

**Identificação de fraude
contra sistemas de reputação
em mercados eletrônicos**

Rafael Plana Maranzato

DISSERTAÇÃO APRESENTADA
AO
INSTITUTO DE MATEMÁTICA E ESTATÍSTICA
DA
UNIVERSIDADE DE SÃO PAULO
PARA
OBTENÇÃO DO TÍTULO
DE
MESTRE EM CIÊNCIAS

Programa: Ciência da Computação
Orientador: Prof. Dr. Alair Pereira do Lago

São Paulo, março de 2010

Identificação de fraude contra sistemas de reputação em mercados eletrônicos

Este exemplar corresponde à redação final da dissertação devidamente corrigida e defendida por Rafael Plana Maranzato e aprovada pela Comissão Julgadora.

Banca Examinadora:

- Prof. Dr. Alair Pereira do Lago (orientador) - IME-USP
- Profa. Dra. Claudia Monteiro Peixoto - IME-USP
- Prof. Dr. Wagner Meira Junior - UFMG

Agradecimentos

Primeiramente agradeço a Deus por ter me dado forças, saúde e ter colocado pessoas tão especiais na minha vida, algumas delas fundamentais para que eu concluísse este trabalho.

Um agradecimento especial à Beatriz, minha esposa, namorada, incentivadora, amiga e revisora, entre tantas outras qualidades. Esta página e muitas outras não seriam suficientes para agradecer-lhe por tudo que vivemos de bom nesses anos de relacionamento. Pouco se importou em perder feriados, finais de semanas e muitas horas em que me dedicava ao mestrado e ao trabalho no *UOL*, que ocorreram simultaneamente e de forma intensa nos últimos anos. Mais do que isso, sempre me deu forças e esteve disponível para me ajudar com muito mais do que precisava. Uma pessoa especial que representa muito na minha vida e é mais do que eu mereço. Eu não chegaria nem a metade de onde cheguei sem ela. *Muito obrigado é muito pouco pra você, Beatriz!*

Agradeço à minha família. Aos meus pais, Nelson e Maria, pela educação que me deram e principalmente pelos grandes valores morais transmitidos ao longo de toda minha vida. *Eu me orgulho de vocês dois: pai e mãe!* À minha “vó” Maria, por sempre estar ao meu lado, incentivando-me à sua maneira alegre de ser. Aos meus irmãos, Felipe e Simone por acreditarem que eu chegaria até aqui. Aos meus sogros, por sempre terem confiado em mim desde o primeiro dia e por terem colocado a Beatriz nesse mundo. À minha sogra Gertrudes meus agradecimentos por tantas revisões, deste e de outros trabalhos, ao longo do tempo.

Agradeço ao *Universo Online (UOL)* pelos desafios que sempre colocou na minha carreira e por ter auxiliado nesta pesquisa. Gostaria de agradecer particularmente ao Marden Silveira Neubert, Márcio Drumond Araújo e Victor Ribeiro, grandes incentivadores dessa especialização acadêmica.

Ao Marden, que se tornou um grande amigo nesses anos, um agradecimento especial por ter contribuído muito para este trabalho e para meu amadurecimento profissional. Incentivou-me desde o primeiro dia e continua disponível para compartilhar e contribuir com ideias para a melhoria desta pesquisa, e mesmo quando tinha pouco tempo, encontrou maneiras para me auxiliar e me motivar. Agradeço pela confiança e liberdade que me propicia diariamente no exercício de minhas funções.

Agradeço ao Rodnei Fontana Lozano e Aline Barbosa Pereira, grandes investigadores de

fraude, que contribuíram demais para este trabalho. Ao estatístico Edil Lemes Ferreira, por todo o auxílio na parte final desta pesquisa.

Agradeço à equipe de desenvolvimento do *TodaOferta* da qual tenho orgulho de fazer parte. Nos momentos mais críticos, sempre me ajudou e se preocupou comigo e com esta pesquisa. Agradeço principalmente por terem suprido com maestria minha ausência decorrente da dedicação a este trabalho, diminuindo minhas preocupações. Agradeço também a todos os funcionários com quem tive oportunidade de trabalhar e conviver desde 1999.

Agradeço demais ao amigo Adriano Pereira pela colaboração na pesquisa e principalmente nos artigos – sem ele os rumos aqui tomados teriam sido outros, certamente inferiores. Sempre solícito, otimista e motivador, deu-me o prazer de trabalharmos em conjunto e seu auxílio foi grandioso. Aprendi muito e continuo aprendendo a cada vez que nos falamos. Serei eternamente grato por tudo que ele fez para mim.

Agradeço ao professor Alair, exemplo de caráter, fé e bondade, que me abriu as portas da academia e teve paciência durante esse período para que eu chegasse à conclusão deste trabalho. Fez de tudo para que a pesquisa e o texto final ficassem dentro dos padrões acadêmicos, corrigindo-me sempre que necessário. Além disso, foi um grande amigo, principalmente nas horas difíceis – seu auxílio e paciência são louváveis.

Agradeço também a todos os professores que tive na vida, desde a escola Cebolinha, Oito de Abril, ETE Lauro Gomes, Fundação Santo André, FIAP, até chegar ao IME-USP, pelo muito me que ensinaram, compartilharam e porque sempre souberam me valorizar.

Agradeço a todos os meus amigos, principalmente àqueles que compartilharam momentos de diversão nesses últimos anos em que o tempo para isso se tornou cada vez mais escasso. Agradeço pelos incentivos, pelas palavras animadoras, pelas conversas úteis e inúteis, pelas discussões (principalmente as de futebol), pelas piadas, pelos jogos, pelas músicas, pelas risadas e por acreditarem em mim, nem que fossem me desafiando ou minimizando minhas reclamações. E também por estarem ao meu lado nos momentos mais difíceis.

Resumo

Ao longo do tempo, o comércio eletrônico tem movimentado um volume de transações cada vez mais significativo. Um dos segmentos que mais cresce é o de mercados eletrônicos, nos quais vendedores de pequeno e médio porte oferecem seus produtos na *Web*. Dentro desses mercados, o sistema de reputação é fundamental, pois reflete em boa parte a credibilidade dos vendedores e é usado como critério de decisão para a compra. Isso faz com que os sistemas de reputação sejam alvos de fraude, seja por vendedores apenas interessados em melhorar sua reputação de forma ilícita, seja por vendedores também com intenção de cometer outros tipos de fraude. Em ambos os casos, avaliações positivas são criadas artificialmente.

Este trabalho apresenta uma metodologia para identificação de fraudadores contra sistemas de reputação, associando a cada vendedor uma probabilidade estimada de fraude. Posteriormente, ordenamos a listagem de vendedores por essa probabilidade, para que ela seja usada como ferramenta pelos especialistas em detecção de fraude. Por isso, tratamos o problema como uma classificação estatística, ao invés de uma classificação tradicional. Vale frisar que o problema de identificação de fraudadores apresenta dificuldades adicionais em relação a um processo usual de classificação em virtude dos dados serem desbalanceados (a classe de fraudadores é fortemente minoritária) e da anotação dos vendedores legítimos ser menos confiável que a anotação dos fraudadores.

A metodologia inicia-se com o processo de extração de características, avaliando eventos onde existe interação entre os usuários. Em seguida, aplica-se o método de Regressão Logística para construir o modelo e classificar os vendedores com base na probabilidade de fraude estimada. A ordenação obtida é avaliada com base em medidas de eficiência, como precisão, cobertura, *AIC*, precisão média e medida-F.

O estudo de caso utiliza dados de um mercado eletrônico brasileiro, o *TodaOferta*. Com a aplicação da metodologia a esse cenário real, contribuímos para a identificação de fraudadores que estavam anotados como legítimos, aumentando o conjunto de fraudadores em 112%. Também produzimos uma ordenação com alta precisão, especialmente no topo da listagem. Acreditamos que a mesma metodologia possa ser aplicada em outros contextos de fraude.

Palavras-chave: mercados eletrônicos, sistema de reputação, detecção de fraude, regressão logística.

Abstract

Electronic commerce (e-commerce) has been growing recently. In that kind of commerce, electronic marketplaces (e-markets) allow buyers and sellers to transact goods through the Web. Inside these marketplaces, the reputation system plays an important role because it shows sellers' credibility based on past transactions and it is used for buyers' decision. This induces that reputation systems are defrauded by sellers who intend to increase their reputation or by sellers that also intend to commit other kinds of frauds. In both scenarios, positive evaluations are artificially created in the reputation system.

This work presents a methodology to identify this kind of fraudsters, assigning a fraud probability for each seller and generating a list sorted by this probability. This list is the main tool used by specialists in fraud identification - that is why we decided to handle this problem as a statistical classification instead of a traditional one. It is important to say that fraud detection is hard because it deals with unbalanced data and annotations for honest users are less reliable than fraudsters' annotation.

The methodology starts with a feature extraction process that analyses events in which users interact with the marketplace. After that, it applies Logistic Regression to build the model and to sort sellers by estimated probability of fraud. The results are evaluated by performance metrics, such as precision, recall, AIC, average precision and F-measure.

The case study uses a real dataset from *TodaOferta*, a Brazilian marketplace. By applying this methodology to a real scenario, we discovered fraudsters that had been labeled as honest users and increased the group of fraudsters by 112%, improving the fraud identification process. Also, we generated lists with high precision, especially on their top. We believe such methodology can also be applied to different fraud context.

Keywords: e-markets, reputation system, fraud detection, logistic regression.

Sumário

Lista de Abreviaturas	xi
Lista de Figuras	xiii
Lista de Tabelas	xv
1 Introdução	1
1.1 Considerações Preliminares	1
1.2 Objetivos	3
1.3 Contribuições	4
1.4 Organização do Trabalho	4
2 Conceitos	7
2.1 Conceitos Básicos	7
2.2 Reputação	10
2.3 Fraude	12
2.4 Sistemas de Reputação Atuais	13
2.5 Descrição do Problema	16
2.6 Descrição da Amostra de Dados	17
3 Fundamentos Teóricos	19
3.1 Razão de Chances	19
3.2 Medidas de Eficiência	19
3.2.1 Precisão e Cobertura	20
3.2.2 Medida-F	21
3.2.3 <i>AIC</i> - Critério de Informação <i>Akaike</i>	22
3.3 Análise de Ligações e Estudo de Redes Naturais	22
3.4 Reconhecimento de Padrões	23
3.5 Regressão Logística	25
3.6 Regressão <i>Stepwise</i>	26

4	Trabalhos Relacionados	29
4.1	Sistemas de Reputação	29
4.2	Similaridade com Conteúdo <i>Web</i> e Identificação de <i>Spam</i>	30
4.3	Propagação de Confiança e Reputação	32
4.4	Técnicas de Detecção de Fraudes e Ruídos	32
4.5	Identificação de Fraudes em Mercados Eletrônicos	34
4.5.1	NetProbe	35
5	Metodologia Proposta	37
5.1	Extração de Características	37
5.2	Classificação Estatística	38
6	Estudo de Caso	43
6.1	Extração de Características	43
6.1.1	Definição dos Conjuntos de Transações e Vendedores	44
6.1.2	Entrevista com Especialistas	45
6.1.3	Seleção de Características	48
6.1.4	Contagem de Características	53
6.1.5	Validações Preliminares	55
6.1.6	Limitações da Abordagem	58
6.2	Aplicação do Método de Regressão Logística	59
6.2.1	Estratégia 1: 17 Características Positivas de Fraude	61
6.2.2	Estratégia 2: 37 Características de Fraude	64
6.2.3	Estratégia 3: Seleção de Modelo Otimizado em <i>FRS</i>	66
6.2.4	Estratégia 4: Revisão dos Elementos do Conjunto <i>FRS</i>	71
6.2.5	Estratégia 5: Modificar a Variável Resposta para <i>FRS</i> Revisado	75
6.2.6	Estratégia 6: Otimização do Modelo de Regressão para <i>FRS</i> Revisado	77
6.2.7	Estratégia 7: Divisão da Amostra em Dados de Treinamento e Teste	81
6.2.8	Estratégia 8: Aplicação do Modelo de Treinamento na Amostra de Teste	83
6.3	Influência das Características nos Modelos	86
6.4	Avaliação Final dos Resultados	88
7	Conclusões	93
7.1	Considerações Finais	93
7.2	Sugestões para Pesquisas Futuras	95

A Sistema <i>NetProbe</i>	97
A.1 Grafos	98
A.2 Descrição do <i>NetProbe</i>	100
A.3 Experimentos com <i>NetProbe</i>	102
B Pacote <i>R</i> - Comandos Utilizados	107
C Resultado das Execuções dos <i>scripts</i> no pacote <i>R</i>	109
C.1 Execução da Estratégia 1	109
C.2 Execução da Estratégia 2	110
C.3 Execução da Estratégia 3	112
C.4 Execução da Estratégia 5	113
C.5 Execução da Estratégia 6	115
C.6 Execução da Estratégia 7	116
D Tabela de Mapeamento de Características	119
E Comparação entre Contagem de Características e Regressão Logística	121
Referências Bibliográficas	125

Lista de Abreviaturas

<i>AFr</i>	Vendedores com Alguma Fraude
<i>AFrT</i>	Transações com Alguma Fraude
APS0	Não aceitação do meio de pagamento integrado
APS1	Aceitação do meio de pagamento integrado
ARCT	Avaliação rápida de compradores, não mais que N horas após a transação
AVGQ	Tempo Médio de Qualificação entre as transações do vendedor
BTVT	Baixa taxa de visitas por transações, menores que N
DTQ0	Não Utilização de Destaque no anúncio
DTQ1	Utilização de Destaque no anúncio
<i>FRS</i>	Vendedores com Fraude contra o Sistema de Reputação
<i>FRST</i>	Transações com Fraude contra o Sistema de Reputação
ITAT	Intervalo de tempo entre a publicação do anúncio e a transação menor que N horas
MEAC	Mesmo Identificador de Estação de trabalho para Anúncio e Comprador
MEAQ	Mesmo Identificador de Estação de trabalho para Anúncio e Qualificação
MEAT	Mesmo Identificador de Estação de trabalho para Anúncio e Transação
MEVC	Mesmo Identificador de Estação de trabalho para Vendedor e Comprador
MEVQ	Mesmo Identificador de Estação de trabalho para Vendedor e Qualificação
MEVT	Mesmo Identificador de Estação de trabalho para Vendedor e Transação
MIAC	Mesmo Endereço IP para Anúncio e Comprador
MIAQ	Mesmo Endereço IP para Anúncio e Qualificação
MIAT	Mesmo Endereço IP para Anúncio e Transação
MIVC	Mesmo Endereço IP para Vendedor e Comprador
MIVQ	Mesmo Endereço IP para Vendedor e Qualificação
MIVT	Mesmo Endereço IP para Vendedor e Transação
MRF	Campos Aleatórios Markovianos (<i>Markov Random Fields</i>)

<i>NFr</i>	Vendedores com Nenhuma Fraude
<i>NFrT</i>	Transações com Nenhuma Fraude
REC0	Vendedor editorialmente não reconhecido
REC1	Vendedor editorialmente reconhecido
TCPS	Transação completada no meio de pagamento integrado
UDTC	Mesmo domínio dos <i>e-mails</i> dos compradores nas transações do anúncio

Lista de Figuras

2.1	Exemplo de Parte da Página do Histórico de Qualificações Recebidas	10
3.1	Função Logística	26
4.1	Estrutura do Grafo de Transações	30
4.2	Exemplo de Fábrica de <i>Links</i>	33
5.1	Fluxo da Metodologia Proposta	42
6.1	Conjunto dos Vendedores e Tipos de Fraude	45
6.2	Linha do Tempo dos Eventos Relacionados à Transação no Mercado Eletrônico	46
6.3	Exemplo de Determinação de Limiar para Característica Não Binária	50
6.4	Precisão, Cobertura e Medida-F para Contagem de Características	57
6.5	Precisão, Cobertura e Medida-F para Contagem de Características - Dados Revisados	58
6.6	Aplicação dos Passos Finais da Metodologia	59
6.7	Guia das Estratégias	61
6.8	Avaliação da Estratégia 1	62
6.9	Avaliação da Estratégia 2	66
6.10	Avaliação da Estratégia 3	68
6.11	Comparação das Precisões P1, P2 e P3 em Função da Cobertura	70
6.12	Revisão dos Especialistas	72
6.13	Avaliação da Estratégia 4	73
6.14	Comparação de Precisão entre Estratégias 3 e 4	75
6.15	Avaliação da Estratégia 5	77
6.16	Avaliação da Estratégia 6	79
6.17	Comparação das Precisões P3, P4, P5 e P6 em Função da Cobertura	81
6.18	Avaliação da Estratégia 7 - Amostra de Treinamento	82
6.19	Avaliação da Estratégia 8 - Amostra de Teste	84
6.20	Comparação de Precisão entre Estratégias	89

A.1	Exemplo de Grafo	98
A.2	Exemplo de Grafo Bipartido	99
A.3	Exemplo de Grafo Bipartido Completo	100
A.4	Exemplo da Execução Final do <i>NetProbe</i>	102
A.5	Formação Procurada no Grafo de Transações	104
E.1	Comparação de Medida-F entre Contagem de Características e Regressão Logística (Estratégia 1)	121

Lista de Tabelas

2.1	Comparação entre Variantes do Comércio Eletrônico	11
6.1	Características, Cobertura e Razão de Chances nas Transações	52
6.2	Características, Cobertura e Razão de Chances entre Vendedores	53
6.3	As 19 Características Binárias Seleccionadas	54
6.4	Precisão, Cobertura e Medida-F para Contagem de Características	56
6.5	Precisão, Cobertura e Medida-F para Contagem de Características - Dados Revisados	57
6.6	Resultados da Estratégia 1	63
6.7	Resultados da Estratégia 2	67
6.8	Resultados da Estratégia 3	69
6.9	<i>AIC</i> e Precisão Média nas Estratégias 1, 2 e 3	70
6.10	Resultados da Estratégia 4	74
6.11	Comparação de Precisão entre Estratégias 3 (P3) e 4 (P4)	76
6.12	Resultados da Estratégia 5	78
6.13	Resultados da Estratégia 6	80
6.14	Resultados da Estratégia 7 - Amostra de Treinamento	83
6.15	Resultados da Estratégia 8 - Amostra de Teste	85
6.16	Z-valores das Variáveis dos Modelos	87
6.17	<i>AIC</i> e Precisão Média nas Estratégias 4, 5 e 6	89
6.18	Percentual de Vendedores Analisados em Função da Cobertura Desejada nas Estratégias 4, 5 e 6	90
A.1	Tabela de Exemplo da Instanciação do <i>NetProbe</i>	101
A.2	Número de Vendedores por Comprador	103
D.1	Correspondência entre Código de Características	119
E.1	Comparação de Medida-F entre Contagem de Características e Regressão Logística (Estratégia 1)	122

Capítulo 1

Introdução

1.1 Considerações Preliminares

O comércio eletrônico vem crescendo de forma significativa ao longo dos últimos anos e essa tendência deve continuar no futuro próximo [7], principalmente no Brasil [14]. Um dos segmentos que apresenta maior expansão no volume de transações é o de *mercados eletrônicos*, no qual ocorrem transações entre compradores e vendedores de médio e pequeno porte. Exemplos desses mercados são empresas como *eBay*¹ e *Mercado Livre*².

No ano de 2007, o *Universo Online (UOL)*³ criou o seu mercado eletrônico, o *TodaOferta*⁴, com o objetivo de participar desse segmento do comércio eletrônico, no qual o *Mercado Livre* é a principal referência brasileira.

Nos mercados eletrônicos, em geral, os compradores negociam com empresas de pequeno e médio porte e até com pessoas físicas à procura de fontes alternativas de renda. Por não conhecerem os vendedores, os compradores se deparam com a falta de *confiança*, seja no mercado eletrônico ou no próprio vendedor, para realizar negócios utilizando a *Web*.

Além disso, como esses mercados atraem um grande número de compradores, muitos deles com pouca experiência em comércio eletrônico ou até mesmo em transações dentro dos mercados eletrônicos, alguns usuários, principalmente vendedores, aproveitam-se desse fato para cometer fraudes, com o objetivo de atingir os compradores e se beneficiar de forma ilícita.

Como a percepção dos compradores é de que o responsável direto pela venda é o mercado eletrônico e não o vendedor, as fraudes também afetam diretamente a imagem e a própria credibilidade das empresas que prestam tal serviço *Web* a vendedores e compradores.

Os mercados eletrônicos mais populares, incluindo todos os *sites* citados anteriormente,

¹<http://www.ebay.com>

²<http://www.mercadolivre.com.br>

³<http://www.uol.com.br>

⁴<http://www.todaoferta.com.br>

empregam sistemas de reputação baseados em um processo de *qualificação* em que vendedores e compradores são convidados a avaliar as transações que realizaram (em geral, como “positiva”, “negativa” ou “neutra”). De acordo com os estudos de Melnik e Alm [25], Houser e Wooders [20], e Resnick e outros [28], o histórico de qualificações, seja pelo percentual de qualificações positivas, seja pela pontuação numérica calculada pelo sistema de reputação, é um critério observado e utilizado pelos compradores para decidir com qual vendedor transacionar.

Porém, da mesma maneira que determinadas páginas são criadas na *Web* com o intuito de forjar *links* para aumentar seu peso na avaliação de relevância dos buscadores, alguns vendedores e compradores forjam transações para aumentarem sua pontuação nos sistemas de reputação. Esse tipo de comportamento pode afetar negativamente as transações de vendedores honestos e também denegrir a imagem dos mercados eletrônicos, uma vez que o sistema de reputação perde confiabilidade.

Basicamente, os objetivos dos fraudadores do sistema de reputação são dois. Um deles é justamente aumentar sua pontuação e se beneficiar desse aumento artificial para realizar mais transações, sem causar danos financeiros a outros compradores. O outro objetivo, mais prejudicial aos mercados eletrônicos e seus compradores se comparado com o primeiro, é obter uma boa pontuação por meio das qualificações forjadas para então cometer fraudes financeiras, lesando principalmente compradores inexperientes. Independentemente da diferença de gravidade entre esses dois objetivos, a fraude de qualificação deve ser combatida, sobretudo para prevenir outros tipos de fraudes decorrentes dela.

Sendo assim, é fundamental que os mercados eletrônicos possuam ferramentas para identificar fraudadores contra o sistema de reputação a partir de suas transações e eventos relacionados à transação. O problema central que é abordado neste trabalho diz respeito a detectar e tratar fraudes contra sistemas de reputação em mercados eletrônicos, especialmente aquelas com o intuito de aumentar artificialmente a pontuação dos vendedores.

É importante ressaltar que o problema de identificação de fraudes apresenta dificuldades adicionais em relação a um processo tradicional de classificação. Uma das dificuldades é que, em geral, os dados são desbalanceados, com a classe de fraudadores significativamente menor que a legítima. Outra dificuldade, especialmente do problema tratado neste trabalho, é que há maior confiabilidade nas anotações de fraude e há desconfiança sobre parte das demais anotações.

Para isso, definimos uma metodologia para extração e seleção de características de fraude, com base em conhecimento das regras de negócio do mercado eletrônico e informações fornecidas por especialistas em detecção de fraude [23]. Essas características foram avaliadas em diversos eventos em que existem interações dos compradores e vendedores com os mercados

eletrônicos, não limitando a análise apenas às transações em si.

Após selecionadas as características de fraude, nós as utilizamos como variáveis de entrada para aplicação de um método estatístico, a *Regressão Logística*⁵, que possibilita construir uma lista de vendedores, ordenada pela probabilidade estimada de cada vendedor ser considerado fraudador do sistema de reputação [24].

