,86	0,54	0,99	1,00	0,93	0,65	0,68	0,41	1,00
32	0,73	0,22	1,00	1,00	1,00	0,98	1,00	0,88	0,66	0,49	0,60	0,89	0,69	0,39
33	0,68	0,20	0,20	0,65	1,00	0,61	0,88	0,98	0,80	0,49	0,61	0,71	0,38	0,69
34	0,75	0,22	0,22	1,00	0,88	1,00	1,00	0,52	0,99	0,82	0,65	1,00	0,59	0,45
35	1,00	0,26	1,00	0,77	1,00	0,91	0,82	0,69	0,50	0,97	1,00	0,41	0,60	1,00
36	0,77	0,23	1,00	1,00	1,00	0,85	1,00	0,65	0,54	0,98	0,64	0,76	0,66	0,38
37	0,70	1,00	0,23	0,23	1,00	0,57	0,87	0,45	1,00	0,99	0,74	0,63	0,38	0,88
38	1,00	0,19	0,19	1,00	1,00	0,92	0,98	1,00	1,00	0,48	1,00	0,37	0,58	0,61
39	0,71	1,00	0,22	0,91	1,00	1,00	0,61	0,97	0,47	0,66	1,00	0,64	0,43	0,92
40	0,70	0,24	0,24	1,00	1,00	0,91	0,51	0,98	0,63	0,69	0,79	0,68	0,39	1,00
41	1,00	0,27	0,27	1,00	1,00	0,48	0,90	1,00	0,99	0,62	0,77	0,66	1,00	0,41
42	0,79	0,28	1,00	1,00	0,28	0,92	0,91	1,00	0,49	0,91	0,60	0,35	0,47	0,58
43	0,71	0,23	0,23	1,00	1,00	0,87	1,00	0,54	0,99	0,74	0,66	1,00	0,63	0,44
44	0,69	0,21	1,00	1,00	1,00	0,89	0,98	0,43	0,55	1,00	0,90	0,65	0,61	1,00
45	1,00	0,18	0,18	1,00	1,00	0,99	0,89	0,46	0,64	1,00	0,76	0,62	0,35	0,90
46	1,00	0,24	0,24	1,00	1,00	0,98	0,88	1,00	0,52	0,62	0,65	0,89	0,67	0,40
47	1,00	0,25	0,81	0,25	0,91	1,00	0,79	0,74	0,98	0,50	0,58	0,92	0,38	0,67
48	0,73	0,26	1,00	0,26	1,00	1,00	0,87	0,99	0,84	0,68	0,47	0,35	0,63	0,64
49	0,68	1,00	0,21	1,00	0,87	0,44	1,00	1,00	0,63	0,99	0,66	1,00	1,00	0,38
50	0,77	0,20	0,20	1,00	1,00	0,69	0,61	0,99	0,90	0,50	0,79	0,91	1,00	0,60
51	0,99	0,19	0,19	1,00	1,00	0,92	0,77	0,98	1,00	0,52	0,40	0,63	0,64	0,65
52	0,72	0,22	1,00	1,00	0,85	0,54	1,00	1,00	0,68	0,82	0,60	0,63	0,39	1,00
53	1,00	0,23	1,00	1,00	0,24	0,89	0,98	1,00	0,55	0,46	0,81	0,34	0,65	0,73
54	1,00	0,24	0,24	1,00	1,00	0,92	0,56	0,67	1,00	0,99	0,74	1,00	0,43	0,69
55	0,74	1,00	0,20	1,00	1,00	0,87	1,00	0,99	0,63	0,81	0,50	1,00	0,37	0,60
56	1,00	0,24	1,00	1,00	0,86	1,00	0,98	0,74	0,58	0,88	0,66	0,71	0,38	0,84
57	1,00	0,24	0,24	1,00	1,00	0,92	0,63	0,88	0,81	0,48	0,98	0,72	0,71	0,39
58	1,00	0,26	0,26	1,00	1,00	0,45	0,98	0,80	0,88	0,62	1,00	0,69	0,40	0,88
59	0,73	0,21	0,21	1,00	1,00	0,87	1,00	0,99	0,68	0,52	0,59	0,62	0,45	0,87

60	0,71	0,23	1,00	0,23	1,00	0,89	0,98	0,72	1,00	0,52	0,90	0,40	0,60	0,63
61	0,72	0,22	0,22	1,00	1,00	0,87	0,83	1,00	0,98	0,60	0,45	1,00	0,38	0,68
62	0,71	0,22	0,22	1,00	1,00	0,88	0,48	0,62	0,99	1,00	1,00	0,60	0,89	0,38
63	0,72	0,21	0,21	1,00	1,00	0,98	0,89	0,90	0,67	0,56	0,76	0,90	0,59	0,40
64	1,00	0,24	0,24	1,00	1,00	0,62	0,88	0,99	0,58	0,78	1,00	1,00	0,63	0,44
65	0,70	0,25	0,25	1,00	1,00	0,87	1,00	0,99	0,81	0,55	0,89	0,62	0,60	0,39