Nessa lista ordenada, obtida com a aplicação do método de Regressão Logística, adotamos medidas tradicionais utilizadas na área de *classificação*, como *precisão*, *cobertura*, *medida-F*, *precisão média* e valor de *AIC*⁶, para compararmos a eficiência dos resultados obtidos a partir dos diversos experimentos que realizamos no estudo de caso. A validação da metodologia foi realizada utilizando dados reais do mercado eletrônico *TodaOferta*, verificando os resultados obtidos com especialistas em detecção de fraude desse mercado eletrônico.

Com a validação, obtivemos uma precisão de 100% para uma cobertura de 55,1% dos vendedores fraudadores contra o sistema de reputação, e precisões próximas de 70% para uma cobertura de 90% desses mesmos fraudadores.

1.2 Objetivos

O principal objetivo deste trabalho é identificar vendedores fraudadores contra o sistema de reputação e *produzir uma lista ordenada pela probabilidade estimada de cada um deles ser fraudador*, fornecendo aos especialistas em detecção de fraude uma ferramenta de suporte à decisão.

É importante deixar claro que nosso objetivo *não é* separar automaticamente os vendedores em dois conjuntos distintos (fraudadores ou não), pois as ações tomadas pelos especialistas em detecção de fraude em um mercado eletrônico dependem de uma avaliação particular, na maioria dos casos, de acordo com as diretrizes da empresa detentora do *site*. Em outras palavras, não empregamos uma classificação tradicional para a resolução deste problema⁷, onde a resposta para cada vendedor seria ele ser ou não um fraudador contra o sistema de reputação.

Dessa maneira, a produção de uma lista ordenada pela probabilidade estimada de fraude contra o sistema de reputação, ou seja, uma *classificação estatística* que possua uma boa precisão especialmente no topo da lista e tenha uma cobertura satisfatória, é uma ferramenta para tomada de decisão dentro dos mercados eletrônicos. De forma complementar, pode-se adotar também um processo automático de suspensão ou advertência aos vendedores, por exemplo, para determinados setores dessa lista. Portanto, o objetivo final deste trabalho é produzir essa lista seguindo as premissas aqui descritas.

⁵O método de Regressão Logística é explicado na Seção 3.5.

⁶O *AIC*, bem como as demais medidas, são definidos Seção 3.2.

⁷Uma descrição mais detalhada do problema pode ser vista na Seção 2.5.

1.3 Contribuições

As principais contribuições deste trabalho estão discriminadas abaixo:

- Metodologia para identificação de fraudadores contra sistemas de reputação;
- Aplicação da metodologia proposta em um estudo de caso com dados reais;
- Produção de uma lista de características capazes de identificar vendedores fraudadores contra sistemas de reputação;
- Aplicação de um método já conhecido da área de estatística (Regressão Logística) em identificação de fraudadores contra o sistema de reputação em mercados eletrônicos;
- Validação de metodologia dos experimentos com pessoas, especialistas em identificação de fraude, sem necessidade de efetuar qualquer inferência a partir das páginas dos mercados eletrônicos⁸;
- Aumento de 112% no conjunto de fraudadores. Antes da aplicação da metodologia na amostra de dados do *TodaOferta*, esses vendedores estavam anotados como usuários legítimos;
- Dois artigos sobre o assunto tratado nesta dissertação que foram publicados em conferências internacionais [23, 24].

1.4 Organização do Trabalho

O restante desta dissertação de mestrado está organizada da seguinte forma. No Capítulo 2 apresentamos os conceitos associados a mercados eletrônicos, sistemas de reputação e fraude, definindo algumas terminologias que serão utilizadas ao longo do texto. Descrevemos também com mais detalhes o problema abordado neste trabalho.

No Capítulo 3 apresentamos os principais conceitos teóricos utilizados ao longo desta pesquisa e no Capítulo 4 discutimos alguns trabalhos relacionados a sistemas de reputação e identificação de fraude.

Em seguida, apresentamos a metodologia proposta para identificação de fraudadores contra sistemas de reputação no Capítulo 5, com detalhes sobre os passos utilizados. A metodologia engloba, desde o processo de extração de características de fraude, até a aplicação e validação dos resultados obtidos na lista ordenada de vendedores.

⁸Vemos no Capítulo 4, que se refere a trabalhos relacionados, que a maioria das pesquisas existentes nessa área, determina o conjunto de fraudadores a partir de inferências sobre avaliações/qualificações exibidas nas páginas dos mercados eletrônicos.

Após a descrição da metodologia, apresentamos no Capítulo 6 os experimentos do estudo de caso, utilizando essa metodologia em uma amostra de dados reais de um mercado eletrônico brasileiro, o *TodaOferta*. Descrevemos passa-a-passo os experimentos realizados.

Finalmente, no Capítulo 7 discutimos as conclusões obtidas neste trabalho e listamos algumas oportunidades para continuidade da pesquisa.

Capítulo 2

Conceitos

O problema que abordamos neste trabalho é a identificação de fraudadores em mercados eletrônicos.

Neste capítulo, antes de descrever o problema, discutimos alguns conceitos básicos relacionados a mercados eletrônicos, enfatizando principalmente aqueles ligados aos sistemas de reputação. Citamos também alguns conceitos sobre fraudes e ao final descrevemos em detalhes o problema abordado.

2.1 Conceitos Básicos

Antes de iniciar uma discussão mais profunda sobre o tema, listamos definições mais precisas para termos e conceitos que serão extensivamente utilizados ao longo do trabalho. São elas:

- *Anotação*: É o processo de dar um atributo a parte dos dados que foram observados. O atributo que mais nos interessa, no caso, é aquele de um vendedor ser fraudador contra o sistema de reputação ou não. Alguns sinônimos utilizados são etiquetação, marcação ou rotulação;
- *Anúncio*: um anúncio consiste em uma descrição de um produto, imóvel, veículo ou serviço, com o intuito de mostrar as características do item para propiciar uma transação futura. Essa descrição consiste de uma série de atributos, como preço, fotos, condições de venda, entre outros;
- *Comércio Eletrônico*: é o conjunto de transações comerciais feitas especialmente por meio de um equipamento eletrônico, como, por exemplo, um computador;
- *Comparadores de Preços*: São ferramentas que ajudam seus usuários a pesquisar preços de produtos específicos em lojas virtuais. Em geral, estes *sites* não vendem produtos

e redirecionam seus usuários para os *sites* das lojas, onde as compras podem ser realizadas. Exemplos de comparadores de preços são o *Shopping UOL*¹, *Buscapé*² e *Shopping.com*³;

- *Compra Direta*: é um tipo de venda em que o vendedor anuncia um produto ou serviço a um preço fixo e o comprador pode concluir a transação sem necessidade de uma negociação com o vendedor. É similar ao que acontece em grandes lojas virtuais, exceto pelo fato de que o vendedor é de menor porte se comparado às empresas que possuem as lojas virtuais;
- *Comprador*: é o indivíduo que adquiriu um determinado item descrito em um anúncio;
- *Consulta* ou *Busca por Palavra Chave*: em nosso contexto, consiste em uma ou mais palavras informadas pelo comprador com a intenção de encontrar determinado item entre os anúncios disponíveis. Ela pode ser estendida com filtros e refinamentos para melhor localização dos produtos;
- *Destaques de Anúncios*: são opções que os mercados eletrônicos oferecem aos vendedores para diferenciar determinados anúncios dos demais. Em geral, esses mercados oferecem algumas opções de destaque a um determinado custo. Entre os exemplos de mecanismos de destaque de anúncio estão a possibilidade de diferenciação de cores no resultado de busca, inclusão de vídeos e alteração da fonte dos caracteres;
- *Intermediário de Pagamento Online*: é um serviço que permite que compradores e vendedores efetivem financeiramente suas transações com garantias de segurança relacionadas ao recebimento dos produtos. O exemplo de intermediário online mais conhecido mundialmente é o *PayPal*⁴, uma empresa do *eBay*. No Brasil, existe o *PagSeguro*⁵, uma empresa do *UOL* e o *Mercado Pago*⁶, de propriedade do *Mercado Livre*. As receitas desses serviços provêm de taxas cobradas de alguma das partes (comprador ou vendedor);
- *Leilão*: é um tipo de venda em que os interessados oferecem determinados valores e o item é vendido para aquele que fizer a maior oferta;

¹<http://shopping.uol.com.br>

²<http://www.buscape.com.br>

³<http://www.shopping.com>

⁴<http://www.paypal.com>

⁵<http://www.pagueseguro.com.br>

⁶<http://www.mercadopago.com.br>

- *Loja Virtual*: são *sites* nos quais empresas oferecem e vendem seus produtos. Exemplos desse segmento são empresas como *Submarino*⁷ e *Americanas.com*⁸;
- *Mercados Eletrônicos*: são empresas que criam mecanismos para que as transações online se concretizem. As fontes de receita dessas empresas provêm de taxas para inclusão de anúncio e opções de destaque e, em algumas delas, da cobrança de comissão de vendas;
- *Mundo Real*: Neste trabalho nos referimos a mundo real para dizer respeito à realidade e aos meios de transações que são tradicionalmente utilizados em nossa cultura, sem a utilização da tecnologia digital, como a Internet;
- *Mundo Virtual*: Nos referimos a mundo virtual para o cenário em que as transações são feitas através de meios eletrônicos.
- *Perfil do Usuário*: em geral é uma página onde são exibidas as quantidades de vendas e compras, além das pontuações dentro do sistema de qualificação. Nela também são exibidos comentários das partes, relativos à transação efetuada, de modo a mostrar o desempenho e histórico do usuário desde o seu cadastro nos mercados eletrônicos até o momento presente;
- *Processo de Qualificação*: é o processo pelo qual os compradores e vendedores são convidados a avaliar a transação, geralmente como “positiva”, “negativa” ou “neutra”, e, dependendo dessa avaliação, podem ganhar ou perder pontos no sistema de qualificação, ficando disponível na página de seu perfil para consulta de outros usuários do mercado eletrônico. A Figura 2.1 mostra um exemplo de um vendedor que possui transações avaliadas com todos esses critérios. Além disso, é possível preencher um pequeno comentário sobre a mesma;
- *Sistema de Reputação*: é o sistema utilizado pelos mercados eletrônicos para avaliar seus usuários, tanto vendedores quanto compradores;
- *Transações Online*: são as transações ocorridas na Internet, originadas a partir do interesse de um comprador em um anúncio de um vendedor. Neste trabalho, a transação pode ser do tipo leilão ou compra direta. No último caso o preço do anúncio não se altera após a existência de ofertas;

⁷<http://www.submarino.com.br>

⁸<http://www.americanas.com>

E	EDINHONUTL	Celular HIPHONE Mp12 Q-mini K10 +JAVA+2GB+BRINDE+PAGSEGURO
	Comentário: Estou com problema com o produto que comprei(NÃO FUNCIONA) preciso de orientação como trocar ou reparar obrigado	
	Réplica: Agradecemos suas palavras... Primeiramente nos da equipe Efigeniarevenda queremos agradecer a sua preferência manda devolta que troco....	
E	CLAUDIOTTI	Samsung Es17 12.2mp 4gb +capa+carregador+tripé+PAGSEGURO
	Comentário: foi rapida, obrigado	
	Réplica: Agradecemos suas palavras... Primeiramente nos da equipe Efigeniarevenda queremos agradecer a sua preferência e informar que nossa satisfação é atender você cliente com eficiência e rapidez	
E	LE23	CEL MP10-MP11-MP12-VAIC T929,2 chip,TV,Cam,Flash,2Gb+brinde!
	Comentário: Péssimo vendedor, péssima compra, não consigo falar com ninguém,o aparelho veio com defeito mandei de volta e disseram que não tem garantia.Não recomendo...	
	Réplica: quem falou que nao tem garantia..Vc foi precipitado , prove então se alguém da minha equipe falou isso , no meu anuncio está bem claro garantia de 3 meses , só trocarei quando vc mudar sua qualificação	

Figura 2.1: Exemplo de Parte da Página do Histórico de Qualificações Recebidas

- *Usuário*: neste trabalho é a pessoa ou entidade que representa o comprador ou o vendedor;
- *Vendedor*: é o indivíduo ou empresa que cria e mantém anúncios nos mercados eletrônicos com o intuito de vender seus itens aos compradores.

Tendo definido os conceitos acima, exibimos na Tabela 2.1 uma comparação entre alguns atributos de mercados eletrônicos, lojas virtuais e comparadores de preço para facilitar o entendimento e compreensão do leitor sobre as diferenças entre essas vertentes do comércio eletrônico.

2.2 Reputação

Segundo o dicionário Houaiss⁹, reputação é um conceito de que alguém ou algo goza em um grupo humano. Conforme Houser e Wooders [20], a reputação é algo que há tempos interessa também aos economistas, que observam que uma boa reputação sobre a qualidade pode agregar valor ao produto, permitindo a prática de um preço mais elevado.

Essa definição pode ser perfeitamente aplicada ao comércio eletrônico, principalmente nos *sites* de leilão e compra direta, em que, na maioria dos casos, o interessado não conhece nem tem contato direto com o vendedor. Portanto, a reputação é a ferramenta utilizada por esses mercados eletrônicos para auxiliar o comprador em potencial a decidir-se por transacionar com tais vendedores, exibindo o seu desempenho anterior.

No mundo real, quando há transações entre as partes, o histórico das transações também informa sobre outras habilidades e tendências. Além disso, a expectativa de reciprocidade ou

⁹<http://www.dicionariohouaiss.com.br>

	Mercado Eletrônico	Comparador de Preço	Loja Virtual
Exemplo Nacional	<i>Mercado Livre, TodaOferta</i>	<i>Shopping UOL, Buscapé</i>	<i>Americanas.com, Submarino</i>
Exemplo Internacional	<i>eBay</i>	<i>Shopping.com</i>	<i>Amazon^a</i>
Porte dos Vendedores	Pequeno ou Médio	Médio ou Grande	Médio ou Grande
Fonte de Receita	Destaques, comissões de venda	Loja/Anunciante	Comprador
Evento de Receita	Vendedor anunciando ou tendo item vendido	Clique do Comprador	Pagamento do Comprador
Responsabilidade sobre a venda	Vendedor	Loja/Anunciante	Loja Virtual

^a A *Amazon* oferece produtos também de seu mercado eletrônico, mas ela sempre faz a intermediação do pagamento entre o comprador e vendedor. Essa informação foi obtida em http://www.amazon.com/gp/help/customer/display.html/ref=hp_lnav_dyn?ie=UTF8&nodeId=200227090 em 18/12/2009.

Tabela 2.1: Comparação entre Variantes do Comércio Eletrônico

retaliação em transações futuras incentivam a manutenção de um bom comportamento [29], à medida que as partes vão se conhecendo e fortalecendo essa relação.

Já no mundo virtual, a confiança é mais difícil de ser estabelecida, pois acontece, na maioria das vezes, entre estranhos. Dessa forma, os sistemas de reputação tentam oferecer informações que auxiliem na representação sobre uma transação futura, ou seja, criam uma expectativa em seus usuários com base em transações anteriores, também feitas entre estranhos.

Ainda na comparação dos dois cenários, é válido ressaltar as seguintes características das transações realizadas no mundo real:

- Transações ocorridas localmente: as operações de varejo tendem a ser grandes no mercado local. Os clientes conseguem conhecer os vendedores por meio de suas reputações, mesmo quando o contato pessoal é restrito;
- Vendedores emprestam reputação de outros contextos (por exemplo, o contexto social, onde atores famosos usam sua imagem em propagandas);
- A reputação é construída ao longo de muitos anos;
- Novos produtos beneficiam-se de marcas pré-estabelecidas, e investimentos significativos em instalações físicas ou imagem.

Essas características são totalmente diferentes das que se apresentam nos mercados eletrônicos, em que raramente o comprador negocia com o mesmo vendedor, existem vários

produtos com marcas desconhecidas e não há nenhuma garantia sobre a idoneidade do vendedor, nem tampouco sobre a veracidade do produto ou serviço anunciado.

Em síntese, podemos afirmar que, nos mercados eletrônicos, a reputação pode ser vista de duas maneiras. De um lado, a *reputação do comprador* permite que se infira a probabilidade dele efetivar o pagamento. Do outro lado, a *reputação do vendedor* permite que se infira a probabilidade de que, depois de recebida a notificação do pagamento, o vendedor entregue o produto conforme anunciado [20]. Ou seja, tais probabilidades podem ser resumidas naquela referente à honestidade das partes da transação [25].

Dessa maneira, podemos verificar a importância dos sistemas de reputação nos mercados eletrônicos, que precisam aumentar diariamente o volume de transações, considerando e minimizando todos os problemas e desafios citados anteriormente.

2.3 Fraude

Ainda de acordo com o dicionário Houaiss, fraude é qualquer ato artiloso, enganoso, de má-fé, com o intuito de lesar ou ludibriar alguém, ou de não cumprir determinado dever. Sabemos que as fraudes são tão antigas quanto a humanidade, e que, com o advento da tecnologia, elas se tornaram mais sofisticadas e imprevisíveis.

Primeiramente, precisamos diferenciar *prevenção de fraude* e *detecção de fraude*. A prevenção descreve medidas que visam impedir ou interromper a ocorrência da fraude. Isso inclui elaboração de estratégias e tecnologias que dificultem as operações do fraudador, sem causar muitos inconvenientes ao usuário comum. Já a detecção é a identificação tão rápida quanto possível da fraude após ser cometida. Podemos verificar que a detecção deve ser disparada assim que a prevenção falha.

Conforme observam Bolton e Hand [5], o desenvolvimento de novos métodos para detecção de fraude é complexo pelo fato de que a troca de informações nesta área é extremamente restrita. Ademais, são envolvidas grandes quantidades de dados, que em geral se tornam desatualizados rapidamente, devido à evolução dos esquemas fraudadores.

Outra dificuldade existente na detecção de fraudes é o fato de existirem pouquíssimos exemplos de ocorrências das mesmas, se comparados com a quantidade de dados sem anomalias. Isso pode levar ao desenvolvimento de classificadores ruins com altos percentuais de acertos.

Pode acontecer que uma fraude não detectada, ou até uma suposta fraude erroneamente detectada, gere grandes prejuízos, dependendo do negócio. Conforme observam Bolton e Hand [5], as fraudes podem ser reduzidas ao menor nível desejado, desde que haja investimento compatível em esforço e tempo. Isso faz com que seja buscado um meio termo entre custo e percentual de detecção, de acordo com o negócio em que a detecção está sendo

aplicada.

Gadi e outros [15] publicaram estudo em que comparam métodos de classificação para identificação de fraude em transações de cartão de crédito e, para que a comparação entre os métodos selecionados pudesse ser feita, utilizaram uma fórmula que determinava o custo de cada método.

Conforme observam Bolton e Hand [5] os métodos estatísticos de classificação e detecção de fraude podem ser diferenciados entre *métodos supervisionados* e *métodos não supervisionados*. Ambos métodos são muitas vezes também chamados de métodos de aprendizagem computacional.

Um *método supervisionado* é aquele em que um especialista provê uma anotação ou custo para cada classe de classificação (no nosso caso, fraudador ou não) em uma amostra de dados de treinamento [13], ou seja, uma amostra de dados em que haja uma anotação prévia sobre essas classes. Já nos *métodos não supervisionados*, tipicamente conhecidos como *clustering*, não há necessidade explícita da anotação, e o próprio sistema cria agrupamentos baseado nos dados existentes. Os métodos supervisionados permitem normalmente melhor acurácia no processo de classificação, já que usam mais informações.

De acordo com Bolton e Hand [5], no que diz respeito à construção de métodos supervisionados, deve-se levar em conta o custo de classificações inadequadas e a diferença dos tamanhos das amostras das classes observadas, sempre considerando o custo do desenvolvimento versus o benefício da detecção da fraude. Já os métodos não supervisionados devem ser empregados em situações em que não existem evidências suficientes para determinar a fraude, de modo que eles servem como facilitadores na obtenção do padrão de fraude.

Outro método existente para a detecção e prevenção de fraude é a análise de ligações (*link analysis*) [6], em que se busca conhecer a rede de relacionamentos entre fraudadores reconhecidos com outros participantes dessa rede.

Como é característica dos fraudadores se adaptarem rapidamente a novos métodos de prevenção e detecção, os sistemas de identificação também devem ser adaptativos. Ademais, deve-se tomar o cuidado para evitar alarmes falsos que possam impactar e gerar custos adicionais ao negócio.

2.4 Sistemas de Reputação Atuais

A seguir, analisamos como funciona o sistema de reputação existente no principal *site* de comércio eletrônico mundial, o *eBay*¹⁰, e que também serve como referência para os

¹⁰Avaliação feita em 19/12/2009 com base nas informações disponíveis em <http://pages.ebay.com/help/feedback/howitworks.html>.

concorrentes nacionais: *Mercado Livre*¹¹ e *TodaOferta*¹². Existem variações entre os sistemas de reputação dessas empresas nacionais, mas ambas se inspiraram no sistema do *eBay*.

Conforme observam Resnick e outros [29] um sistema de reputação coleta, agrega e distribui avaliações/qualificações sobre um comportamento passado de seus usuários e, a partir dessas avaliações, ajuda outros usuários a decidir em quem confiar, encoraja um comportamento fidedigno e intimida a participação de usuários desonestos e inexperientes.

Antes de analisar o sistema de reputação do *eBay*, vale ressaltar que a própria empresa considera tal sistema como um dos principais motivos que a levaram a se tornar o líder de mercado no segmento e transacionar diariamente diversos produtos ao redor do mundo [29].

O sistema de reputação do *eBay* permite que as partes da transação, compradores e vendedores ou leiloeiros, se avaliem ao concretizarem uma transação. Assim que o leilão é finalizado ou a compra se concretiza, cada parte qualifica o desempenho da contraparte, atribuindo um valor positivo, neutro ou negativo, com possibilidade de deixar um comentário associado a esse valor. A pontuação final R do usuário calculada no sistema de reputação é dada por:

$$R = (1 \times p) + (-1 \times n) + (0 \times z) = p - n,$$

onde p é o número de qualificações positivas distintas¹³, n é o número de qualificações negativas distintas, e z é o número de qualificações neutras distintas.

O *eBay* ainda exhibe o percentual de qualificações positivas¹⁴. Para o cálculo do percentual, não se consideram apenas qualificações distintas, como acontece na pontuação. Sendo assim, o percentual é calculado dividindo-se o número total de qualificações positivas pela soma do número total de qualificações positivas e negativas¹⁵.

Essa pontuação e esse percentual são exibidos nos anúncios, permitindo a outros compradores analisar o desempenho do vendedor, antes de efetuar um lance ou uma compra. O comprador também pode ler os comentários associados às qualificações.

Além disso, o modelo de reputação atribui alguns ícones baseados na pontuação para indicar os usuários recém cadastrados e também para determinadas faixas de pontuação.

¹¹Mais detalhes sobre o sistema de reputação do *Mercado Livre* podem ser vistos em <http://www.mercadolivre.com.br/jm/ml.faq.s.portalFaqs.FaqsController?axn=verFaq&faqId=2380&categId=CASYS> - Acessado em 19/12/2009.

¹²Mais detalhes sobre o sistema de reputação do *TodaOferta* podem ser vistos em <http://todaoferta.uol.com.br/extras/ajuda/qualificacao.html> - Acessado em 19/12/2009.

¹³Em caso de mais de uma transação para um mesmo vendedor ou comprador, apenas a última transação é considerada na pontuação se as transações acontecerem a mais de uma semana.

¹⁴O *eBay* considera as qualificações recebidas nos últimos 12 meses para exibição desse percentual, desconsiderando as qualificações negativas.

¹⁵Informação obtidas em <http://pages.ebay.com/help/feedback/scores-reputation.html> em 23/12/2009. Até essa data, *TodaOferta* e *Mercado Livre* não consideravam um determinado período de tempo para cálculo do percentual.

Dependendo da faixa, o usuário pode receber benefícios em outros produtos da empresa ou de seus parceiros.

O *eBay* também aplicou, a partir do segundo semestre de 2008, uma evolução do atual sistema, permitindo múltiplas avaliações para aspectos específicos da transação, como pontualidade na entrega, atendimento, etc., além de permitir cinco níveis para cada uma destas avaliações. Essas informações são complementares à pontuação e percentual de qualificações positivas. Até o final do ano de 2009, tanto *TodaOferta* quanto *Mercado Livre* não utilizavam múltiplas avaliações para a mesma transação.

Um dos problemas existentes no sistema de reputação do *eBay*, que serviu de inspiração para seus concorrentes, vem justamente da facilidade para se cadastrar: basta ter um *e-mail* válido. Dessa maneira, é muito fácil para os fraudadores criarem contas e iniciarem suas atividades no mercado eletrônico, sem qualquer necessidade de compromisso com o passado. Para vendedores, é necessário informar também o número do cartão de crédito a fim de minimizar cadastros falsos.

Segundo Resnick e outros [29], um bom sistema de reputação requer ao menos as seguintes três propriedades:

- As partes na transação existirão ao longo do tempo;
- As avaliações sobre as transações são capturadas e distribuídas;
- As avaliações servem como guia para as transações futuras.

Ademais, os autores ressaltam que existem três principais problemas que precisam ser observados nos sistemas de reputação:

- Primeiramente, há pouco incentivo para o preenchimento da avaliação.;
- Em seguida, é muito difícil acontecer uma avaliação negativa, pois geralmente as partes se acertam entre o fechamento da transação e o recebimento da mercadoria;
- E depois, a dificuldade em se afirmar que as avaliações sejam honestas, pois pode haver interesses para prejudicar concorrentes ou até acordos de ajuda mútua a fim de forjar pontuações positivas, por exemplo.

Além disso, verifica-se que nem toda qualificação é comentada, e que compradores têm poucos estímulos para fazer a avaliação – diferentemente do vendedor que depende de sua reputação para futuras vendas; também, não é sempre possível distinguir fraudes de erros eventuais. Estes, entre outros fatores, prejudicam a idoneidade dos sistemas de reputação [25] e, por conseguinte, das empresas que prestam este serviço.

Como afirmam Gavish e Tucci [16], os compradores que forem afetados por algum tipo de fraude em um mercado eletrônico, diminuirão sua frequência de transações nesse mercado, afetando diretamente vendedores honestos e causando impactos na receita das empresas responsáveis por esses *sites*, que dependem das transações para obterem receita.

2.5 Descrição do Problema

Primeiramente, convém lembrar que o objetivo principal deste trabalho de pesquisa é contribuir para a melhoria do processo de investigação e detecção de fraudes em mercados eletrônicos.

Dessa forma, o problema aqui abordado é a identificação de fraudadores contra sistemas de reputação em mercados eletrônicos, em particular aqueles vendedores que tem sua pontuação adulterada com base em qualificações recebidas a partir de compras falsas. Portanto, é uma identificação que precisa encontrar vendedores com base em suas ações e dos compradores a eles relacionados.

As transações consideradas para a análise são apenas aquelas que tiveram uma qualificação positiva do comprador. Consideramos esse tipo de qualificação como o mais importante fator para fraude contra o sistema de reputação pois é ela que permite adulterar a percepção de compradores em relação aos vendedores e afeta diretamente a imagem do mercado eletrônico. Avaliações negativas ou neutras recebidas por vendedores ou qualquer tipo de avaliação recebida pelo comprador não fazem parte do escopo deste trabalho e consideramos objeto de pesquisa futura.

Este trabalho analisa e avalia técnicas que podem ser aplicadas para identificação desses fraudadores, verificando a transação em si e outros eventos relacionados às ações dos compradores e vendedores no cenário de mercados eletrônicos. O objetivo deste processo é construir uma lista ordenada dos vendedores com base na probabilidade estimada de cada um deles ser um fraudador contra o sistema de reputação.

A partir dessa classificação ordenada de usuários, os administradores do mercado eletrônico podem tomar ações baseadas em uma política de análise e detecção de fraudes. Em alguns casos, uma investigação mais aprofundada tem que ser feita; em outros, a punição dos usuários pode ser feita rapidamente. Isso depende da avaliação de um especialista em detecção de fraudes, que também decide que tipo de punição aplicar. Exemplos de punição podem ser apenas um registro interno para auxiliar em investigações futuras, advertência, suspensão ou até o cancelamento do cadastro do usuário. Novamente, esse tipo de punição depende da avaliação dos especialistas.

É importante ressaltar que levamos em consideração a possibilidade de dividir os usuários em dois conjuntos – fraudadores ou não. Porém, analisando a maneira como os especialistas

em detecção de fraude atuam e procedem, após uma denúncia ou investigação de fraude, optamos por adotar técnicas que possibilitem diferenciar cada usuário com base na probabilidade estimada de fraude. Sendo assim, consideramos que uma lista ordenada por essa probabilidade é o resultado mais adequado a ser produzido para esses especialistas em fraude.

2.6 Descrição da Amostra de Dados

A amostra de dados que utilizamos pertence ao *TodaOferta* e considera transações efetuadas durante um ano, de agosto de 2007 até o final de julho de 2008.

Os dados utilizados são um subconjunto aleatoriamente extraído da atividade do *TodaOferta* durante esse período e englobam:

- 350 mil usuários (compradores e vendedores);
- 114 mil transações;
- Cerca de 4 mil vendedores;
- 95 mil qualificações geradas a partir das transações;
- 860 mil anúncios, sendo desses 505 mil anúncios ativos. Foram desconsiderados os anúncios que não permitem transações (anúncios de imóveis, veículos e serviços);
- 5 mil ocorrências de fraude, identificadas manualmente, sendo que aproximadamente 20% delas de fraudes contra o sistema de reputação.

É importante citar que, como a identificação de fraudes até o momento de publicação deste trabalho é feita manualmente, não se sabe ao certo quantas ocorrências de fraude não estão sendo identificadas efetivamente, e como dissemos anteriormente, pretendemos contribuir para uma melhoria nesse processo, ou seja, a anotação em relação aos vendedores fraudadores é totalmente confiável, enquanto a anotação dos vendedores legítimos pode estar subestimada.

Outro ponto importante em relação às anotações é que o vendedor é anotado como fraudador ou não, ou seja, não há anotações específicas por transação. Entretanto, o evento que dá origem à investigação é a transação. Dessa forma, a anotação do vendedor é replicada para todas as suas transações.

Divulgamos em <http://www.ime.usp.br/~alair/rafaelpm/dissertacao/> os arquivos que utilizamos nos experimentos realizados ao longo do Capítulo 6, os quais estão sanitizados para garantir a privacidade dos usuários do *TodaOferta*. Uma descrição completa de cada coluna da amostra pode ser obtida no mesmo endereço.

Capítulo 3

Fundamentos Teóricos

Neste capítulo apresentamos os principais fundamentos teóricos utilizados no decorrer deste trabalho.

3.1 Razão de Chances

Nesta seção apresentamos o conceito de Razão de Chances, que é utilizado neste trabalho para avaliação do processo de extração de características, descrito a partir do Capítulo 5.

A razão de chances (em inglês, *Odds-Ratio*) é uma medida de associação entre dois valores de dados binários. É definida como a razão entre a chance de ocorrência de um evento em um determinado grupo e a chance de ocorrência em outro grupo, onde a chance é a probabilidade de ocorrência deste evento dividida pela probabilidade da não ocorrência do mesmo evento.

Se as probabilidades de um evento em cada um dos grupos forem p_1 para o primeiro grupo (G_1) e p_2 para o segundo grupo (G_2), então a razão de chances é determinada por:

$$\frac{p_1/(1-p_1)}{p_2/(1-p_2)} = \frac{p_1(1-p_2)}{p_2(1-p_1)}$$

Uma razão de chances de 1 implica que o evento é igualmente provável nos dois grupos. Uma razão de chances maior que 1 indica que o evento é mais provável no primeiro grupo (G_1). Caso seja menor que 1, ela indica que o evento é mais provável no segundo grupo (G_2).

3.2 Medidas de Eficiência

A seguir, apresentamos algumas das medidas existentes para avaliar eficiência de sistemas de Recuperação de Informação. Tais medidas também podem ser utilizadas no contexto de Aprendizado Computacional.

No contexto deste trabalho, utilizamos tais medidas para avaliação das listas de vendedores fraudadores obtidas a partir dos experimentos do Capítulo 6.

3.2.1 Precisão e Cobertura

As medidas de precisão e cobertura são utilizadas em diversos contextos, como na Recuperação de Informação e Classificação Estatística, para medir efetividade dos resultados obtidos [22]. Em inglês, a precisão é comumente chamada de *precision* e a cobertura de *recall*.

A *precisão* é vista como uma medida de exatidão ou fidelidade. Em Recuperação de Informação, uma precisão igual a 100% significa que todo resultado retornado por uma consulta é relevante - mas não diz nada a respeito de qual parte de todos resultados relevantes foi retornado. É definida como:

$$\text{Precisão} = \frac{|\{\text{relevantes}\} \cap \{\text{retornados}\}|}{|\{\text{retornados}\}|}$$

Por outro lado, a *cobertura* é vista como uma medida de integralidade. Em Recuperação de Informação, uma cobertura igual a 100% significa que todos resultados relevantes foram retornados por uma consulta - mas não diz nada sobre o número de resultados irrelevantes também que foram retornados. É definida como:

$$\text{Cobertura} = \frac{|\{\text{relevantes}\} \cap \{\text{retornados}\}|}{|\{\text{relevantes}\}|}$$

Uma avaliação apropriada requer um análise das curvas de precisão e cobertura à medida que a análise avança [3].

É também possível interpretar precisão e cobertura não somente como razões, mas também como probabilidades. A precisão é a probabilidade dos resultados da resposta serem relevantes, enquanto a cobertura é a probabilidade dos resultados relevantes serem listados em uma consulta.

Neste trabalho, em que avaliamos a precisão e a cobertura de uma classificação estatística (*ranking*) construída com o propósito de identificar fraudadores contra o sistema de reputação, consideramos como *relevantes* o conjunto de *fraudadores* e como *retornados todos os vendedores*, do topo da lista até determinada posição. Calculamos a precisão e a cobertura a cada posição da lista de resultados ordenada pela probabilidade estimada de cada vendedor ser considerado fraudador.

Seja k uma posição do *ranking*, $K(k)$ o conjunto de vendedores até a k -ésima posição, $P(k)$ a precisão na posição k e $C(k)$ a cobertura na posição k , definidas das seguintes formas:

$$P(k) = \frac{|\{\text{fraudadores}\} \cap \{K(k)\}|}{|\{K(k)\}|}$$

e

$$C(k) = \frac{|\{\text{fraudadores}\} \cap \{K(k)\}|}{|\{\text{fraudadores}\}|}$$

Como observam Manning e outros [22], uma vantagem de avaliar essas duas medidas é que uma pode ser mais importante que a outra dependendo das circunstâncias. No resultado de busca na *Web*, por exemplo, os usuários querem resultados relevantes na primeira página (alta precisão). Por outro lado, profissionais mais especializados, como investigadores, preferem resultados com uma maior cobertura e toleram uma precisão menor. Como observam os autores, em um sistema usual, a precisão geralmente cai à medida que o número de resultados aumenta, o que revela um compromisso típico entre precisão e cobertura.

Outra medida existente é a *precisão média* (*Average Precision*), que consiste em tomar a média aritmética dos valores de precisão para cada posição k em que o resultado dessa posição seja relevante. Neste trabalho, ser relevante é ser considerado fraudador.

Seja $P(k)$ a precisão calculada na k -ésima posição e $rel(k)$ uma função binária que avalia se o resultado da k -ésima é fraudador ou não, e $|K|$ a quantidade de resultados. A precisão média (AP) é definida por:

$$AP = \frac{\sum_{k=1}^{|K|} (P(k) \times rel(k))}{|K|}$$

3.2.2 Medida-F

Uma medida que combina cobertura e precisão é a média harmônica¹ entre elas chamada de medida-F, ou em inglês *F-Measure*, definida por:

$$F(k) = \frac{2}{1/C(k) + 1/P(k)},$$

onde $C(k)$ é a cobertura para o k -ésima posição na lista dos resultados ordenados (*ranking*), $P(k)$ é a precisão para essa k -ésima posição, e $F(k)$ é a média harmônica entre $C(k)$ e $P(k)$, relativa a k -ésima posição. A medida-F assume um valor no intervalo $[0, 1]$. Ela é 0 quando nenhum resultado relevante foi retornado e é 1 quando todos os resultados da resposta são relevantes. Adicionalmente, a média harmônica F tem um valor alto quando precisão e

¹A média harmônica dos números reais positivos a_1, \dots, a_n é definida como sendo o número de membros dividido pela soma do inverso dos membros, como segue:

$$H = \frac{n}{\frac{1}{x_1} + \frac{1}{x_2} + \dots + \frac{1}{x_n}} = \frac{n}{\sum_{i=1}^n \frac{1}{x_i}}, \quad x_i > 0 \text{ para todo } i.$$

cobertura são altas. Por essa razão, a determinação por um valor máximo para F pode ser interpretado como uma tentativa de encontrar o melhor ajuste possível entre precisão e cobertura [3].

A fórmula geral pode ser definida por:

$$F_{\beta} = \frac{(1 + \beta^2) \times (\text{precisao} \times \text{cobertura})}{\beta^2 \times \text{precisao} + \text{cobertura}},$$

onde $\beta^2 \in [0, \infty]$. A medida-F padrão considera igualmente precisão e cobertura, que é equivalente a ter $\beta = 1$. Valores de $\beta < 1$ enfatizam a precisão, enquanto valor de $\beta > 1$ enfatizam a cobertura. Precisão, cobertura e medida-F são métricas com valores entre 0 e 1, mas é comum escrevê-las em porcentagem [22]. Neste trabalho optamos por expressar a medida-F no intervalo entre 0 e 1.

3.2.3 AIC - Critério de Informação Akaike

O *AIC* é um teste estatístico que foi desenvolvido por Hirotugu Akaike [2], cuja sigla é derivada de “*An Information Criterion*” ou também “*Akaike Information Criterion*”. É uma medida de qualidade de adequação de um determinado modelo estatístico, e permite uma comparação de modelos. Essa comparação será feita ao longo dos experimentos. Um modelo com menor valor de *AIC* é considerado melhor entre os comparados. É definido como:

$$AIC = 2k - 2 \ln(L),$$

onde k é o número de parâmetros do modelo e L é o maior valor da função de verossimilhança.

Existem outras variações do *AIC* e consideramos que analisá-los é objeto de trabalho futuro. No nosso cenário, optamos apenas por um índice que permitisse expressar quando um modelo é melhor que outro. Tal comparação será feita ao longo dos experimentos descritos no Capítulo 6. Para mais detalhes sobre esta medida remetemos o leitor à referência de Akaike [2].

3.3 Análise de Ligações e Estudo de Redes Naturais

Uma das principais motivações deste trabalho para o uso dos conceitos de grafos é no estudo de redes de relacionamentos, em particular para representar as transações envolvendo compradores e vendedores.

A análise de ligações, também conhecida como *análise de links* (em inglês *link analysis*), é um método que trata da análise dos relacionamentos em qualquer tipo de rede natural. Entre exemplos de tipo de rede podemos considerar as páginas da Internet e o relacionamento entre compradores e vendedores em um mercado eletrônico.

Alguns exemplos de trabalhos clássicos no estudo de modelagem de autoridade de páginas da Internet fazem uso das técnicas de análise de ligações, tais como o *PageRank* [6] e o *TrustRank* [18]. Para mais detalhes sobre algumas das aplicações dos métodos de análise de ligações à Recuperação de Informação remetemos o leitor ao trabalho de Manning e outros [22].

3.4 Reconhecimento de Padrões

Nesta seção apresentamos um breve resumo sobre Reconhecimento de Padrões, uma vez que neste trabalho nos deparamos com problemas e situações que exigiram a aplicação dos conceitos descritos a seguir.

O *Reconhecimento de Padrões* é o procedimento que objetiva o tratamento de dados brutos (dados sem qualquer pré-processamento, em outras palavras) e posterior tomada de decisão baseada na categoria do padrão [13]. Ou seja, ele objetiva uma *classificação* a partir da determinação de *características (features)*.

A seguir, descrevemos alguns tipos de classificação. A *Classificação Tradicional* é baseada em testes de hipóteses e seu problema central é classificar um elemento entre dois conjuntos, não se levando em conta as propriedades estatísticas das características encontradas. Nesse caso, aceita-se ou rejeita-se uma hipótese em favor de outra. Pode-se dizer também que, se a probabilidade de uma hipótese cair dentro de um limiar for considerado significativo, aceita-se uma das hipóteses existentes.

Já *Classificação Estatística Baseada em Padrões (statistical pattern classification)* leva em conta as propriedades estatísticas de cada característica e procura encontrar a hipótese mais provável a partir de uma série de hipóteses. O resultado final também pode ser a classificação entre dois conjuntos, como na classificação tradicional, mas em geral o resultado final da classificação é uma lista com a probabilidade estimada de cada elemento estar inserido nos conjuntos observados.

Conforme observam Duda e outros [13], muitos dos problemas dessa área de Reconhecimento de Padrões dependem do domínio do problema sendo tratado, e suas soluções também dependem de conhecimento e de inspiração de quem está tentando resolvê-lo. Para o contexto deste trabalho, apresentamos os principais problemas² que consideramos mais pertinentes a esta pesquisa. São eles:

- *Extração de Características (feature extraction)*: é uma tarefa que está mais fortemente relacionada ao domínio do problema à classificação propriamente dita. Nesta tarefa, exploram-se os dados de forma a identificar informações irrelevantes ao problema e que

²Os autores consideram que existem 13 problemas de interesse geral, e para mais detalhes remetemos o leitor a Seção 1.3 desta referência.

possam ser desprezadas, e identificar aquelas informações que possam ser compostas de forma a caracterizar o problema.

- *Ruído*: é definido como qualquer propriedade do padrão identificado que ocorra em situações normais e não no modelo sendo construído, ou seja, uma propriedade que ocorra em determinada classe procurada, mas que também ocorre aleatoriamente, sem ser na classe procurada.
- *Sobreajuste (Overfitting)*: é o efeito de otimizar um algoritmo de aprendizagem com certos dados em que se conhecem os resultados desejados. O efeito colateral é não ter o mesmo desempenho para dados novos, uma vez que o modelo fica super-otimizado para os dados conhecidos.
- *Seleção do Modelo*: é a tarefa de selecionar um modelo estatístico a partir de um conjunto de modelos. Entre os critérios para seleção de um modelo, temos a Regressão *Stepwise* ou análise do valor de *AIC* de cada modelo, por exemplo.
- *Conhecimento Prévio*: refere-se a toda informação disponível sobre o problema adicional a amostra de dados de treinamento.
- *Características Faltantes*: são características cujos valores não se conseguem determinar, tipicamente, porque os dados não puderam ser coletados.
- *Contexto*: É o domínio do problema, onde ele se insere em uma situação real. É necessário utilizar as informações do contexto do problema para se obter um bom classificador, não se restringindo apenas à amostra de dados, por exemplo.
- *Riscos e Custos*: Conforme Duda e outros [13], o objetivo dos classificadores é recomendar uma ação, e cada ação tem associada ela um risco e custo. O risco mais simples é o erro de classificação, ou seja, indicar que determinado elemento não é o que ele realmente é – e esse erro certamente possui um custo associado.

Conforme observam Duda e outros [13], todo método que incorpore informações de dados de treinamento na montagem de um classificador emprega *aprendizado* (ou aprendizado de máquina, em inglês *machine learning*), que utiliza tais dados para modelar a função que estima a probabilidade do elemento a ser classificado. Este aprendizado pode ser feito de diferentes formas, que descrevemos a seguir.

Uma das formas de se empregar aprendizado é utilizando-se de *método supervisionado*, que é aquele em que um especialista provê uma anotação ou custo para cada classe de classificação (no nosso caso, fraudador ou não) em uma amostra de dados de treinamento.

Sendo assim, tem-se uma amostra de dados em que haja uma anotação prévia sobre essas classes.

Outra opção é empregar um *método não supervisionado*, tipicamente conhecido como *clustering*, em que não se usa uma anotação prévia dos dados e o próprio sistema cria agrupamentos e semelhanças baseado nos dados existentes.

Para mais detalhes sobre este assunto remetemos o leitor à referência de Duda e outros [13].

3.5 Regressão Logística

Em estatística, Regressão Logística é uma técnica utilizada para o prognóstico de probabilidade de valores de uma variável categórica, frequentemente binária – que neste trabalho indica ser fraudador ou não – a partir de um conjunto de observações com variáveis explicativas contínuas e/ou binárias, que, no caso, são as características de fraude.

A Regressão Logística é utilizada em ciências médicas [1] e sociais e tem outras denominações, como modelo logístico, modelo *logit* e classificador de máxima entropia. Neste trabalho, aplicamos essa técnica para obter a ordenação dos vendedores com base em sua probabilidade estimada de fraude. Essa aplicação será descrita no Capítulo 5

Para Hosmer e Lemeshow [19], é importante entender que o objetivo de uma análise utilizando este método é o mesmo que qualquer construção de modelo utilizado em estatística: encontrar o modelo mais adequado e conciso que descreva o relacionamento entre uma variável resposta e um conjunto de variáveis independentes.

Considere um conjunto de p variáveis independentes representadas no vetor:

$$\mathbf{x}' = (x_1, x_2, \dots, x_p) \quad (3.1)$$

E seja a probabilidade condicional do resultado representada por:

$$P(Y = 1|\mathbf{x}) = \pi(\mathbf{x})$$

A função *logit* é determinada pela equação:

$$z = g(\mathbf{x}) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p,$$

onde β_0 é chamado de intercepto (*intercept*) e $\beta_1, \beta_2, \dots, \beta_p$ são denominados coeficientes de x_1, x_2, \dots, x_p , respectivamente. No caso, o modelo de Regressão Logística é:

$$f(z) = \pi(\mathbf{x}) = \frac{e^z}{e^z + 1} = \frac{1}{1 + e^{-z}}.$$

Um gráfico da função é exibido na Figura 3.1. Essa função pode ter como entrada valores de

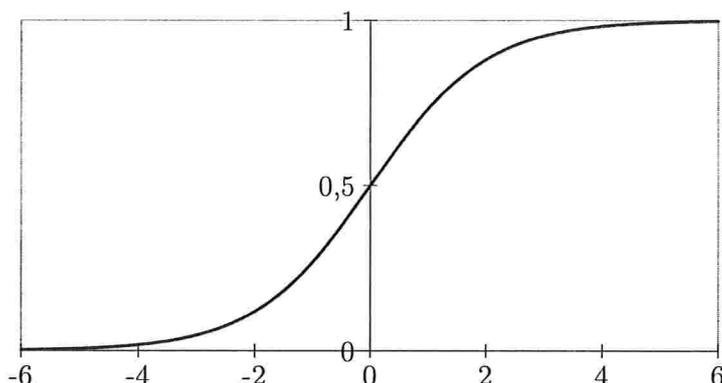


Figura 3.1: Função Logística

mais infinito a menos infinito, ou seja, $z \in (-\infty, +\infty)$. O resultado será um valor entre 0 e 1, ou seja, $f(z) \in [0, 1]$. A variável z representa a exposição a uma série de fatores de risco, enquanto $f(z)$ representa a probabilidade de um resultado particular, dada uma série de fatores de risco. A variável z é a medida da contribuição de todos fatores de risco utilizados no modelo e também é conhecido como *logit*.

Cada coeficiente descreve o tamanho de sua contribuição para o fator de risco. Coeficientes com valores positivos significam que o fator de risco aumenta a probabilidade do resultado, enquanto coeficientes com valores negativos significam o inverso. Um coeficiente com valores altos significa que o fator de risco influencia fortemente a probabilidade do resultado, enquanto que valores próximos de zero significam que tem baixa influência no resultado.