66	0,79	0,29	1,00	0,29	0,90	1,00	0,51	1,00	0,98	0,67	1,00	0,90	0,66	0,41
67	1,00	0,23	0,98	0,98	1,00	1,00	0,47	0,91	0,65	1,00	0,58	1,00	0,67	0,38
68	1,00	0,26	0,26	0,87	1,00	1,00	0,73	0,45	0,65	0,72	0,99	0,36	0,60	1,00
69	1,00	1,00	0,23	1,00	1,00	0,83	0,82	0,98	0,52	0,90	0,67	1,00	0,62	0,49
70	1,00	0,26	1,00	1,00	0,88	0,26	0,49	0,99	0,84	1,00	1,00	0,67	0,36	0,58
71	0,73	0,25	0,25	1,00	1,00	0,89	0,99	1,00	0,61	0,51	0,70	0,90	0,40	0,63
72	1,00	0,22	1,00	1,00	1,00	0,89	0,64	1,00	0,81	1,00	0,51	1,00	0,38	0,64
73	1,00	0,23	0,23	1,00	0,90	0,49	1,00	0,61	0,66	0,99	1,00	0,64	0,40	0,90
74	0,76	0,21	0,21	1,00	1,00	0,51	1,00	0,98	0,88	0,67	0,66	1,00	0,62	0,40
75	1,00	0,23	1,00	0,97	1,00	0,90	0,98	0,50	1,00	0,71	0,80	0,62	0,40	0,60
76	1,00	0,24	0,98	1,00	0,87	1,00	0,60	0,98	1,00	0,56	0,76	0,39	0,69	1,00
77	0,67	0,22	1,00	0,22	1,00	0,86	0,60	0,97	0,77	0,53	0,72	1,00	0,40	0,60
78	0,74	1,00	0,21	1,00	1,00	1,00	0,93	1,00	0,51	0,78	0,92	0,64	0,43	0,60
79	1,00	0,27	0,27	1,00	1,00	0,98	0,50	0,89	0,59	0,66	1,00	1,00	0,66	0,39
80	1,00	0,20	0,20	1,00	1,00	0,89	0,62	1,00	1,00	0,99	0,51	0,42	0,55	1,00
81	1,00	0,24	0,24	0,87	1,00	0,46	1,00	1,00	0,66	0,61	0,99	0,63	0,41	0,69
82	1,00	0,21	1,00	0,21	0,52	0,88	1,00	0,76	0,99	0,60	0,49	0,38	0,58	1,00
83	0,73	0,24	1,00	1,00	0,24	0,87	0,79	0,89	0,98	0,36	0,64	0,72	0,65	0,50
84	0,71	0,21	1,00	0,22	1,00	0,88	0,51	0,97	0,61	1,00	0,63	0,60	0,38	1,00
85	1,00	0,24	1,00	1,00	0,88	1,00	0,71	1,00	0,98	0,48	0,66	0,58	0,87	0,39
86	0,76	0,26	0,26	1,00	0,63	1,00	0,90	1,00	0,61	0,56	0,77	0,44	0,56	1,00
87	0,69	0,24	1,00	0,24	1,00	0,99	0,88	1,00	0,55	0,72	0,61	0,88	0,39	0,63
88	1,00	0,22	1,00	1,00	1,00	0,85	0,98	0,64	0,79	0,53	1,00	0,63	0,35	1,00
89	1,00	0,22	0,22	1,00	1,00	0,87	0,97	0,51	1,00	0,71	0,61	0,88	0,43	0,66
90	1,00	0,22	0,22	1,00	0,65	1,00	0,53	0,98	0,66	0,87	0,63	0,42	0,69	0,59

91	0,77	0,25	0,24	1,00	1,00	0,90	0,98	0,51	1,00	1,00	0,82	1,00	0,63	0,58
92	0,69	0,22	1,00	1,00	1,00	0,91	0,50	0,99	0,61	0,70	0,91	0,70	1,00	
93	0,77	0,21	0,21	1,00	1,00	0,75	0,86	0,98	1,00	0,88	0,51	0,60	0,68	0,40
94	0,71	0,19	0,19	1,00	0,91	1,00	0,98	0,51	0,82	0,60	0,74	1,00	0,71	0,39
95	0,71	0,23	1,00	1,00	0,86	1,00	1,00	0,73	0,93	0,49	0,58	0,88	0,41	0,68
96	1,00	0,20	1,00	0,98	0,20	1,00	0,88	0,55	0,61	1,00	0,89	0,35	0,62	0,46
97	0,75	0,22	1,00	1,00	1,00	0,88	1,00	0,98	0,71	0,62	0,88	0,54	0,61	0,37
98	0,68	0,20	0,20	1,00	1,00	0,90	0,66	0,54	1,00	0,46	1,00	0,91	0,37	0,68
99	0,72	0,25	0,25	1,00	1,00	0,89	0,52	0,95	0,58	1,00	0,89	0,78	0,63	0,38
100	0,79	0,24	0,24	1,00	1,00	0,87	1,00	0,98	0,81	0,64	1,00	1,00	0,53	0,63