Para mais detalhes sobre o modelo e diferentes aplicações do mesmo, remetemos o leitor ao trabalho de Hosmer e Lemeshow [19].

3.6 Regressão *Stepwise*

Nessa seção descrevemos o procedimento de Regressão *Stepwise* que foi aplicado nos experimentos do Capítulo 6 para otimizar os modelos de Regressão Logística obtidos com as características de fraude analisadas no problema tratado neste trabalho.

A *Regressão Stepwise*³ é um procedimento de seleção de variáveis (ou características) de um modelo de regressão. Em geral, é feito por meio de um processo automático que testa e seleciona as variáveis com base um critério pré-definido. Neste trabalho utilizamos o Critério de Informação de *Akaike* (*AIC*) [2].

Esse procedimento pode ser feito de três formas:

³Não encontramos uma tradução adequada para o termo, por isso decidimos mantê-lo em inglês.

1. Seleção Progressiva (*Forward Selection*): inicia o modelo sem variáveis e a cada passo as inclui, uma a uma, enquanto for possível melhorar o modelo com novos conjuntos de variáveis.
2. Seleção Regressiva (*Backward Selection*): inicia o modelo com todas as variáveis e a cada passo as remove, uma a uma, enquanto for possível melhorar o modelo com novos conjuntos de variáveis.
3. Seleção Combinada (*Both Selection*): é uma combinação das duas técnicas anteriores, que insere e remove variáveis a cada etapa.

Em cada passo da seleção, o modelo é testado com os coeficientes de cada uma das variáveis iguais a zero, um por vez. Ou seja, considerando as variáveis x_1, x_2, \dots, x_p e $k = 1, 2, \dots, p$, é verificado se, quando $\beta_k = 0$, o modelo é mais eficiente do que com o valor original de β_k .

Como relatam Hosmer e Lemeshow [19], utilizar um procedimento de Regressão *Stepwise* pode proporcionar um modo rápido e efetivo para tratar um número grande de variáveis e ajustar um grande número de equações de Regressão Logística simultaneamente.

Qualquer procedimento de seleção ou exclusão de variáveis de um modelo é baseado em um procedimento estatístico que verifica a “importância” das variáveis, e as inclui ou as exclui com base em uma regra pré-determinada. A “importância” da variável é definida pela medida de significância de seu coeficiente [19].

Neste trabalho optamos por empregar apenas a seleção regressiva e consideramos que é objeto de trabalho futuro empregar as outras opções para comparação de eficiência entre elas no problema abordado neste trabalho. A opção pela seleção regressiva se deve ao fato dela ter obtido o mesmo resultado que a seleção combinada.

O Algoritmo 3.1 exhibe simplificadamente as etapas do processo de Seleção *Stepwise* Regressiva. Um modelo M é composto pelas variáveis x_1, x_2, \dots, x_p , onde $k = 1, 2, \dots, p$, e p corresponde ao número de variáveis desse modelo. Estamos pressupondo a existência da função $RemoveDoModelo(v, M)$ que, dada uma variável v , remove-a do Modelo M , da função $VariaveisDoModelo(M)$ que dado um modelo M , retorna as variáveis desse modelo e da função $AIC(M)$, que calcula o valor de AIC para o Modelo M .

Para mais detalhes sobre Regressão *Stepwise* remetemos o leitor à Seção 4.3 do trabalho de Hosmer e Lemeshow [19].

Algoritmo 3.1 Seleção *Stepwise* Regressiva

SELEÇÃO(M)

```
1  ▷  $M$ : Modelo
2   $v \leftarrow null$ 
3  repita  $M \leftarrow RemoveDoModelo(v, M)$ 
4       $M' \leftarrow M$ 
5       $X \leftarrow VariaveisDoModelo(M)$ 
6      para  $i$  de 1 até  $|X|$  faça
7           $M'' \leftarrow RemoveDoModelo(x_i, M')$ 
8          se  $AIC(M'') < AIC(M')$  então
9               $v \leftarrow x_i$ 
10              $M' \leftarrow M''$ 
11 até que  $AIC(M') < AIC(M)$ 
12 devolva  $M$ 
```

Capítulo 4

Trabalhos Relacionados

Neste capítulo descrevemos alguns dos principais trabalhos relacionados ao tema desta dissertação.

Primeiramente discutimos sobre a importância de sistemas de reputação em mercados eletrônicos. Em seguida, observamos como a estrutura das negociações desses mercados possui similaridades com a estrutura de páginas da Internet, inclusive nos problemas encontrados em ambos cenários.

Analisamos também algumas técnicas que utilizam tal similaridade para modelar o conceito de confiança e reputação. Por fim, analisamos alguns trabalhos para identificação de fraudes, especialmente em mercados eletrônicos.

4.1 Sistemas de Reputação

Conforme observam Resnick e outros [29] sistemas de reputação coletam, agregam e distribuem avaliações/qualificações sobre um comportamento passado de seus usuários. Dellarocas [11] publicou uma pesquisa em que é ressaltada a importância dos sistemas de reputação não somente para mercados eletrônicos, mas também para outras aplicações *Web*, como, por exemplo, sistemas de avaliação de produtos e serviços. Dellarocas [11] também relata alguns desafios que um sistema de reputação virtual possui.

Devido a essa importância, alguns estudos analisam a relação entre uma boa reputação e o sucesso das transações efetuadas [27], bem como a dificuldade em estabelecer uma noção de confiança nos sistemas de reputação virtuais [11].

Um desafio reside no fato dos usuários utilizarem informações de pessoas desconhecidas para embasar sua avaliação sobre outro desconhecido, ou seja, confiarem em opiniões de terceiros para construir sua própria avaliação. O desafio é como fazer com que o sistema também possa parecer tão confiável quanto as opiniões ali expressadas.

O outro desafio é relativo à idoneidade e veracidade das opiniões, algo que também foi pesquisado por Resnick [29], que exemplificou o problema descrevendo uma situação rela-

tiva à criação de identidades que emitem determinadas opiniões/avaliações e posteriormente deixam de interagir com os sistemas de reputação. Em um momento seguinte, outras identidades são criadas sem qualquer relação com as identidades anteriores, não garantindo o estabelecimento de uma opinião/avaliação consistente.

Sobre o relacionamento entre reputação dos vendedores e o sucesso das transações, Pereira e outros [27] fizeram um estudo detalhado sobre as vendas realizadas no mercado eletrônico *TodaOferta* e verificaram como uma boa reputação do vendedor é importante para o sucesso das transações. Para corroborar com essa constatação, Melnik e Alm [25] analisaram anteriormente algumas transações do mercado eletrônico *eBay* e também observaram tal situação.

4.2 Similaridade com Conteúdo *Web* e Identificação de *Spam*

Pandit e outros [26] caracterizam as estruturas de transações como similares à estrutura de páginas da *Web*, como mostra a Figura 4.1, em que cada nó representa um negociador e uma ou mais arestas, conectadas àquele nó, representam as transações efetuadas pelo negociador. Para eles, assim como acontece com os *links* nas páginas da *Web*, as arestas possuem

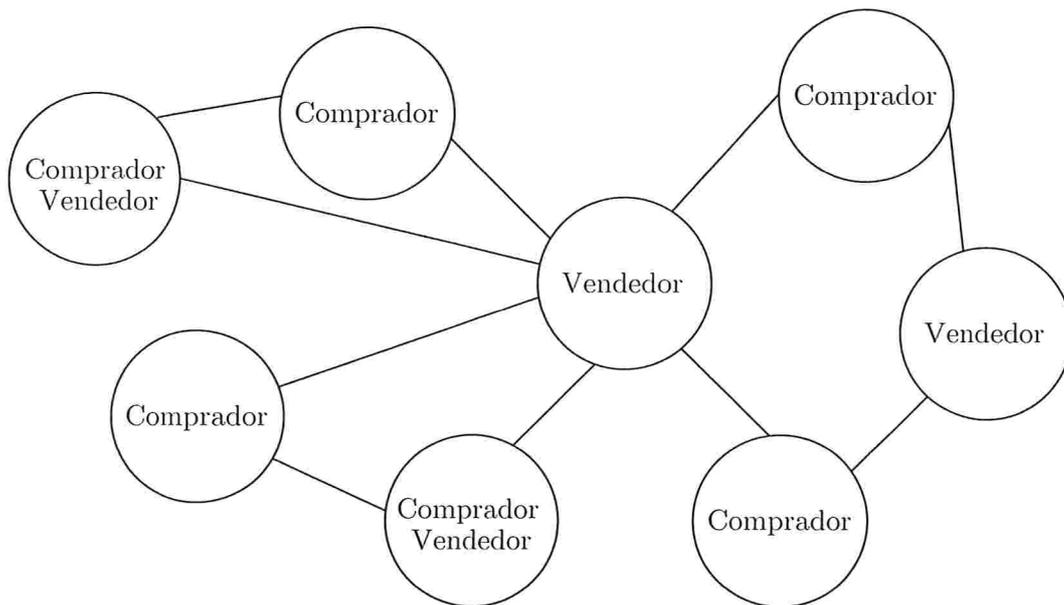


Figura 4.1: Estrutura do Grafo de Transações

uma semântica própria e suas propriedades podem ser propagadas para os nós vizinhos, de modo similar ao que ocorre com a técnica de *PageRank* [6], base de funcionamento do algoritmo de Recuperação de Informação adotado pela máquina de busca do *Google*¹.

Dessa maneira, os problemas e soluções existentes na obtenção de páginas com autoridade,

¹<http://www.google.com>

ou seja, páginas que são confiáveis e de boa reputação e páginas fraudulentas (que podem ser denominadas como *spam*) também se aplicam para a identificação de potenciais fraudadores e conseqüentemente para encontrar bons negociadores.

Um dos artifícios existentes na *Web* para obter melhor posicionamento em resultados de máquinas de busca, como *Google* e *Yahoo!*², por exemplo, é a criação artificial de estruturas de *links*, denominados *links* ruidosos (*noisy links*). Carvalho e outros [10] observam que esses *links* ruidosos não podem ser computados como votos de qualidade e às vezes afetam a análise das máquinas de busca. Os autores reforçam também que é muito importante diminuir o efeito do ruído introduzido artificialmente no relacionamento entre as páginas. Um exemplo desse ruído pode ser a existência de *links* entre *sites* de empresas pertencentes a um mesmo grupo controlador ou parceiro, que certamente estarão interconectados; diferentemente do que acontece nas análises de ligações de páginas *Web*, tais votos/*links* não representam efetivamente votos/*links* de qualidade. Mais uma vez, podemos verificar que tais análises também se aplicam diretamente ao cenário de mercados eletrônicos, em que a relação entre comprador e vendedor pode conter ruídos, como negociações forçadas, por exemplo.

Para pessoas experientes, identificar um *spam*, seja em conteúdo de páginas *Web* ou em *e-mails*, não é uma tarefa muito difícil. Como afirmam Gyöngyi e outros [18], as empresas que fornecem resultados de busca na *Web* empregam uma boa quantidade de funcionários especializados na identificação de *spams*. Uma vez que o *spam* é identificado, a máquina de busca interrompe a coleta e não indexa o conteúdo. Esse processo é muito caro e demorado, mas de vital importância para o negócio dessas empresas. Para Pandit e outros [26], algo similar também é feito pelos mercados eletrônicos, que investem em pessoal para detecção e investigação de fraudes. Entretanto, apenas uma análise humana se torna inviável em qualquer cenário, seja na análise de *links* de páginas *Web* ou nos mercados eletrônicos, devido ao grande volume de páginas e usuários envolvidos no relacionamento.

Conforme apresentado por Gyöngyi e outros [18], a detecção de *spams* e fraudes utilizando-se de computadores não é uma questão simples. Por isso, na opinião dos autores, é necessário o emprego de técnicas semi-automáticas que, combinando a avaliação de especialistas dos domínios com o auxílio de algoritmos, identifiquem potenciais *spams* ou fraudes, bem como as origens das autoridades.

Segundo Carvalho e outros [10], muitos dos ruídos em páginas da *Web* podem ser facilmente detectados quando se observa o relacionamento entre *sites* ao invés de observar os relacionamentos entre páginas. Na proposição dos autores, existem três abordagens: (1) identificar o reforço mútuo entre os *sites*, (2) identificar relacionamentos entre *sites* em que um deles tem *PageRank* [6] acumulado de apenas um outro *site*, (3) penalizar ligações que

²<http://www.yahoo.com>

artificialmente promovem um determinado site.

4.3 Propagação de Confiança e Reputação

Outra técnica que pode ser compartilhada do ranqueamento e reputação de páginas *Web* é a propagação de autoridade ou confiança, que está intimamente ligada com a área de detecção de fraudes, segundo Pandit e outros [26].

Entre os algoritmos de propagação de confiança está o *TrustRank* [18], que foi criado inicialmente para combater *spams* por meio da propagação de confiança entre as páginas da *Web*. Em síntese, o algoritmo consiste em selecionar manualmente um conjunto de páginas com alta qualidade e associar a elas um alto valor de confiança. Em seguida, com uma adaptação do algoritmo *PageRank* [6], é feita a propagação deste valor de confiança por meio dos *links* de saída. Tal abordagem também é empregada de maneira inversa em páginas consideradas ruins. Segundo os autores, a vantagem do algoritmo proposto por eles em relação ao *PageRank* [6], é que o *TrustRank* [18] incorpora o conhecimento acerca da qualidade da página ao invés de considerar apenas o número de *links* de entrada e penaliza páginas que tentam burlá-lo utilizando *links* artificiais. Além disso, utilizando-se da propagação, a qualidade – ou falta dela – é espalhada no grafo de relacionamento das páginas, agrupando-as de maneira mais qualitativa.

4.4 Técnicas de Detecção de Fraudes e Ruídos

Entre os tipos de fraudes apresentadas por Bolton e Hand [5], a que mais se assemelha ao cenário de mercados eletrônicos é a fraude que ocorre em sistemas de telecomunicações. Nesse cenário, as principais fraudes acontecem na assinatura do serviço, como a utilização de uma identidade falsa, com a intenção de não efetuar o pagamento. No caso dos mercados eletrônicos, é a típica fraude efetuada pelos compradores, também sem a intenção de pagar pelo produto, o que gera trabalho desnecessário para os vendedores e podendo prejudicá-los nas avaliações do sistema de reputação.

Segundo os autores, esse tipo de fraude em sistemas de telecomunicações pode ser detectado facilmente no momento do pagamento da fatura, mas podemos verificar que tal abordagem não seria aplicada nos mercados eletrônicos, já que, a princípio, o comprador não tem relacionamento financeiro com o *site*.

Uma das alternativas para tentar diminuir os efeitos desse problema é a verificação de cadastros em *sites* ou empresas que prestam serviço dessa natureza, como, por exemplo, a SERASA³. Com certo investimento por parte das empresas que possuem seus mercados eletrônicos, esse procedimento já poderia ser empregado em seus fluxos atuais de cadastro.

³<http://www.serasa.com.br>

Outra abordagem utilizada no sistema de telecomunicações para detecção de fraudes é a análise de *links* (vide Seção 3.3). Segundo trabalho de Bolton e Hand [5], como os relacionamentos das ligações representam comunidades de interesse, isso pode indicar redes de fraudadores, e, por conseguinte, a rede de usuários fraudados.

Com relação à detecção de *spams* para páginas da *Web*, que parece se aplicar ao cenário de mercados eletrônicos, um dos métodos empregados é a detecção de fábrica de *links*. As ligações feitas por essas fábricas representam uma série de páginas densamente conectadas, criadas com o propósito de iludir o sistema de ranqueamento ou ordenação das máquinas de busca. Para Becchetti e outros [1], esse expediente pode ser definido também como uma manipulação na estrutura de *links* por um grupo de usuários com a intenção de aumentar a pontuação de um ou mais usuários desse grupo. Os autores observaram que as páginas pertencentes a este conjunto de fábricas de *links* possuem uma grande quantidade de ligações entre suas páginas e pouco relacionamento com as restantes. Tal característica já foi citada por Bolton e Hand [5] e está entre os problemas que ocorrem também em mercados eletrônicos [26]. A Figura 4.2 mostra um exemplo comparando o relacionamento entre páginas de fábricas de *links* e o relacionamento entre páginas consideradas normais.

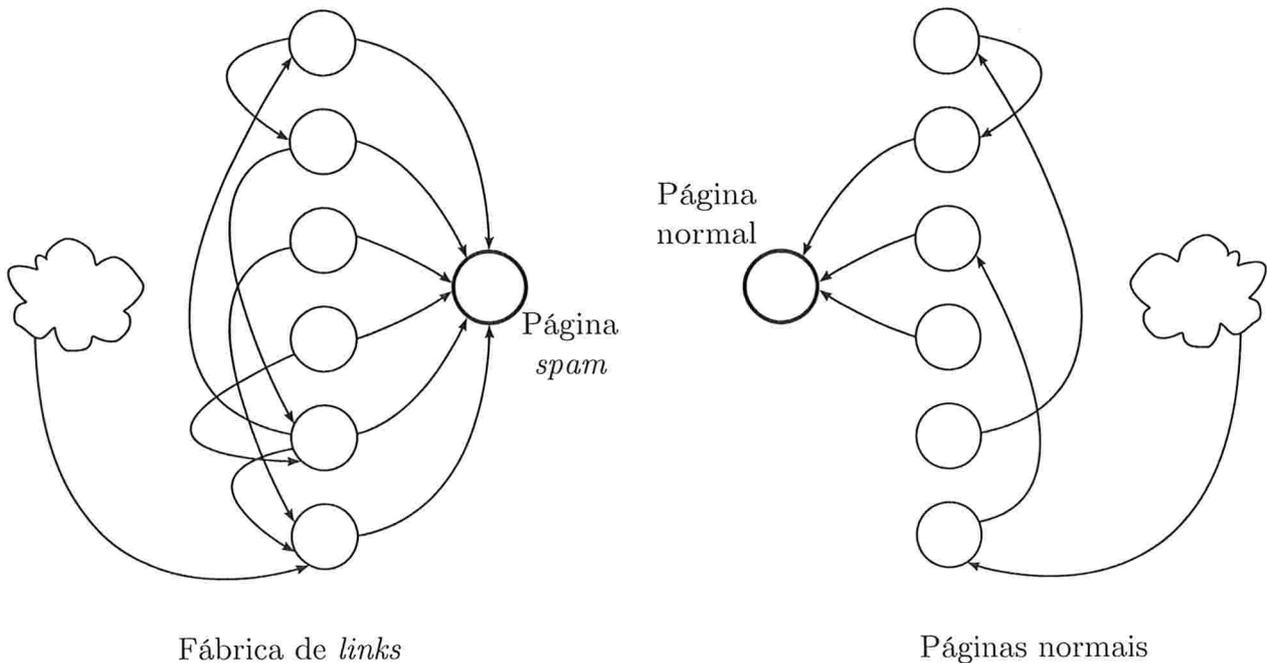


Figura 4.2: Exemplo de Fábrica de *Links*

Utilizando-se da rede formada pelas negociações, Chau e Faloutsos [9] observaram alguns tipos de comportamento dos fraudadores:

- Vender ou comprar uma grande quantidade de itens com preço baixo com o intuito de

construir artificialmente uma boa reputação;

- Vender ou comprar itens de preço moderado e alto, transacionando com usuários cúmplices que parecem atuar como usuários legítimos, a fim de obter uma boa reputação;

Os autores observaram também que, em geral, estes eventos ocorrem em um curto período de tempo, pois os fraudadores querem se beneficiar o mais rapidamente possível para que, caso sejam detectados, já tenham conseguido sucesso na aplicação da fraude em várias transações.

4.5 Identificação de Fraudes em Mercados Eletrônicos

Por atrair um número expressivo de usuários, os mercados eletrônicos se tornaram alvo de fraudadores, uma vez que volumes financeiros significativos são transacionados por meio desses *sites*.

Gavish e Tucci [16] publicaram um estudo sobre fraudes cometidas no mercado eletrônico *eBay*, analisando alguns comportamentos de fraudadores, como venda de produtos abaixo do preço da concorrência para incrementar suas vendas, e troca de políticas de pagamento. Um exemplo desse último caso é o vendedor que afirma aceitar cartão de crédito, mas depois insiste em ter o pagamento em meios convencionais. Ao final do trabalho, os autores publicam algumas recomendações para os mercados eletrônicos. Tais recomendações são relativas a procedimentos e decisões de negócio que poderiam contribuir para dificultar a ocorrência de fraudes, atuando como medida preventiva.

Em outra pesquisa que analisa as qualificações e comentários do mercado eletrônico *eBay*, Gregg e outros [17] identificaram que os principais tipos de fraudes cometidas são o não recebimento do item anunciado e o recebimento de produtos que não são exatamente iguais aos que foram anunciados. Para eles, o sistema de reputação é uma ferramenta que pode auxiliar a identificação desses fraudadores.

Chau e Faloutsos [8] também publicaram um estudo em que analisaram alguns volumes de transações e preços de produtos de vendedores fraudadores e de outros considerados honestos. Para determinar o conjunto de fraudadores foi feita uma inferência sobre as qualificações recebidas de vendedores no mercado eletrônico *eBay* e comentários realizados em fóruns de discussão sobre tais vendedores. Na nossa visão é uma abordagem limitada, já que não há qualquer validação de tal procedimento por parte de especialistas em detecção de fraude do *eBay*.

4.5.1 NetProbe

Como pudemos observar, existem várias técnicas para a detecção de fraudes, ruídos e *spams* e propagação de autoridade, direcionadas ao relacionamento de páginas na *Web* que também podem ser aplicadas, com certas adaptações, em mercados eletrônicos.

Segundo Becchetti e outros [4], a maioria das máquinas de busca atuais utiliza uma combinação de diferentes fatores para ordenar os resultados de busca, analisando não somente a ocorrência do texto no documento e a estrutura de *links*, mas também a detecção de *spams* para determinar o resultado final.

Foi por meio desse princípio que Pandit e outros [26] propuseram o sistema *NetProbe* para detecção de fraude e propagação de confiança em sistemas de leilões online, e que pode ser utilizado também para a modalidade de compra direta, pois ele se baseia na detecção de fraude a partir das informações do sistema de reputação, processo idêntico para essas duas modalidades de venda. Segundo os autores, a vantagem do *NetProbe* está na sua habilidade em não somente localizar os fraudadores, mas também prognosticar usuários que tendem a cometer fraudes no futuro.

Os autores consideram que cada aresta do grafo de transações, que pode ser observado na Figura 4.1, pode ser interpretada como um indicador de similaridade em relação ao comportamento – usuários honestos irão interagir mais frequentemente com outros usuários honestos, enquanto os fraudadores vão interagir em pequenos grupos deles próprios. Dessa forma, a honestidade e as fraudes podem ser detectadas por meio da identificação da densidade de conexão entre os subgrafos das transações.

Resumidamente, o *NetProbe* parte de uma anotação inicial de fraudadores e procura no grafo de transações núcleos bi-partidos⁴ utilizando técnicas de propagação de confiança e reputação. Ao final de sua execução, o sistema identifica usuários fraudadores, honestos e cúmplices. Para mais detalhes sobre este trabalho remetemos o leitor ao Apêndice A, onde também descrevemos um experimento preliminar que efetuamos usando como base esse tipo de técnica.

Basicamente, nesse experimento não conseguimos encontrar na amostra de dados do mercado eletrônico *TodaOferta* as características que identificam os fraudadores descritas pelo *NetProbe*, que foi feito utilizando informações do mercado eletrônico *eBay*.

É importante ressaltar que inicialmente planejávamos utilizar um processo tradicional de extração de características juntamente com análise topológica do grafo de transações, mas não encontramos na amostra de dados a formação de rede de fraudadores, nos moldes do que os autores relatam no artigo do *NetProbe*. Mais detalhes sobre esse experimento estão descritos no Apêndice A.3. Apesar de esses autores relatarem que a extração de características

⁴As definições sobre grafos podem ser vistas no Apêndice A.1.

é limitada na identificação de fraudadores, verificamos que em nossos experimentos o oposto.

Outro fator que é importante ressaltar sobre o *NetProbe*, é que esse sistema não teve a oportunidade de dispor de uma validação dos resultados por pelo mercado eletrônico em relação aos conjuntos de fraudadores, algo que felizmente pudemos efetuar neste trabalho. Em nossa visão, a inferência feita para determinação dos elementos dos conjuntos de fraudadores e legítimos é extremamente arriscada, pois não há comprovação, de fato, sobre a real anotação desses vendedores. Em outras palavras, não há confiabilidade sobre essa anotação.

Dessa forma, todos esses fatores reforçou-nos a intuição bem sucedida neste trabalho de que seria mais proveitosa a aplicação de uma metodologia que utilizasse extração de características e posteriormente empregasse algum método para ordenar os vendedores pela probabilidade estimada de fraude, com base nessas características. No Capítulo 5 descrevemos essa metodologia e no Capítulo 6, os experimentos que efetuamos.

Capítulo 5

Metodologia Proposta

Neste capítulo, explicamos a metodologia elaborada para identificar fraudadores contra o sistema de reputação em mercados eletrônicos. Efetuamos uma descrição textual de cada etapa e ao final a Figura 5.1 consolidará em um diagrama todos os passos relatados a seguir. A metodologia possui duas partes fundamentais: o processo de extração de características e a classificação dos vendedores com base na probabilidade estimada de fraude.

Um pré-requisito para a aplicação da metodologia proposta é dispor de uma amostra de dados com anotações que indiquem a existência de vendedores fraudadores e também identifiquem outros legítimos, ou seja, que possuam anotações relativas aos conjuntos envolvidos e que discriminem cada um deles.

5.1 Extração de Características

O primeiro passo da metodologia consiste em identificar a ocorrência de ações que sejam suspeitas de fraude, recorrendo aos especialistas em detecção de fraude que atendem e verificam evidências de fraude no mercado eletrônico em questão. A partir de algumas evidências e características de fraude presentes nas transações, que representam o principal evento relacionado à fraude nessa aplicação de mercados eletrônicos, também analisamos outros eventos correlatos, como cadastro dos usuários ou do anúncio transacionado, por exemplo. Em suma, é necessário verificar outras ações dos usuários (compradores e vendedores) com o mercado eletrônico, além do evento primário de fraude, que neste contexto é a transação e qualificação/avaliação recebida após se efetivar a transação.

Além das características levantadas pelos especialistas em detecção de fraude, também é importante considerar outras hipóteses que podem ser indícios de fraude com base no conhecimento das regras de negócio. Em outras palavras, não limitamos a análise apenas às informações fornecidas pelos especialistas. Portanto, é necessário conhecer o cenário da aplicação de mercados eletrônicos e regras utilizadas nesse contexto.

O passo subsequente é comprovar, para cada característica, se ela é ou não um potencial

indicador de fraude. Para isso, utilizamos inicialmente a razão de chances entre a ocorrência da característica no conjunto de fraudadores contra o sistema de reputação em relação ao grupo de controle, que no caso é formado pelo conjunto de vendedores sem qualquer incidência de algum tipo de fraude. Quando a razão é considerada *significativa*, acima de um limiar mínimo que depende do contexto de cada sistema, a característica é selecionada. Neste trabalho, arbitrariamente optamos por considerar apenas as características que tivessem razão de chances, nas transações, maior que três (este valor representa uma chance ao menos três vezes maior de ocorrer no conjunto de transações com fraudadores do que nas transações legítimas). Em outros cenários, esse valor poderá ser diferente e merece ser também analisado com base na amostra de dados relativa ao problema em questão.

Nem todas características tem valores binários em sua determinação, como por exemplo, aquelas que estão associadas a intervalos de tempo, como o período entre a transação e a qualificação, que pode ocorrer imediatamente após a transação ou dentro do limite de dias estipulado pelo mercado eletrônico. Nesses casos, uma estratégia é adotar um limiar mínimo para a razão de chances entre frações desses intervalos nos conjuntos de fraudadores e não fraudadores.

Esse processo deve ser empregado para as características indicativas de fraude e também para as que indicam não-anomalia, pois estas últimas fornecem informação que colabora para diminuir a chance de fraude.

Tendo selecionado as características significativas, a etapa seguinte é comprovar se elas realmente identificam os fraudadores.

5.2 Classificação Estatística

Como já dissemos na Seção 2.5, em que descrevemos o problema abordado neste trabalho, nosso objetivo é produzir uma lista de vendedores, ordenada pela probabilidade estimada de cada vendedor ser considerado fraudador. Esse é o principal insumo para o trabalho dos especialistas, que almejam uma lista que os auxilie a identificar os fraudadores (cobertura) e que seja a mais precisa possível, especialmente no topo dessa lista, para que os custos e riscos associados à investigação sejam minimizados.

Sendo assim, tratamos o assunto como um problema de *classificação estatística* (ordenação ou *ranking*) ao invés de tratá-lo simplesmente utilizando classificação tradicional, em que o resultado final seria a separação dos vendedores em dois conjuntos distintos (um de fraudadores e outro de não-fraudadores).

Essa decisão foi tomada após analisar a maneira como os especialistas em detecção de fraude reagem à identificação de um vendedor fraudador. A avaliação sobre qual decisão tomar (por exemplo uma suspensão ou uma advertência, dependendo do caso) é específica

para cada vendedor, por isso uma lista ordenada permite que esse processo seja feito seguindo um critério que privilegie a investigação de vendedores nos quais a probabilidade estimada de fraude seja maior. Por sua vez, uma classificação tradicional baseada em testes de hipóteses não permitiria considerar essa probabilidade, apenas separando os vendedores em dois conjuntos. Além disso, tendo uma lista ordenada, esperamos que venha a ser possível definir valores limiares a partir dos quais seja possível tomar decisões automáticas com base nessa probabilidade estimada. Tais decisões automáticas requerem altíssima precisão, o que normalmente não se obtém em uma classificação tradicional.

Por tudo isso, a questão será tratada como um problema de classificação estatística, produzindo listas de vendedores ordenadas por um determinado índice. Avaliamos as listas produzidas com base em medidas de eficiência como precisão, cobertura, medida-F, precisão média (*Average Precision*) e AIC^1 , como logo vemos a seguir.

Para a validação das características, usamos uma abordagem considerada simples (*naive approach*), mas que se mostrou eficaz até certo ponto [23], na qual selecionamos apenas as que aumentam a chance de fraude, ignorando em um primeiro momento as que diminuem a chance de fraude, e, para cada vendedor, contamos quantas características de fraude este possui. Ao final, geramos uma lista ordenada pela quantidade de características de cada vendedor. Reforçamos que essa é uma técnica extremamente simples, entretanto ela auxilia a validação do procedimento de extração de características.

Tendo a lista ordenada, para cada posição na ordenação, calcula-se a precisão (*precision*), a cobertura (*recall*) e a medida-F ($F\text{-Measure}$)² do topo da lista até essa posição, tendo como referência para esses cálculos a anotação existente na amostra de dados. Dois pontos devem ser observados: a cobertura obtida com as características selecionadas e a precisão obtida especialmente no topo da lista. Em mais detalhes:

- Se a cobertura for baixa, novas características devem ser selecionadas e avaliadas, a partir dos casos não cobertos, principalmente;
- Se a precisão no topo da lista não for considerada satisfatória, seleciona-se os primeiros vendedores da lista ordenada que não foram reconhecidos como fraudadores para uma investigação manual feita por especialistas.

Se os resultados não forem satisfatórios, ou seja, o topo da lista indicar vendedores legítimos nas primeiras posições, deve-se voltar ao processo de extração de características, para rever as características obtidas e para que novas sejam consideradas. Convém observar

¹Mais detalhes sobre AIC estão descritos na Seção 3.2.3.

²Mais detalhes sobre essas medidas estão descritos na Seção 3.2.

que essa situação relativa a características faltantes não aconteceu em nossos experimentos. Acreditamos que, dado nosso conhecimento das regras de negócio do mercado eletrônico utilizado para os experimentos, o processo de extração de características foi feito com maior qualidade.

Tendo selecionado características relevantes e indicadoras de fraude, o passo seguinte é partirmos para aplicação de um método estatístico para ordenar os vendedores com base na probabilidade estimada de fraude.

Neste trabalho utilizamos o método de Regressão Logística³. Posteriormente, a Seção 6.2 irá descrever com detalhes todos os experimentos e estratégias aplicadas com o objetivo de obter uma ordenação em que os resultados dos cálculos de precisão e cobertura sejam satisfatórios.

Não pretendemos no escopo deste trabalho discutir os detalhes do método de Regressão Logística, analisando detalhadamente os coeficientes obtidos ou a correlação entre as características selecionadas. Nosso objetivo é aplicar um método conhecido em um problema relativamente novo, nesse caso, identificação de fraudadores contra o sistema de reputação.

Como a Regressão Logística permite inúmeras variações em sua aplicação, é importante definirmos uma medida para comparar as estratégias de aplicação do método no decorrer dos experimentos. Continuamos utilizando as medidas de precisão, cobertura e medida-F para cada posição da listagem de vendedores, além do valor de *AIC*, que permite ter uma única medida para toda a lista. Outra medida que pode ser aplicada à ordenação da listagem é a precisão média.

Uma vez tendo o resultado do modelo disponível, ou seja, a execução do modelo após a definição da equação inicial, é possível trabalhar na otimização do mesmo por meio de seleção de características, ou simplesmente considerar este resultado como final.

Caso a opção seja por encerrar a aplicação do modelo, acreditamos que seja fundamental uma validação feita por especialistas em detecção de fraudes. Faz-se necessária uma comparação entre as medidas de eficiência obtidas nos dados originais e nos dados revisados para comprovar se os valores obtidos com a revisão indicam melhora ou piora da qualidade da ordenação.

Se a opção for por otimizar o modelo, há uma série de técnicas disponíveis, como a Regressão *Stepwise*⁴, para seleção de características, que podem ser aplicadas.

Além da otimização, retornar ao processo de extração de características é algo que não pode ser descartado. Tendo a lista ordenada, pode-se determinar um limiar que divida os resultados em dois conjuntos, no nosso caso, entre fraudadores e vendedores legítimos.

³Mais detalhes sobre o método de Regressão Logística estão descritos na Seção 3.5.

⁴Mais detalhes sobre a Regressão Stepwise estão descritos na Seção 3.6.

Avaliando o conjunto de fraudadores relatados, devemos analisar os elementos que não são anotados como fraudadores, que em uma classificação tradicional tipicamente seriam denominados *falso-positivos*. Caso se prefira confiar totalmente na anotação, devemos então procurar por características que diminuam a chance desses vendedores serem considerados fraudadores (características negativas). O ideal neste momento, porém, é primeiro solicitar uma verificação da anotação vigente aos especialistas. Aqueles que realmente não forem fraudadores são, então, fonte de extração de características negativas. Outra avaliação similar pode ser feita no conjunto de vendedores legítimos, nesse caso procurando por características que diferenciem os fraudadores erroneamente ali listados. Neste trabalho o limiar adotado para a separação dos conjuntos foi o número de fraudadores conhecidos.

Como as opções de otimização são inúmeras, a definição do ponto de parada caberá a uma análise particular dos resultados obtidos, avaliando as medidas de eficiência. Acreditamos que o mais importante é conseguirmos gerar uma lista ordenada em que a verificação dos vendedores da listagem seja eficaz, ou seja, uma lista em que a precisão seja muito alta no início e na qual seja aceitável decrescê-la à medida que se avança nessa análise. Da mesma forma, é importante que a cobertura em relação aos fraudadores seja a maior possível frente à quantidade de vendedores suspeitos listados.

Uma ferramenta que pode auxiliar nesse sentido é a análise da precisão em função da cobertura. À medida que a cobertura aumenta, a precisão tende a cair. Entretanto, nesse contexto, acreditamos que deve-se objetivar uma precisão alta no início da lista ordenada, para que o esforço do trabalho dos especialistas seja o menor possível nessa parte da lista.

Uma ilustração que sintetiza o que foi apresentado neste capítulo pode ser vista na Figura 5.1. Ela contém os principais passos descritos e fornece uma ideia de como aplicar a metodologia proposta em um estudo de caso real.

Seguindo a metodologia proposta, descrevemos no Capítulo 6 os experimentos realizados utilizando uma amostra de dados reais do mercado eletrônico *TodaOferta*⁵, explicando os procedimentos utilizados e analisando os resultados obtidos.

⁵Mais detalhes sobre a amostra de dados podem ser vistos na Seção 2.6.

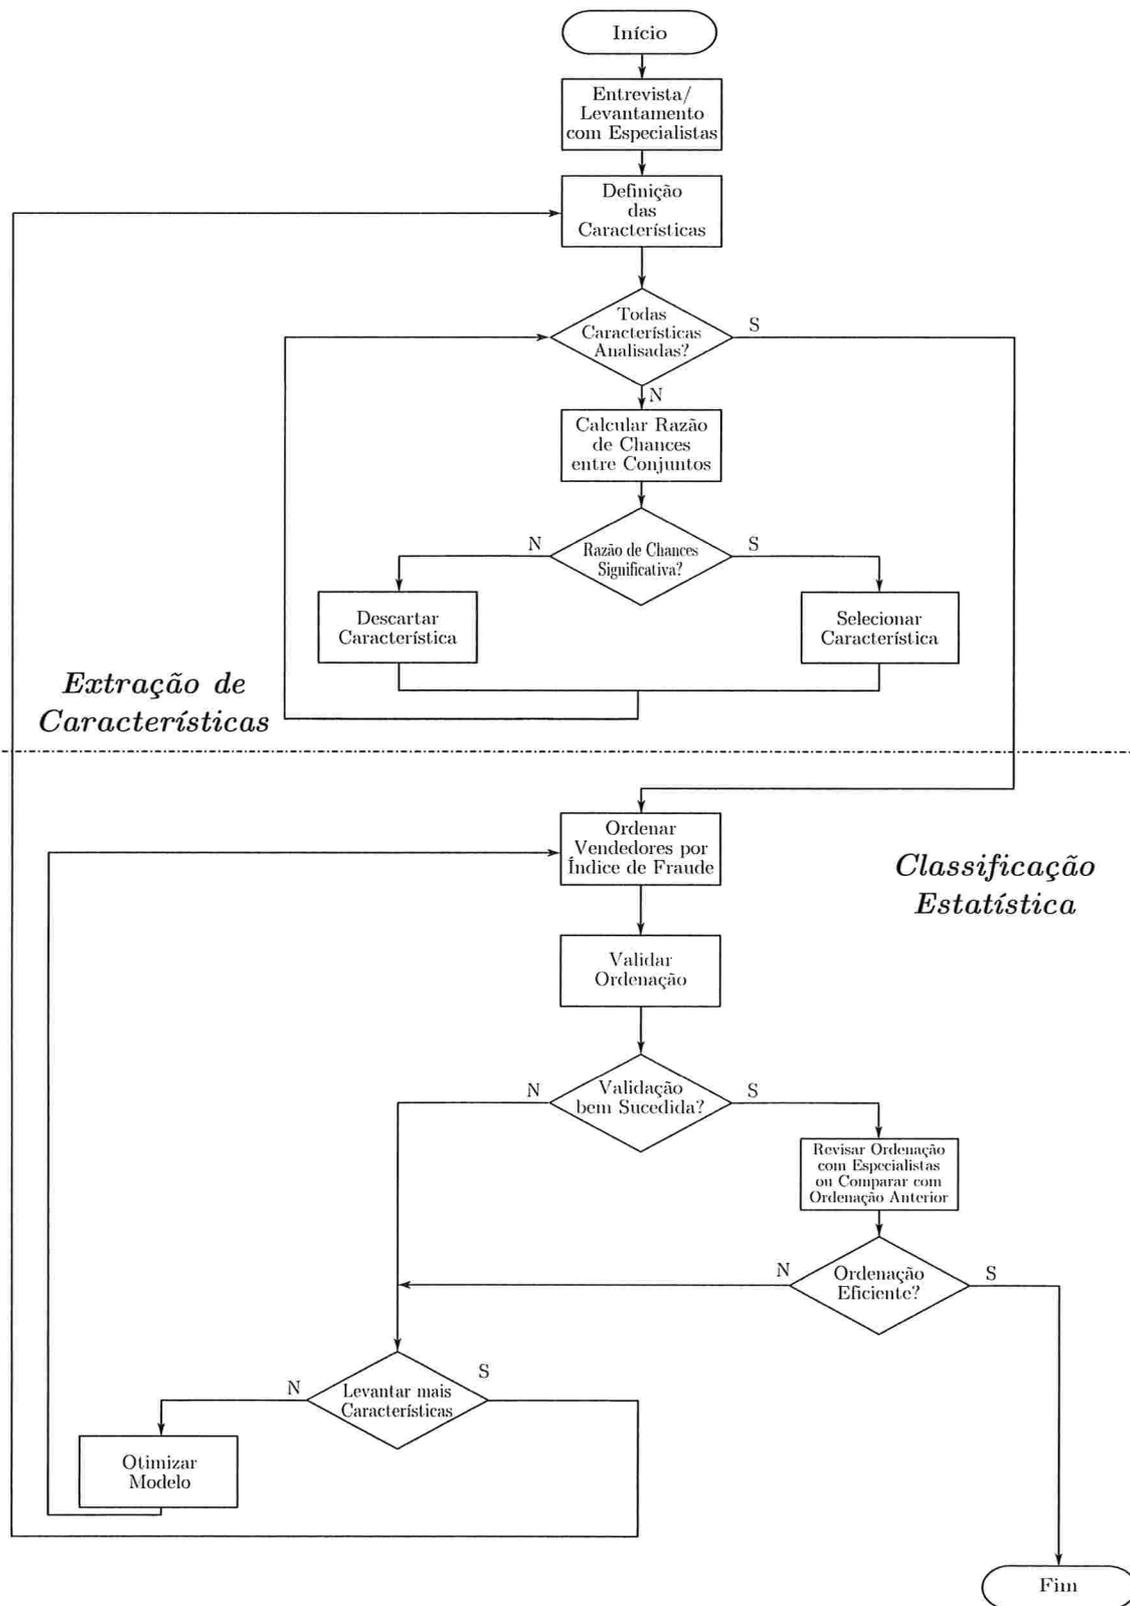


Figura 5.1: Fluxo da Metodologia Proposta

Capítulo 6

Estudo de Caso

Neste Capítulo descrevemos os experimentos que aplicam a metodologia descrita no Capítulo 5 em uma amostra de dados real do mercado eletrônico *TodaOferta*¹.

Primeiramente descrevemos o processo de extração de características e mostramos alguns resultados preliminares. Em seguida, aplicamos um processo estatístico mais robusto para ordenar os fraudadores com base nas características que foram extraídas na primeira etapa. Ao final, mostramos os resultados obtidos na identificação de fraudadores contra o sistema de reputação.

6.1 Extração de Características

Nesta seção abordamos o processo de extração de características que identificam fraudadores contra o sistema de reputação em mercados eletrônicos, que é equivalente à primeira parte da metodologia descrita no Capítulo 5.

Um fato importante a se ressaltar sobre esta seção é que parte dos resultados aqui apresentados foram publicados em artigo na 7ª Conferência Latino-Americana da *Web*² [23]³.

Aplicando a metodologia proposta no Capítulo 5, iniciamos o processo a partir de uma entrevista com especialistas em detecção de fraude do mercado eletrônico *TodaOferta* e chegamos ao final dessa seção com uma seleção de características que comprovaram ser eficazes na identificação de fraudadores. Entretanto, antes do processo de extração, delimitamos os conjuntos de transações e vendedores sobre os quais trabalhamos, definindo algumas propriedades desses conjuntos.

¹Mais detalhes sobre a amostra de dados podem ser vistos na Seção 2.6.

²<http://latin-web.org/laweb09/>

³Alguns valores estão ligeiramente diferentes se compararmos a publicação do artigo e este trabalho, pois a amostra de dados utilizada não foi exatamente a mesma. De qualquer forma, a metodologia empregada foi idêntica.

6.1.1 Definição dos Conjuntos de Transações e Vendedores

Uma consideração importante neste trabalho é que dentro do universo de todas as transações realizadas, consideramos apenas aquelas que resultaram em qualificação positiva, pois este trabalho está direcionado para a identificação de fraudadores contra o sistema de reputação que afetem positivamente a pontuação do vendedor. Chegamos a realizar alguns experimentos considerando todas as transações disponíveis, ou seja, todas as transações independentemente da qualificação recebida, mas os resultados obtidos não trouxeram vantagens da detecção das fraudes contra o sistema de reputação. Certamente, em um trabalho futuro para tratar outros tipos de fraude que ocorrem em mercados eletrônicos, todas as transações devem ser consideradas e analisadas.

Com base nas informações obtidas na entrevista, definimos 3 conjuntos de transações, que apresentamos a seguir⁴:

$$\begin{aligned} NFrT &= \{\text{Transações sem Fraude}\}; \\ AFrT &= \{\text{Transações com Algum tipo de Fraude}\}; \\ FRST &= \{\text{Transações com Fraude contra o Sistema de Reputação}\}. \end{aligned}$$

Considerando as definições acima, podemos observar as propriedades:

$$\begin{aligned} FRST &\subset AFrT; \\ AFrT \cap NFrT &= \emptyset; \\ AFrT \cup NFrT &= \{\text{Todas as Transações}\}. \end{aligned}$$

Vale lembrar que até podemos detectar fraude em uma transação ou nos seus eventos relacionados, mas que o objetivo final é encontrar o vendedor fraudador, independentemente do evento gerador de fraude. Sendo assim, além dos conjuntos das transações, similarmente definimos o conjunto de vendedores. Se um vendedor participa de ao menos uma transação fraudulenta, ele é considerado fraudador, não importando quantas transações possui. Portanto, definimos os seguintes conjuntos de vendedores:

$$\begin{aligned} NFr &= \{\text{Vendedores sem Fraude}\}; \\ AFr &= \{\text{Vendedor com Alguma Fraude}\}; \\ FRS &= \{\text{Vendedores com Fraude contra o Sistema de Reputação}\}. \end{aligned}$$

⁴Decidimos por manter *FRST* do acrônimo em inglês de “*Fraud against Reputation System - Transaction*”, pois nos artigos que publicamos já utilizamos este acrônimo [23, 24].

A Figura 6.1 ilustra esses conjuntos e suas relações.

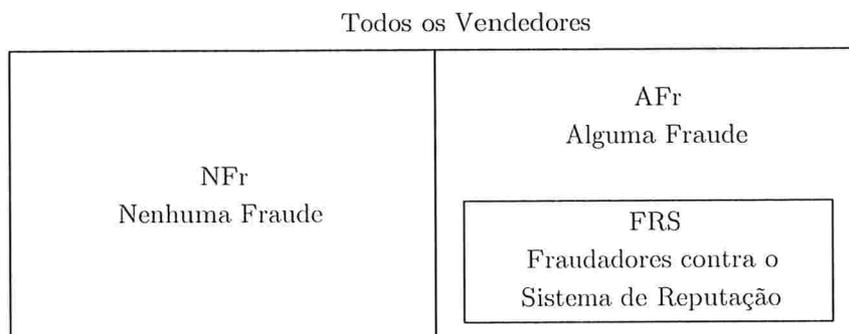


Figura 6.1: Conjunto dos Vendedores e Tipos de Fraude

Tendo definido esses conjuntos e suas propriedades, o próximo passo do estudo de caso é levantar características que possam identificar fraudadores contra o sistema de reputação.

6.1.2 Entrevista com Especialistas

A fim de conhecer melhor os procedimentos de análise e detecção de fraude e quais seriam as características analisadas na identificação da mesma, fizemos uma reunião inicial com os funcionários do *TodaOferta* responsáveis pela investigação e prevenção de fraude nesse mercado eletrônico. Essa entrevista é o primeiro passo da metodologia proposta no Capítulo 5. Ao longo do texto os denominamos de *especialistas em detecção de fraude*, ou simplesmente *especialistas*.

Eles nos explicaram que na grande parte do seu tempo não havia um trabalho preventivo, ou seja, a maioria do esforço era destinada a atender e tratar denúncias de fraude, dificultando o trabalho de prevenção, que poderia ser feito para evitar fraudes e melhorar a credibilidade do mercado eletrônico.

Uma observação importante em relação à regra de identificação de fraude e que será utilizada no decorrer deste trabalho foi enfatizada pelos especialistas em detecção de fraude:

Se existir ao menos uma transação de um vendedor que fraude o sistema de reputação, este vendedor é considerado fraudador contra o sistema de reputação, não importando a quantidade de transações realizadas por ele.

Disseram também que a penalização ao vendedor fraudador poderia variar, sendo simplesmente a sua inabilitação e exclusão de seu cadastro, ou uma suspensão, ou uma notificação ou apenas um registro para suportar e embasar decisões futuras em caso de reincidência.



Em relação às características de fraude, eles nos disseram que nas suas análises utilizam principalmente a existência de um mesmo identificador na estação de trabalho⁵, um mesmo endereço IP do vendedor e do comprador, e um intervalo curto de tempo entre a transação e a qualificação da mesma. Às vezes, eles também consultam os dados cadastrais do vendedor em outros bancos de dados que o *UOL* (a quem pertence o mercado eletrônico *TodaOferta*) possui, mas, em geral, conseguem solucionar os casos sem a necessidade desta última opção.

Foi também discutida a possibilidade de empregar o uso dessas características nas diferentes situações em que há alguma ação do comprador ou vendedor, como por exemplo o evento de cadastro dos mesmos. A Figura 6.2 exibe os eventos relacionados que acontecem antes, durante e depois da transação em um mercado eletrônico. Neste caso, utilizamos as

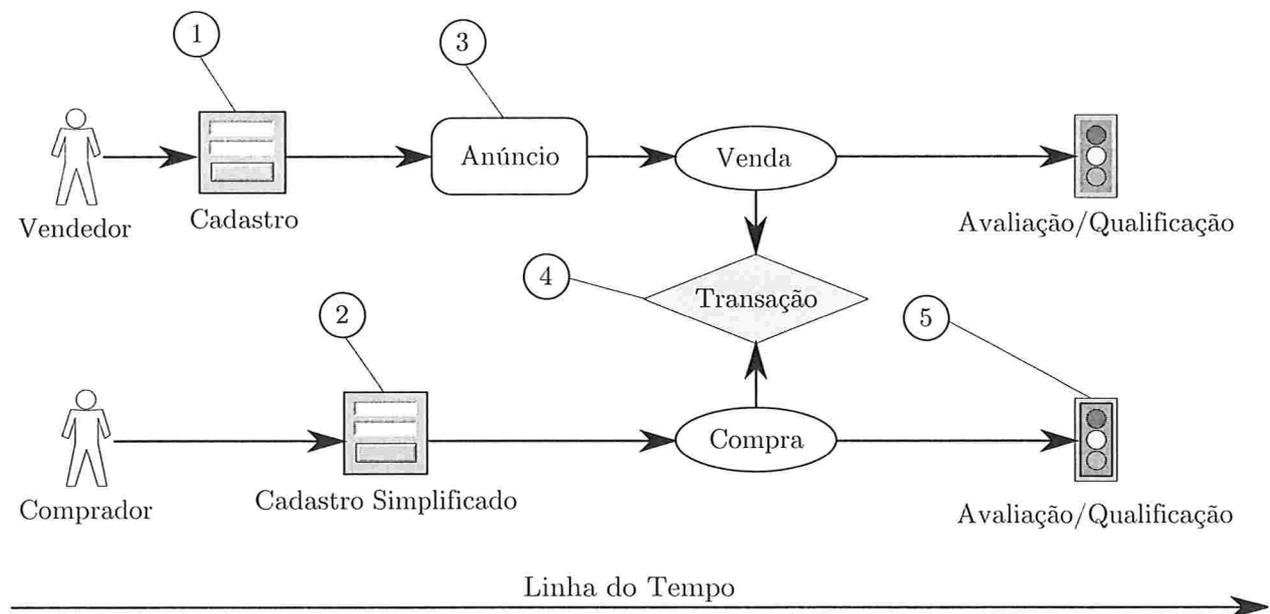


Figura 6.2: Linha do Tempo dos Eventos Relacionados à Transação no Mercado Eletrônico

informações do contexto do problema para auxiliar na identificação dos fraudadores.

Como vemos na Figura 6.2, temos 5 eventos que podem ser analisados:

1. Cadastro do Vendedor: é o ato em que o vendedor se registra no mercado eletrônico;
2. Cadastro do Comprador: é o ato em que o comprador se registra no mercado eletrônico. O cadastro é mais simples e o comprador preenche um formulário com menos atributos que o Vendedor;

⁵Os detalhes para geração e formação deste identificador não foram ditos, mas para este trabalho o que importa é considerar a existência da característica “mesmo identificador”.

3. Cadastro do Anúncio: é o ato em que o vendedor cadastra o anúncio que posteriormente será objeto de uma transação;
4. Transação: é ato em que o comprador opta por iniciar a compra de um ou mais itens anunciados;
5. Avaliação/Qualificação do comprador: é o ato em que o comprador avalia o vendedor na transação efetuada.

Considerando os itens anteriores, observamos que o evento de Avaliação/Qualificação efetuada pelo vendedor não foi considerado. Essa decisão se deve ao fato de que a fraude de qualificação que estamos estudando é aquela que tem como objetivo fraudar o sistema de reputação, distorcendo-o, para melhorar o posicionamento do vendedor. Obviamente é possível fraudar o sistema de reputação também para forjar qualificação de comprador, mas além de ser bem menos frequente e menos relevante ao contexto de fraudes contra o sistema de reputação, não faz parte do escopo deste trabalho. Sendo assim, podemos considerar *seis combinações* entre *dois eventos associados ao vendedor* e *três eventos associados ao comprador*:

1. Cadastro do Vendedor contra Cadastro do Comprador;
2. Cadastro do Vendedor contra Transação iniciada pelo Comprador;
3. Cadastro do Vendedor contra Qualificação efetuada pelo Comprador;
4. Cadastro do Anúncio contra Cadastro do Comprador;
5. Cadastro do Anúncio contra Transação iniciada pelo Comprador;
6. Cadastro do Anúncio contra Qualificação efetuada pelo Comprador.

Ainda na continuidade dessa reunião, iniciamos uma discussão sobre quais outras características poderiam ser utilizadas. Essa discussão foi pautada na experiência de negócio dos envolvidos e veremos posteriormente que algumas das características foram úteis para a modelagem, enquanto que outras não se comprovaram significativas para identificação de fraude contra o sistema de reputação.

O passo seguinte ao levantamento é verificar a existência das características na amostra de dados – tanto as características já utilizadas pelos especialistas, quanto as possíveis que discutimos e que não eram ainda consideradas. A seção seguinte descreve esse processo de seleção de características para identificação de fraudadores contra o sistema de reputação.

6.1.3 Seleção de Características

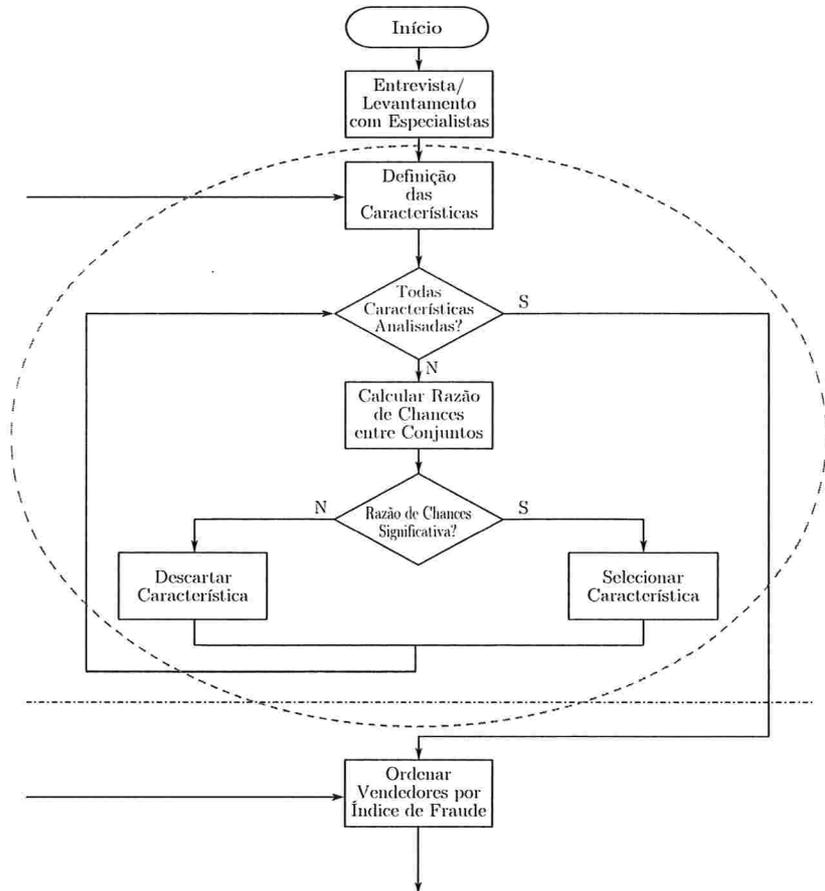
Com os conjuntos e algumas características definidas, o passo seguinte da metodologia é selecionar as características indicativas de fraude. O processo de seleção iniciou pela listagem das mesmas a fim de posteriormente verificá-las na amostra de dados. O levantamento teve como base a entrevista descrita na Seção 6.1.2 e o conhecimento das regras do mercado eletrônico.

Considerando as duas principais características analisadas pelos especialistas (mesmo identificador de estação e mesmo endereço IP), e aplicando-

as às seis combinações de eventos relacionados à negociação, chegamos a doze características, as quais identificamos com um acrônimo⁶ e listamos a seguir:

- Mesmo Identificador de Estação de trabalho para Anúncio e Comprador (MEAC);
- Mesmo Identificador de Estação de trabalho para Vendedor e Comprador (MEVC);
- Mesmo Identificador de Estação de trabalho para Anúncio e Transação (MEAT);
- Mesmo Identificador de Estação de trabalho para Anúncio e Qualificação (MEAQ);
- Mesmo Identificador de Estação de trabalho para Vendedor e Qualificação (MEVQ);

⁶Parte destas características foram utilizadas em publicações [23, 24] em inglês utilizando diferentes acrônimos. Caso haja interesse em verificar a correspondência entre o que publicamos neste trabalho e o que já foi publicado nos artigos, listamos na Tabela D.1 a correspondência entre esses acrônimos.



- Mesmo Identificador de Estação de trabalho para Vendedor e Transação (MEVT);
- Mesmo Endereço IP para Anúncio e Comprador (MIAC);
- Mesmo Endereço IP para Vendedor e Comprador (MIVC);
- Mesmo Endereço IP para Anúncio e Transação (MIAT);
- Mesmo Endereço IP para Anúncio e Qualificação (MIAQ);
- Mesmo Endereço IP para Vendedor e Qualificação (MIVQ);
- Mesmo Endereço IP para Vendedor e Transação (MIVT).

Em relação ao anúncio do vendedor listamos mais 4 características:

- Aceitação do meio de pagamento integrado, que neste caso é o *PagSeguro*⁷ (APS1);
- Não aceitação do meio de pagamento integrado, que neste caso é o *PagSeguro* (APS0);
- Utilização de Destaque no anúncio (DTQ1);
- Não Utilização de Destaque no anúncio (DTQ0).

Em relação ao vendedor temos mais duas características:

- Vendedor editorialmente reconhecido (REC1);
- Vendedor editorialmente não reconhecido (REC0).

E ainda resta uma característica relativa à transação:

- Transação completada no meio de pagamento integrado (TCPS).

Como podemos observar, essas características listadas são determinadas por meio de uma verificação binária, onde se comprova ou não a existência da mesma. Além delas, verificamos características não binárias, onde existe um limiar associado às mesmas, como por exemplo, o intervalo de tempo entre a negociação e a qualificação. Para casos como este, particionamos o período em intervalos regulares e verificamos, para cada um desses intervalos, a razão de chances entre *FRST* e todas as transações e também a razão de chances entre *NFrT* e todas as transações. Tendo a razão de chances calculada para cada uma desses conjuntos e períodos, encontramos o limiar onde a razão de chances de *FRST* se torna menor que a de

⁷<http://www.pagseguro.com.br>

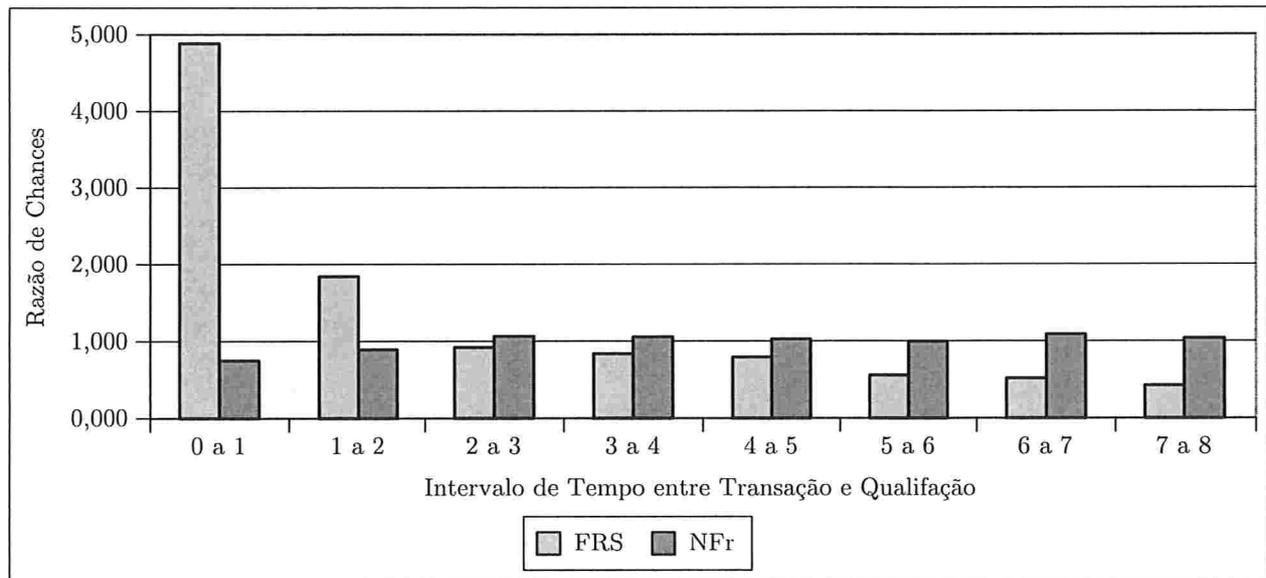


Figura 6.3: Exemplo de Determinação de Limiar para Característica Não Binária

$NFrT$, e utilizamos esse limiar como referência para indicar se a transação possui ou não a característica.

O gráfico da Figura 6.3 mostra um exemplo desse procedimento, no qual dividimos o intervalo de tempo entre a transação e a qualificação em alguns períodos, do instante 0 a 1, de 1 a 2, até de 7 a 8, e calculamos a razão de chances como explicado anteriormente para cada um desses períodos. No caso do exemplo desse gráfico, o limiar determinado é o instante 2, a partir do qual observamos que a razão de chances de $NFrT$ se torna maior que $FRST$.

Esse limiar é o que chamamos de N na descrição de cada característica⁸ que listamos a seguir:

- Avaliação rápida de compradores, não mais que N horas após a transação (ARCT);
- Baixa taxa de visitas por transações efetuadas, menores que N , por anúncio (BTVT);
- Intervalo de tempo entre a publicação do anúncio e a transação menor que N horas (ITAT).

Com o limiar definido, podemos adotar o mesmo procedimento das características binárias, nas quais verificamos se elas ocorrem ou não nos conjuntos de transações fraudulentas.

⁸Por questões do acordo de confidencialidade com o mercado eletrônico *TodaOferta*, não podemos divulgar o valor exato de N nas características extraídas.

Além dessas, determinamos características relativas ao conjunto de transações do anúncio. Tivemos também que estabelecer um número mínimo de transações para a determinação da existência ou não da característica, pois com apenas uma ou duas transações, por exemplo, as características selecionadas não seriam discriminantes. São elas:

- Mesmo domínio dos *e-mails* dos compradores dentro das transações do anúncio, considerando ao menos N transações (UDTC);
- E-mails com o mesmo domínio entre comprador e vendedor, considerando ao menos N transações (MDVC).

Após a definição dessas características, o passo seguinte foi comprovar se cada uma delas era ou não uma característica realmente relacionada à fraude contra o sistema de reputação. Como as características ocorrem também em transações legítimas, temos que verificar como esse ruído afeta a identificação dos fraudadores a partir das mesmas.

Sendo assim, seguindo o que definimos na metodologia para seleção das características, para cada uma delas, calculamos a razão de chances da característica no conjunto de transações identificadas como fraude contra o sistema de reputação ($FRST$) em relação ao conjunto de transações legítimas ($NFrT$) e a razão inversa. A Tabela 6.1 lista todas as características com o respectivo valor da razão de chances calculado entre $NFrT$ e $FRST$ e o inverso, ordenadas pelo valor da razão de chances entre $FRST$ e $NFrT$ para facilitar análises subsequentes.

Observamos que algumas características, como por exemplo as listadas no início, ocorrem com uma frequência muito maior nas transações fraudulentas. Outras características, como a “Não Utilização de Destaque no anúncio” (DTQ0), tem praticamente o mesmo percentual de ocorrência nas transações $FRST$, $NFrT$ e todas as transações. Por outro lado, o fato do vendedor ser editorialmente reconhecido (REC1) faz com que a razão de chances seja próxima de zero, indicando que essa característica diminui a chance de uma transação de um vendedor reconhecido ser fraudulenta.

Além da verificação feita nas transações, expandimos a análise para os vendedores. Para cada característica, calculamos a razão de chances entre NFr e FRS e a razão inversa, e é esperado que os valores obtidos no cálculo dessas razões sejam diferentes entre as transações e os vendedores. Essa expansão foi feita criando uma lista de vendedores a partir das transações, e a existência da característica era determinada pela existência de pelo menos uma transação com tal evidência. A Tabela 6.2 mostra os resultados obtidos, também ordenados pelo valor da razão de chances entre FRS e NFr .

Com base nos valores encontrados nas Tabelas 6.1 e 6.2, arbitrariamente decidimos por considerar apenas as características que possuíam valor de razão de chances maior ou igual

Característica	% em <i>FRST</i>	% em <i>NFrT</i>	% em Todas as Transações	Razão de Chances entre <i>FRST</i> e <i>NFrT</i>	Razão de Chances entre <i>NFrT</i> e <i>FRST</i>
MIVQ	26,1%	1,0%	3,1%	34,698	0,029
MIVT	27,6%	1,1%	3,4%	33,625	0,030
MIVC	26,0%	1,2%	3,4%	28,055	0,036
MIAQ	30,5%	2,0%	4,5%	21,059	0,047
MIAT	34,7%	2,5%	5,3%	20,320	0,049
MIAC	29,8%	2,3%	4,5%	18,254	0,055
MDCV	16,5%	1,2%	2,5%	17,025	0,059
MEVT	15,3%	1,4%	2,7%	12,928	0,077
MEVQ	13,5%	1,3%	2,4%	12,197	0,082
MEVC	14,3%	1,4%	2,6%	11,464	0,087
MEAT	23,7%	3,0%	5,0%	9,926	0,101
MEAQ	19,5%	2,6%	4,3%	9,110	0,110
ARCT	58,3%	13,4%	17,6%	9,056	0,110
MEAC	19,3%	2,8%	4,3%	8,412	0,119
BTVT	39,4%	10,4%	12,9%	5,604	0,178
UDTC	26,8%	6,4%	7,9%	5,367	0,186
ITAT	34,7%	11,9%	15,4%	3,937	0,254
APS0	68,1%	46,1%	48,9%	2,496	0,401
REC0	79,8%	66,5%	72,0%	1,989	0,503
DTQ0	26,2%	25,1%	26,2%	1,058	0,945
DTQ1	73,8%	74,9%	73,8%	0,945	1,058
APS1	32,5%	53,9%	51,1%	0,411	2,434
TCPS	2,8%	11,4%	21,0%	0,224	4,458
REC1	1,1%	27,1%	22,8%	0,030	33,405

Tabela 6.1: Características, Cobertura e Razão de Chances nas Transações

a 3 dentro das transações. Vale observar que as BTVT e UDTC tiveram razão de chance menor que 3 quando analisamos os vendedores, mas o limiar considerado para seleção das características considerava a razão de chances da característica nas transações.

Certamente poderíamos ter escolhido outro limiar, mas consideramos essa possibilidade como um trabalho futuro. Denominamos essas características como *características positivas de fraude*, já que suas presenças são indícios positivos de fraude.

Outra análise que podemos fazer com os dados das Tabelas 6.1 e 6.2 é em relação às características com valores de razão de chances próximos de zero. Essas características indicam que a existência da mesma diminui a probabilidade dela ser encontrada nas transações ou vendedores fraudulentos. Denominamos essas características como *características negativas de fraude*.

Característica	% em <i>FRS</i>	% em <i>NFr</i>	% em Todos os Vendedores	Razão de Chances entre <i>FRS</i> e <i>NFr</i>	Razão de Chances entre <i>NFr</i> e <i>FRS</i>
MIVQ	27,5%	2,8%	5,1%	13,196	0,076
MIVN	29,8%	3,2%	5,8%	12,662	0,079
ARCT	86,1%	33,1%	38,6%	12,548	0,080
MIVC	29,8%	3,5%	6,2%	11,844	0,084
MIAN	46,8%	7,5%	11,1%	10,801	0,093
MIAQ	38,6%	6,1%	8,9%	9,665	0,103
MEAN	46,4%	8,4%	11,8%	9,432	0,106
MIAC	39,3%	6,6%	9,5%	9,163	0,109
MEVN	30,5%	4,6%	7,1%	9,045	0,111
MEVC	30,2%	4,7%	7,1%	8,793	0,114
MEAC	40,7%	7,5%	10,2%	8,459	0,118
MEAQ	40,7%	7,6%	10,5%	8,329	0,120
MEVQ	26,8%	4,3%	6,4%	8,185	0,122
MDCV	22,4%	5,3%	6,7%	5,200	0,192
ITAT	44,1%	16,8%	19,7%	3,891	0,257
BTVT	53,6%	28,6%	30,7%	2,885	0,347
UDTC	39,3%	25,6%	26,8%	1,885	0,530
APS0	14,1%	13,2%	13,3%	1,075	0,930
REC0	17,4%	17,8%	17,6%	0,975	1,026
DTQ1	13,0%	13,9%	13,3%	0,926	1,080
DTQ0	7,1%	8,0%	8,0%	0,874	1,144
APS1	5,3%	7,1%	6,6%	0,739	1,354
REC1	0,4%	0,8%	0,6%	0,560	1,786
TCPS	0,9%	2,9%	2,6%	0,309	3,232

Tabela 6.2: Características, Cobertura e Razão de Chances entre Vendedores

Com base nos critérios que definimos ao longo dessa seção, características selecionadas estão listadas na Tabela 6.3.

A próxima etapa da aplicação da metodologia é validar se essas características permitem a identificação de fraudadores contra o sistema de reputação, com base em uma ordenação específica.

6.1.4 Contagem de Características

A fim de verificar a efetividade e comprovar se as características selecionadas realmente identificam fraudadores contra o sistema de reputação, decidimos empregar um método simples de contagem de características para ordenar a lista de vendedores. Essa validação é o que descrevemos na metodologia, no Capítulo 5, como o passo seguinte à seleção das características. Verificamos que, neste trabalho, as características extraídas foram suficientes

Característica	Descrição	Tipo
ARCT	Avaliação rápida de compradores, não mais que N horas após a transação	Positiva
BTVT	Baixa taxa de visitas por transações, menores que N	Positiva
ITAT	Intervalo de tempo entre a publicação do anúncio e a transação menor que N horas	Positiva
MDVC	E-mails com o mesmo domínio entre comprador e vendedor, considerando ao menos N transações	Positiva
MEAC	Mesmo Identificador de Estação de trabalho para Anúncio e Comprador	Positiva
MEAQ	Mesmo Identificador de Estação de trabalho para Anúncio e Qualificação	Positiva
MEAT	Mesmo Identificador de Estação de trabalho para Anúncio e Transação	Positiva
MEVC	Mesmo Identificador de Estação de trabalho para Vendedor e Comprador	Positiva
MEVQ	Mesmo Identificador de Estação de trabalho para Vendedor e Qualificação	Positiva
MEVT	Mesmo Identificador de Estação de trabalho para Vendedor e Transação	Positiva
MIAC	Mesmo Endereço IP para Anúncio e Comprador	Positiva
MIAT	Mesmo Endereço IP para Anúncio e Transação	Positiva
MIAQ	Mesmo Endereço IP para Anúncio e Qualificação	Positiva
MIVC	Mesmo Endereço IP para Vendedor e Comprador	Positiva
MIVQ	Mesmo Endereço IP para Vendedor e Qualificação	Positiva
MIVT	Mesmo Endereço IP para Vendedor e Transação	Positiva
REC1	Vendedor editorialmente reconhecido	Negativa
TCPS	Transação completada no meio de pagamento integrado	Negativa
UDTC	Mesmo domínio dos <i>e-mails</i> dos compradores dentro das transações do anúncio, considerando ao menos N transações	Positiva

Tabela 6.3: As 19 Características Binárias Selecionadas

para identificar fraudadores, de modo que não tivemos a necessidade de retornar ao processo de extração de características. É importante ressaltar que esse método permite somente que utilizemos características positivas, ou seja, aquelas que identifiquem a ocorrência da fraude. Portanto, não podemos considerar características cujas presenças sejam indicativas de não-fraude, já que esse método de contagem apenas soma as características de fraude sem levar o peso de cada um delas na amostra de dados. Até poderíamos subtrair as características negativas, mas o propósito dessa contagem era validar as características extraídas, e a maioria delas era característica positiva de fraude.

Um exemplo desse tipo de característica é o reconhecimento editorial (REC1), onde o vendedor ou pode enviar sua documentação para uma análise cadastral ou o vendedor tem um relacionamento comercial com o mercado eletrônico. Essa característica possui um valor de razão de chances de 0,030 se utilizarmos o percentual nas transações e 0,560 para os vendedores.

Por outro lado, se calcularmos a razão de chances entre as transações não fraudulentas ($NFrT$) e as transações que fraudaram o sistema de reputação ($FRST$), invertendo a razão, o valor obtido é 33,405, o que nos leva a concluir que o fato da existência dessa característica diminui a probabilidade de fraude. Considerando o valor da razão de chances no conjunto de vendedores, o valor obtido é 1,786. Analogamente acontece para a característica TCPS, que nas transações tem razão de chances igual a 4,458 e nos vendedores 3,232.

Como a verificação de contagem de características trata somente de características positivas de fraude, as características REC1 e TCPS foram excluídas da contagem, restando então 17 (dezessete) características para a análise. A fim de verificar se essas realmente eram as melhores para identificar fraudadores contra o sistema de reputação, ordenamos a lista de vendedores com base no número de características que representam indicadores de fraude. A medição de eficiência dessa abordagem de ordenação simples foi feita utilizando-se medidas frequentemente utilizadas nas áreas de Aprendizado Computacional e de Recuperação de Informação, como precisão, cobertura, medida-F e precisão média, já definidas na Seção 3.2 e utilizadas na descrição da metodologia. A Tabela 6.4 exibe os valores encontrados para estas três medidas. Observamos que o melhor valor da medida-F ocorre quando consideramos vendedores com ao menos cinco características positivas de fraude.

Podemos observar estes valores também no gráfico da Figura 6.4, onde vemos que a precisão é decrescente à medida que diminuimos o número de características por vendedor. Por outro lado, a cobertura aumenta gradativamente com essa diminuição de características consideradas. Em relação à precisão média⁹, o valor obtido com essa ordenação foi de 38,9%. Na próxima seção discutimos com mais detalhes os resultados obtidos com esse método simples de validação que utiliza contagem de características como critério de ordenação.

6.1.5 Validações Preliminares

Podemos observar que a ordenação produzida pela abordagem de contagem de características, na Seção 6.1, levou a uma precisão média de 38,9%, e que o maior valor da medida-F (0,416) ocorre quando analisamos os vendedores com 5 ou mais características de fraude. Nesse ponto, a cobertura é de 60,3% e a precisão é 31,8%, conforme observado na Tabela 6.4. Se por um lado desejávamos precisões maiores, também estávamos cientes de que

⁹A precisão média está descrita na Seção 3.2.1.

Número de Características	Cobertura	Precisão	Medida-F
17	1,4%	100,0%	0,027
16	2,7%	72,7%	0,052
15	6,8%	69,0%	0,123
14	10,5%	59,6%	0,179
13	15,6%	53,5%	0,241
12	19,3%	49,1%	0,277
11	24,4%	48,3%	0,324
10	30,2%	44,7%	0,360
9	33,6%	41,3%	0,370
8	41,0%	37,5%	0,392
7	46,8%	34,0%	0,394
6	51,9%	32,8%	0,402
5	60,3%	31,8%	0,416
4	69,2%	26,5%	0,383
3	76,3%	20,7%	0,325
2	86,1%	16,7%	0,280
1	96,6%	11,5%	0,206

Tabela 6.4: Precisão, Cobertura e Medida-F para Contagem de Características

a anotação dos fraudadores era mais confiável do que a dos vendedores legítimos. Havia suspeitas de que alguns fraudadores não tivessem sido identificados ainda. Iniciamos, assim, um procedimento de validação das características, com o objetivo de comprovar se as características que extraímos seriam suficientes ou se teríamos que extrair novas características para identificação dos fraudadores, ou seja, se existiam características faltantes.

Sendo assim, solicitamos aos especialistas que investigassem os vendedores com pelo menos 10 (dez) características e que não pertenciam ao conjunto *FRS*. Após a revisão, recalculamos os valores obtidos nas medidas de eficiência e os comparamos com os resultados iniciais. A Tabela 6.5 mostra que esse processo simples (contagem de características) conseguiu identificar um número maior de fraudadores. A tabela também mostra que as características selecionadas são relevantes para identificação de fraudadores contra o sistema de reputação – esses fraudadores originalmente eram considerados vendedores legítimos, ou seja, faziam parte do conjunto *NFr*.

Com base nessa revisão, comparamos os resultados da anotação inicial com a nova anotação feita pelos especialistas, a qual chamamos de *amostra revisada*. Observamos que todas as medidas (precisão, cobertura e medida-F) têm um desempenho superior aos apresentados na Tabela 6.4, onde os resultados baseiam-se nos dados originais, não revisados. Em relação à precisão média, obtemos 73,8% na amostra revisada, o que representa um aumento de 89,8% nessa medida.

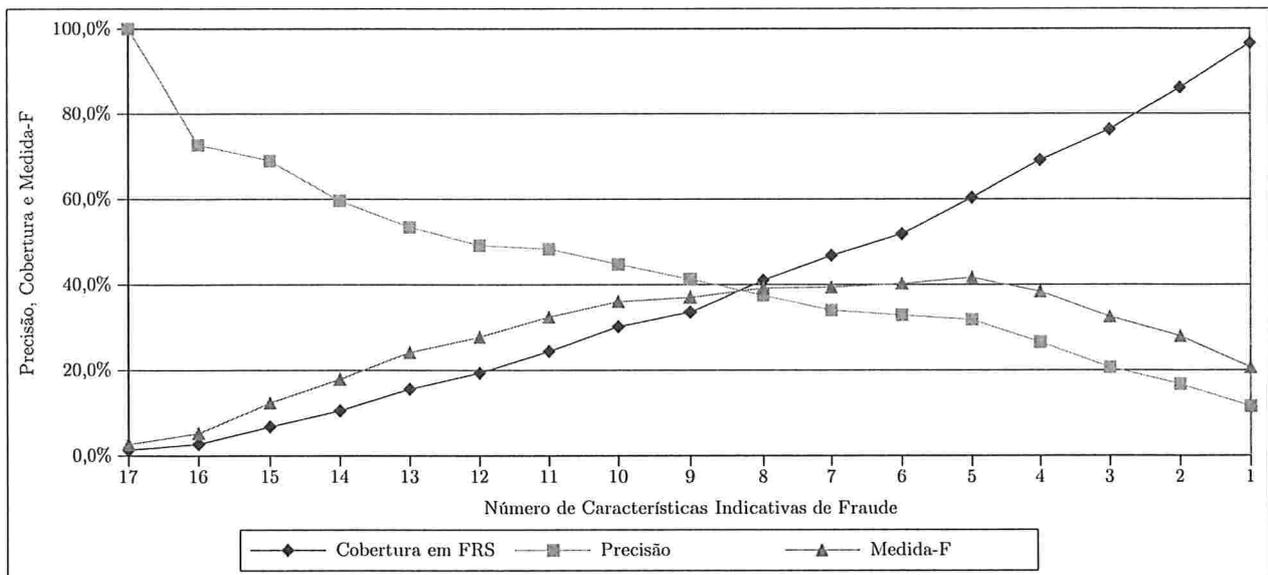


Figura 6.4: Precisão, Cobertura e Medida-F para Contagem de Características

Número de Características	Cobertura	Precisão	Medida-F
17	1,0%	100,0%	0,020
16	2,7%	100,0%	0,053
15	7,2%	100,0%	0,134
14	12,9%	100,0%	0,229
13	21,3%	100,0%	0,352
12	28,8%	100,0%	0,447
11	37,0%	100,0%	0,540
10	48,9%	99,0%	0,654
9	51,4%	86,3%	0,644

Tabela 6.5: Precisão, Cobertura e Medida-F para Contagem de Características - Dados Revisados

Ainda na análise dessa revisão, o gráfico da Figura 6.5 mostra um aumento considerável nos valores obtidos em precisão e em medida-F, o que nos leva a concluir que a abordagem simples utilizada pode ser empregada para identificar uma parte dos fraudadores, além de comprovar que as características selecionadas foram adequadas, validando o processo de seleção.

Por outro lado, essa abordagem permitiu que validássemos as características extraídas, não havendo necessidade de retornar ao processo de extração de características. Observamos também que essa abordagem de contagem de características possui algumas limitações, que serão explicadas a seguir.

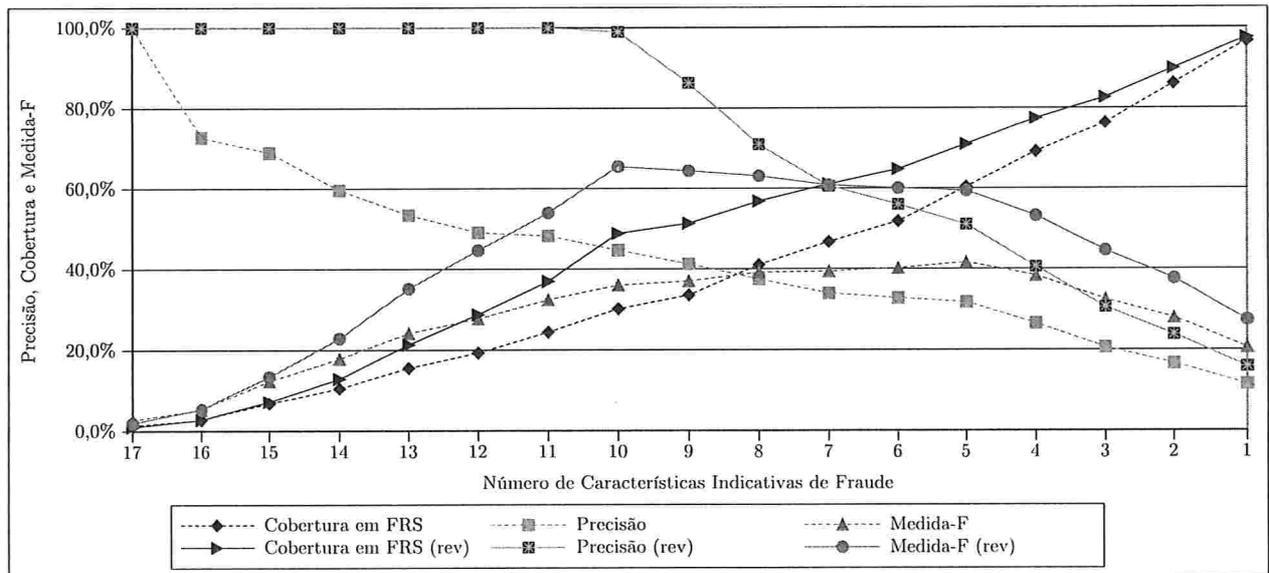


Figura 6.5: Precisão, Cobertura e Medida-F para Contagem de Características - Dados Revisados

6.1.6 Limitações da Abordagem

A primeira das limitações da abordagem de contagem de características está no fato de não ser possível utilizar as características negativas de fraude. Analisando os dados das Tabelas 6.1 e 6.2, observamos as características REC1 e TCPS diminuem a chance do vendedor ser fraudador, mas a contagem de características positivas não permite utilizá-las nessa abordagem.

A segunda limitação reside no fato de apenas utilizar características binárias ou que fossem convertidas a características binárias, não permitindo considerar valores com distribuição contínua, como por exemplo o intervalo de tempo entre a transação e a qualificação – tivemos que estabelecer um limiar e utilizá-lo como referência para determinar se a transação, e conseqüentemente o vendedor, possuía tal característica ou não.

Outra limitação é relacionada à incapacidade de incorporar o percentual de transações com determinada característica em relação a todas transações dos vendedores. Isso faz com que, por exemplo, um vendedor com uma transação contendo a característica de fraude dentre várias transações, possua o mesmo peso que um vendedor que tenha a maioria, ou a totalidade, de transações com a indicação de fraude. E como vimos na Seção 3.4, utilizar os conhecimentos do contexto e do negócio são problemas recorrentes da área de Reconhecimento de Padrões, que também se preocupa com os custos da classificação.

Na seção seguinte colocamos em prática a aplicação do método de Regressão Logística¹⁰ que sucedeu a validação feita pelo método de contagem de características. Embora não

¹⁰Mais detalhes teóricos sobre o método estão na Seção 3.5.

seja o objetivo do trabalho empregar e avaliar esse método, uma comparação rápida entre seus resultados e aqueles obtidos pela primeira das estratégias utilizadas com a Regressão Logística pode ser encontrada no Apêndice E. De fato, diferentes estratégias de Regressão Logística foram utilizadas até encontrar uma ordenação eficiente que se baseia nas medidas de precisão, cobertura e medida-F, mas também em precisão média e valor de *AIC*.

6.2 Aplicação do Método de Regressão Logística

Nesta seção aplicamos o método de Regressão Logística para ordenar a lista de vendedores com base na probabilidade estimada de cada um deles ser considerado fraudador contra o sistema de reputação. Essa ordenação contém os passos finais da metodologia proposta no Capítulo 5, referentes à classificação estatística, que estão ressaltados na Figura 6.6.

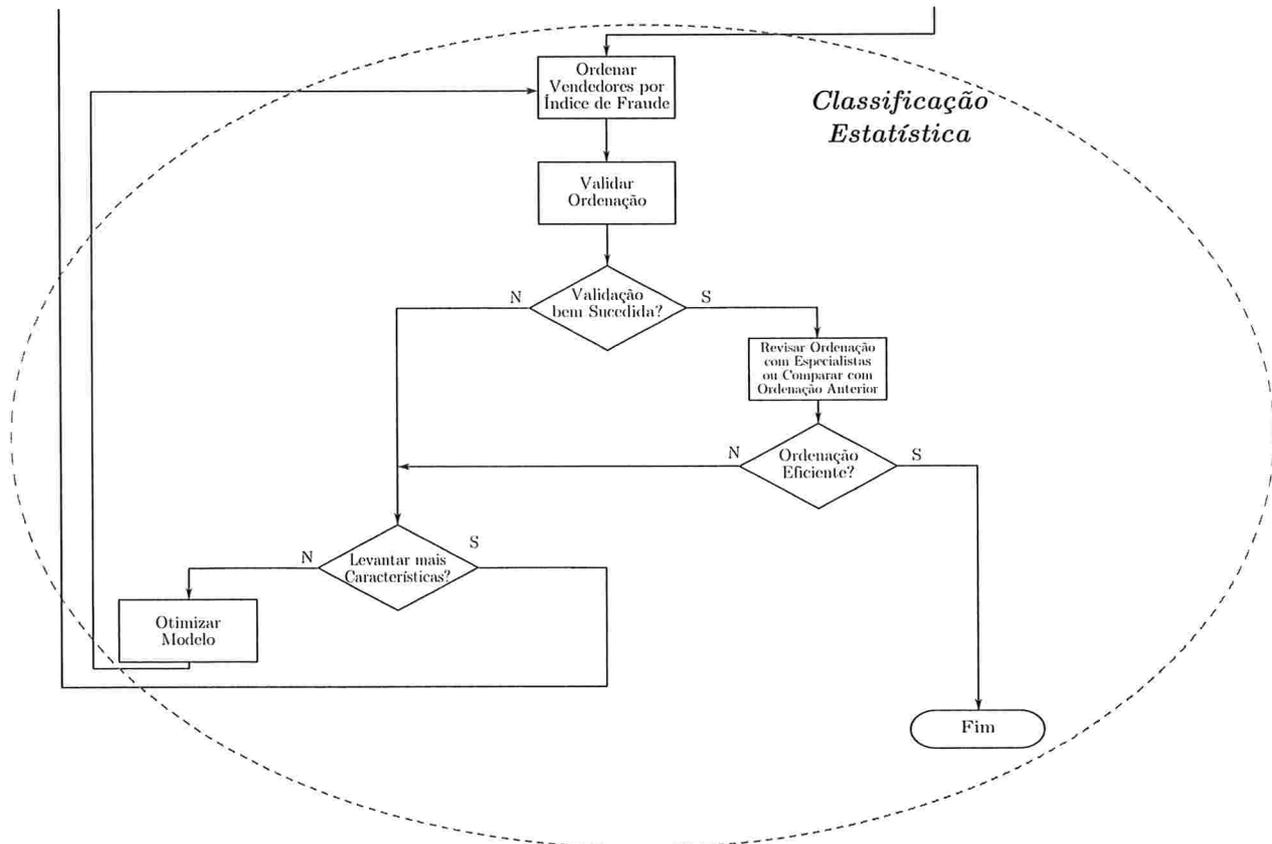


Figura 6.6: Aplicação dos Passos Finais da Metodologia

Da mesma maneira que publicamos em artigo resultados com o procedimento adotado ao longo da Seção 6.1, a parte inicial dos resultados que são exibidos nas próximas seções também foram publicados em outro artigo¹¹ [24] no 25º Simpósio de Computação Aplicada

¹¹ Alguns valores estão ligeiramente diferentes se compararmos a publicação do artigo e este trabalho, pois

da ACM¹² (ACM-SAC¹³), na trilha técnica que trata de confiança e reputação¹⁴.

Para aplicar o método de Regressão Logística na amostra de dados utilizamos o *pacote*¹⁵ *R*, que é uma linguagem e um ambiente para processamento estatístico, distribuído gratuitamente sob licença aberta. No Apêndice B apresentamos um *pseudo-código* que sintetiza o procedimento utilizado no decorrer dos experimentos.

Um fator importante em relação à definição dos conjuntos de transações e às amostras utilizadas na aplicação da Regressão Logística precisa ser explicado com mais detalhes. Inicialmente pensamos em particionar os dados em treinamento e teste, já que a decisão contrária de treinar e testar sobre a totalidade dos dados, e que foi por nós adotada, pode acarretar em um sobreajuste das medidas de eficiência (*overfitting*).

Contudo, a validação das características feita anteriormente já nos mostrava divergências entre os dados anotados originalmente e os dados revisados, pois acaba-se por considerar bem menos fraudadores do que de fato existem na amostra. Acreditávamos de início que usar a máxima informação para o desenvolvimento do modelo poderia compensar as discrepâncias nas anotações, que, acreditávamos, deveria ser mais grave. Ademais, o problema principal do modelo desenvolvido é produzir uma ordenação dos vendedores segundo a probabilidade estimada de fraude, e um eventual sobreajuste (*overfitting*) não necessariamente altera a ordenação.

Outra decisão importante que precisa ser explicada foi o descarte das transações apontadas exclusivamente como *AFrT* na anotação inicial, pois identificamos nessas transações algumas características similares às presentes em *FRST*. O mesmo acontece para o conjunto dos vendedores *AFr* e *FRS*. Exemplificando, apesar de um determinado vendedor ser considerado um fraudador, ele não era especificamente um fraudador contra o sistema de reputação. Como os outros tipos de fraudadores (*AFr – FRS*) não podem ser considerados vendedores legítimos nem fraudadores contra o sistema de reputação, a opção foi por descartar as transações desses vendedores. Por termos definido o escopo do trabalho na identificação dos vendedores fraudadores contra o sistema de reputação e ter analisado características pertinentes apenas a esse conjunto, acreditamos que a análise de outros tipos de fraude seja objeto de trabalho futuro, já que para os mercados eletrônicos, todo tipo de fraude deve ser identificado e prevenido.

Nas seções subsequentes temos aplicações do método de Regressão Logística em diferentes amostras de dados utilizadas não foi exatamente a mesma. De qualquer forma, a metodologia empregada foi idêntica.

¹²<http://www.acm.org>

¹³<http://www.acm.org/conferences/sac/sac2010/>

¹⁴<http://www.trustcomp.org/treck/>

¹⁵<http://www.r-project.org/>

estratégias. Em todas elas, descrevemos a estratégia que vamos aplicar e ao final de cada uma temos uma avaliação dos resultados obtidos. A Figura 6.7 mostra um guia dos experimentos descritos nas próximas seções.

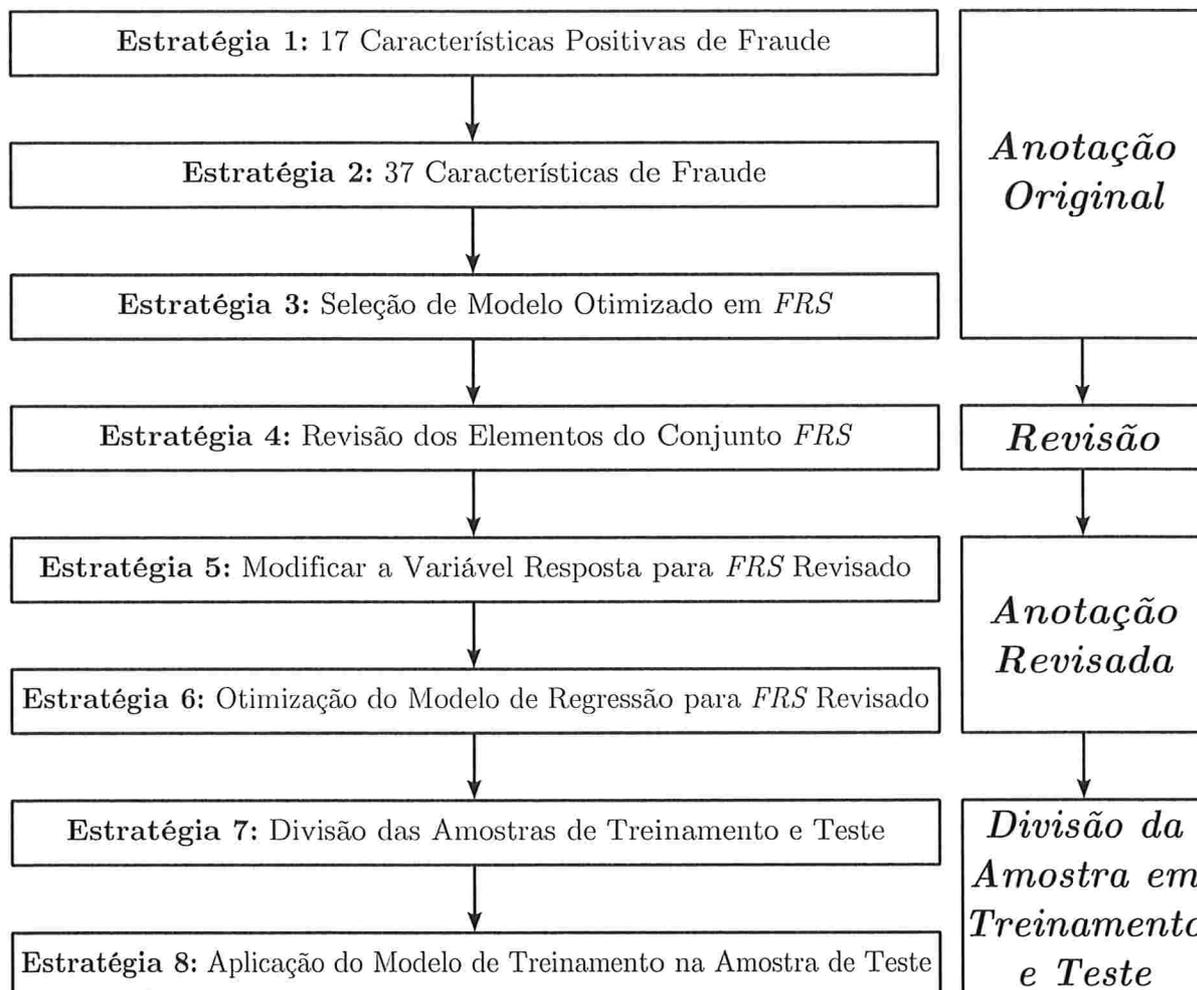


Figura 6.7: Guia das Estratégias

6.2.1 Estratégia 1: 17 Características Positivas de Fraude

Estratégia 1 Ordenar a lista de vendedores considerando somente as 17 características positivas de fraude, as mesmas utilizadas na Seção 6.1.4.

Nessa primeira aplicação do modelo, a variável que se quer descobrir é *FRS* (variável resposta) e as 17 características são as variáveis independentes¹⁶. Utilizando os códigos das características e mantendo o mesmo formato da seção teórica para as variáveis do modelo

¹⁶ No *pacote R*, a fórmula é transcrita da seguinte forma:

$FRS \sim ITAT + MEAC + MEAT + MEAQ + MEVC + MEVT + MEVQ + MDCV + MIAC + MIAT + MIAQ + MIVC + MIVT + MIVQ + ARCT + UDC + BTVT$

(vide Equação 3.1 da Seção 3.5), temos $p = 17$ e:

$$\begin{aligned} x_1 &= \text{ITAT}, x_2 = \text{MEAC}, x_3 = \text{MEAT}, x_4 = \text{MEAQ}, x_5 = \text{MEVC}, \\ x_6 &= \text{MEVT}, x_7 = \text{MEVQ}, x_8 = \text{MDCV}, x_9 = \text{MIAC}, x_{10} = \text{MIAT}, \\ x_{11} &= \text{MIAQ}, x_{12} = \text{MIVC}, x_{13} = \text{MIVT}, x_{14} = \text{MIVQ}, \\ x_{15} &= \text{ARCT}, x_{16} = \text{UDTC}, x_{17} = \text{BTVT}. \end{aligned} \quad (6.1)$$

O gráfico da Figura 6.8 e a Tabela 6.6 mostram o desempenho da primeira aplicação do método de Regressão Logística dessa Estratégia 1, de modo a ordenarmos a lista de vendedores pela probabilidade estimada do vendedor estar em *FRS*. O desempenho foi calculado baseado nas medidas descritas na Seção 3.2. Com a lista ordenada, calculamos a precisão (P1), cobertura (C1) e a medida-F (F1) para cada posição da ordenação, considerando como base os vendedores que estão no intervalo entre o primeiro vendedor listado e o vendedor em questão, à medida que se avança na análise da listagem.

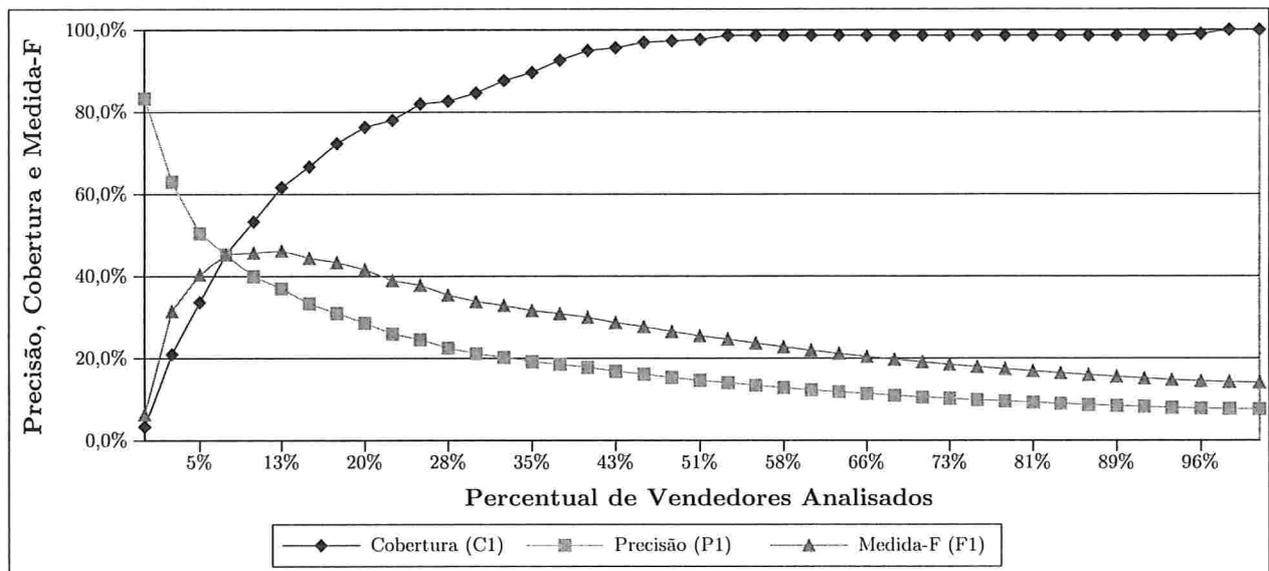


Figura 6.8: Avaliação da Estratégia 1

Os valores observados no gráfico da Figura 6.8 e a Tabela 6.6 mostram o valor calculado dessas medidas a cada percentual de vendedores analisados na listagem. Na tabela, optamos por suprimir alguns percentuais à medida que o percentual de vendedores analisados aumenta, pois as tendências dessas medidas não sofrem alterações significativas. Além disso, tal disposição facilita a leitura e análise dos resultados, principalmente no topo da lista, onde está nosso maior interesse. A saída dessa execução feita no *pacote R* pode ser vista em detalhes no Apêndice C.1.

% Vendedores	C1	P1	F1
1%	10,7%	82,1%	0,189
2%	17,7%	67,9%	0,280
3%	23,3%	59,8%	0,336
4%	29,3%	56,4%	0,386
5%	33,3%	51,3%	0,404
6%	38,0%	48,7%	0,427
7%	41,0%	45,1%	0,429
8%	46,7%	44,9%	0,458
9%	49,7%	42,5%	0,458
10%	52,7%	40,5%	0,458
11%	56,3%	39,4%	0,464
12%	59,7%	38,2%	0,466
13%	62,0%	36,7%	0,461
14%	62,7%	34,4%	0,444
15%	65,0%	33,3%	0,441
16%	69,0%	33,2%	0,448
17%	71,0%	32,1%	0,442
18%	72,3%	30,9%	0,433
19%	74,3%	30,1%	0,428
20%	76,0%	29,2%	0,422
21%	76,7%	28,1%	0,411
25%	81,3%	25,0%	0,383
30%	83,7%	21,5%	0,341
40%	93,7%	18,0%	0,302
50%	97,7%	14,7%	0,256
60%	98,7%	12,4%	0,221
70%	98,7%	10,7%	0,193
80%	98,7%	9,4%	0,171
90%	98,7%	8,3%	0,154
100%	100,0%	7,6%	0,141

Tabela 6.6: Resultados da Estratégia 1

Antes de discutir sobre os resultados obtidos, é importante ressaltar que não consideramos as revisões feitas pelos especialistas na Seção 6.1.5, ou seja, partimos dos dados originais utilizados no processo de extração das características descrito na Seção 6.1.

Nessa primeira aplicação do método de Regressão Logística verificamos que o melhor desempenho para a medida-F é de 0,466, quando são analisados 12% da lista dos vendedores ordenados pela probabilidade estimada de cada um estar em *FRS*. Entretanto, o percentual de fraudadores identificados até esta mesma parte da lista ordenada não passa de 60% (59,7%) e a precisão não chega a 40% (38,2%). Com relação à medida geral da ordenação

temos um valor de AIC^{17} de 1.490,9 e a precisão média é de 45,1%.

Na nossa visão, a listagem obtida com essa estratégia necessita de aprimoramentos e otimizações para aumentar a precisão e cobertura especialmente no topo da lista. Com esses resultados, muitos casos teriam que ser analisados, gerando um esforço e custos altos para os especialistas, além de dificultar a implementação de procedimentos automáticos para cancelamento ou suspensão dos fraudadores, por exemplo.

Resultado da Aplicação da Estratégia 1: Considerando apenas as 17 características positivas de fraude temos limitações para obter uma boa precisão e cobertura na parte superior da lista ordenada pela probabilidade estimada do vendedor estar no conjunto *FRS*.

Em seguida, utilizamos mais características, alterando o modelo de regressão com esses novos parâmetros, adotando uma estratégia diferente da apresentada nesta seção.

Efetuamos também uma comparação entre a abordagem de características utilizada na Seção 6.1.4 e o resultado dessa Estratégia. A comparação e análise desses resultados estão disponíveis no Apêndice E.

6.2.2 Estratégia 2: 37 Características de Fraude

Estratégia 2 *Ordenar a lista de vendedores considerando as 17 características positivas da Estratégia 1, características negativas de fraude, a distribuição contínua, além do percentual de ocorrência das características positivas nas transações do vendedor.*

A segunda estratégia de aplicação da Regressão Logística (Estratégia 2) passa a incorporar as características negativas de fraude REC1 e TCPS¹⁸, que não foram consideradas na Seção 6.1.4 e na Estratégia 1, bem como passa a incluir o tempo médio de qualificação entre as transações do vendedor (AVGQ), além dos percentuais da ocorrência das 17 características utilizadas na Estratégia 1. Esses percentuais foram determinados considerando a quantidade de transações do vendedor que possuíam a característica em relação a todas as transações do vendedor. Todas elas somadas levam a 37 características.

Em relação às características que utilizam percentuais, é importante frisar que inicialmente não pensávamos adotar esse procedimento, pois uma regra de negócio do mercado eletrônico *TodaOferta* afirmava que não importava o percentual da característica nas transações para determinar se o vendedor era fraudador ou não. Essa decisão foi motivada pelo fato de que observamos, especialmente nas primeiras posições da listagem, vendedores com características similares, mas com diferenças significativas em quantidade de transações

¹⁷A descrição do *AIC* (Critério de Informação de *Akaike*) pode ser vista na Seção 3.2.3.

¹⁸Mais detalhes sobre as características estão descritos na Seção 6.1.4.

com a característica. Além disso, esse percentual facilita o trabalho de investigação do especialista, reduzindo o custo de investigação, pois eles não precisam analisar um número grande de transações supostamente legítimas. Além disso, como se trata de características positivas, espera-se que esse percentual contribua para priorizar nas ordenações os vendedores que tenham uma frequência maior de transações com características consideradas fraudulentas. Veremos adiante que a utilização desse percentual contribuirá para que a listagem dos vendedores seja mais eficiente.

Para nomear as características relativas aos percentuais, adicionamos o prefixo “pct” às siglas das características utilizadas na Equação 6.1 Sendo assim, com $p = 37$ foram incluídas as seguintes variáveis no modelo:

$$\begin{aligned} x_{18} &= \text{pctITAT}, x_{19} = \text{pctMEAC}, x_{20} = \text{pctMEAT}, x_{21} = \text{pctMEAQ}, x_{22} = \text{pctMEVC}, \\ x_{23} &= \text{pctMEVT}, x_{24} = \text{pctMEVQ}, x_{25} = \text{pctMDCV}, x_{26} = \text{pctMIAC}, x_{27} = \text{pctMIAT}, \\ x_{28} &= \text{pctMIAQ}, x_{29} = \text{pctMIVC}, x_{30} = \text{MIVT}, x_{31} = \text{pctMIVQ}, x_{32} = \text{pctARCT}, \\ x_{33} &= \text{pctUDTC}, x_{34} = \text{pctBTVT}, x_{35} = \text{REC1}, x_{36} = \text{TCPS}, x_{37} = \text{AVGQ}. \end{aligned} \quad (6.2)$$

Antes de prosseguir, é importante lembrar que optamos por exibir nos gráficos e tabelas subsequentes os dados relativos a apenas um quarto da listagem de vendedores, pois estamos mais interessados em medir e comparar a ordenação produzida na parte superior da lista. Além disso, essa opção nos oferece uma facilidade visual para observar e comparar os resultados obtidos.

Na análise dos resultados dessa estratégia, acrescentamos também os valores da medida-F obtidos na Estratégia 1 e que são exibidos no gráfico da Figura 6.8, e podemos observar uma melhora nos valores dessa medida na segunda estratégia se comparada com a primeira.

A Tabela 6.7 exibe os dados de cobertura (C2), precisão (P2) e medida-F (F2) da Estratégia 2 para os vendedores com maior chance de estarem no conjunto FRS , segundo as probabilidades estimadas com o modelo de regressão que utiliza as variáveis das Equações 6.1 e 6.2. A última coluna dessa tabela mostra o percentual de aumento da medida-F se compararmos os valores obtidos na Estratégia 1 (F1) e na Estratégia 2 (F2).

Podemos observar que com a aplicação da Estratégia 2, o melhor valor da medida-F (F2=0,520) ocorre quando analisamos 7% da lista dos vendedores. Se relembrarmos o que observamos no melhor valor dessa medida obtido nos resultados da Estratégia 1 (F1=0,466), necessitávamos analisar 12% dos vendedores. Além disso, comparando os resultados da Estratégia 2 nesse mesmo percentual, observamos um aumento na medida de cobertura (C1=59,7% x C2=63,3%) e de precisão (P1=38,2% x P2=40,6%). Com relação à medida geral da ordenação temos um valor de AIC de 1.430,0, também melhor que o obtido na

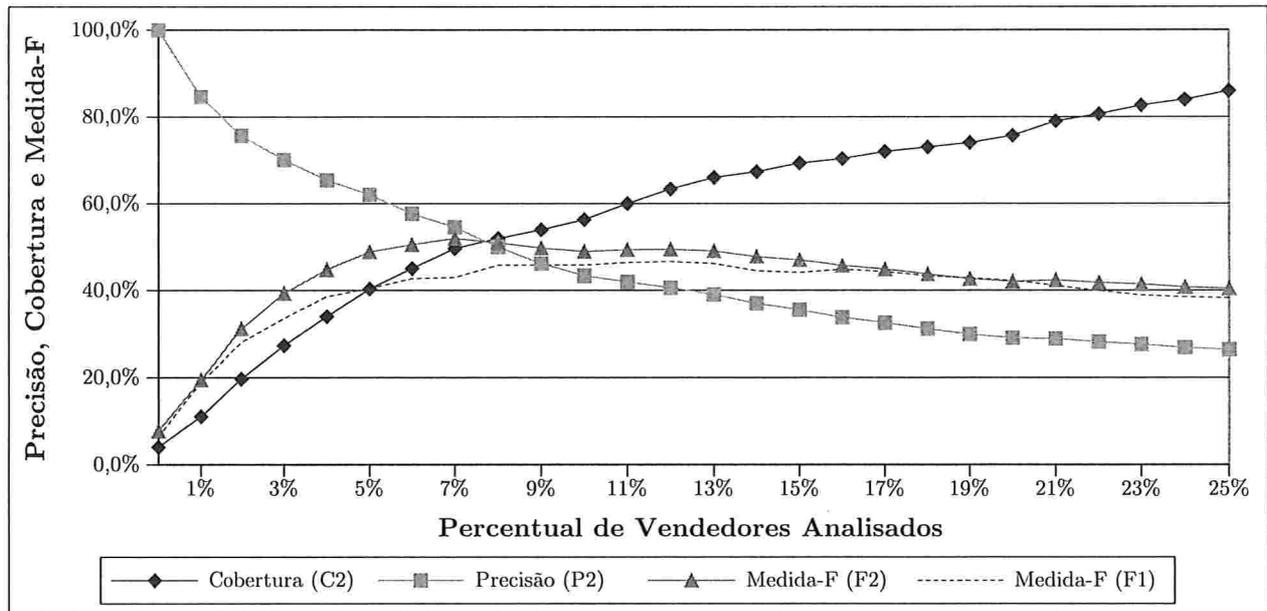


Figura 6.9: Avaliação da Estratégia 2

Estratégia 1 (1.490,9), uma vez que quanto menor for o valor de AIC , melhor. Em relação à precisão média, tivemos um aumento de 17,3%, obtendo nessa estratégia o valor de 53,0%.

Outra comparação que pode ser feita é na análise dos valores obtidos no topo, nas Tabelas 6.6 e 6.7, comparando os resultados das primeiras posições da listagem obtida na Estratégia 2 com a da Estratégia 1, especialmente a que corresponde à análise de menos de 10% dos vendedores. Podemos observar que há um ganho considerável nos valores da medida-F. A saída obtida na execução do *script* no *pacote R* pode ser analisado no Apêndice C.2.

Resultado da Aplicação da Estratégia 2: Aumentando o número de características de 17 para 37, passando a considerar características negativas de fraude, características de distribuição contínua e percentual de características dentro das transações do vendedor, conseguimos ganho nas medidas de eficiência se compararmos os resultados da Estratégia 2 com a Estratégia 1.

6.2.3 Estratégia 3: Seleção de Modelo Otimizado em *FRS*

Estratégia 3 *Otimizar o modelo de regressão por meio de seleção de características gerada por regressão stepwise.*

Nessa terceira estratégia de aplicação do método de Regressão Logística, o objetivo é ajustar o modelo após ter utilizado o conjunto de todas as características possíveis até então. O ajuste no modelo tem como meta selecionar as variáveis mais relevantes dentre as

% Vendedores	C2	P2	F2	F1	(F2-F1)/F1
1%	11,0%	84,6%	0,195	0,189	3,1%
2%	19,7%	75,6%	0,312	0,280	11,3%
3%	27,3%	70,1%	0,393	0,336	17,1%
4%	34,0%	65,4%	0,447	0,386	15,9%
5%	40,3%	62,1%	0,489	0,404	21,0%
6%	45,0%	57,7%	0,506	0,427	18,4%
7%	49,7%	54,6%	0,520	0,429	21,1%
8%	52,0%	50,0%	0,510	0,458	11,4%
9%	54,0%	46,2%	0,498	0,458	8,7%
10%	56,3%	43,3%	0,490	0,458	7,0%
11%	60,0%	42,0%	0,494	0,464	6,5%
12%	63,3%	40,6%	0,495	0,466	6,1%
13%	66,0%	39,1%	0,491	0,461	6,5%
14%	67,3%	37,0%	0,478	0,444	7,4%
15%	69,3%	35,6%	0,470	0,441	6,7%
16%	70,3%	33,8%	0,457	0,448	1,9%
17%	72,0%	32,6%	0,449	0,442	1,4%
18%	73,0%	31,2%	0,437	0,433	0,9%
19%	74,0%	30,0%	0,427	0,428	-0,4%
20%	75,7%	29,1%	0,420	0,422	-0,4%
21%	76,7%	28,1%	0,411	0,411	0,0%
22%	77,0%	26,9%	0,399	0,399	0,0%
23%	77,7%	26,0%	0,389	0,389	0,0%
24%	79,3%	25,4%	0,385	0,385	0,0%
25%	81,3%	25,0%	0,383	0,383	0,0%

Tabela 6.7: Resultados da Estratégia 2

37 utilizadas na Estratégia 2 para a amostra de dados em questão, objetivando uma lista ordenada mais eficiente que as anteriores, que pode ser medida por meio dos cálculos de precisão, cobertura, medida-F, precisão média e valor de *AIC*.

Para obter um modelo mais otimizado, utilizamos o comando `stepAIC` do pacote *R*. Nesse comando, dada uma fórmula (no nosso caso a fórmula é definida com as variáveis das Equações 6.1 e 6.2) o resultado é uma outra fórmula, ou seja, um novo modelo, obtido após a utilização do procedimento de *Regressão Stepwise*¹⁹. O critério de escolha do melhor modelo é o valor de *AIC*.

Partindo-se das 37 características descritas nas Equações 6.1 e 6.2, obtemos um modelo

¹⁹Mais detalhes sobre esse procedimento estão descritos na Seção 3.6.

com 17 ($p = 17$) variáveis²⁰ selecionadas:

$$\begin{aligned} x_1 &= \text{ITAT}, x_2 = \text{pctITAT}, x_3 = \text{MEAC}, x_4 = \text{pctMEAC}, x_5 = \text{pctMEAT}, \\ x_6 &= \text{pctMDCV}, x_7 = \text{MIAC}, x_8 = \text{MIAT}, x_9 = \text{MIAQ}, x_{10} = \text{MIVC}, \\ x_{11} &= \text{pctMIVT}, x_{12} = \text{ARCT}, x_{13} = \text{pctARCT}, x_{14} = \text{pctUDTC}, \\ x_{15} &= \text{BTVT}, x_{16} = \text{TCPS}, x_{17} = \text{AVGQ}. \end{aligned} \quad (6.3)$$

Analisando as variáveis da Equação 6.3, observamos que entre elas foram selecionadas características positivas de fraude (ex. $x_3 = \text{MEAC}$), negativas (ex. $x_{16} = \text{TCPS}$), distribuição contínua (ex. $x_{17} = \text{AVGQ}$) e os percentuais (ex. $x_2 = \text{pctITAT}$), indicando que todo tipo de característica que extraímos contribuiu para a criação do modelo mais otimizado.

Dispondo das variáveis consideradas mais relevantes, ou seja, aquelas que foram obtidas na aplicação da Regressão *Stepwise*, a próxima etapa é aplicar novamente o novo modelo na amostra de dados. O gráfico da Figura 6.10 e a Tabela 6.8 mostram os resultados obtidos após a utilização desse modelo criado a partir das Equações 6.3.

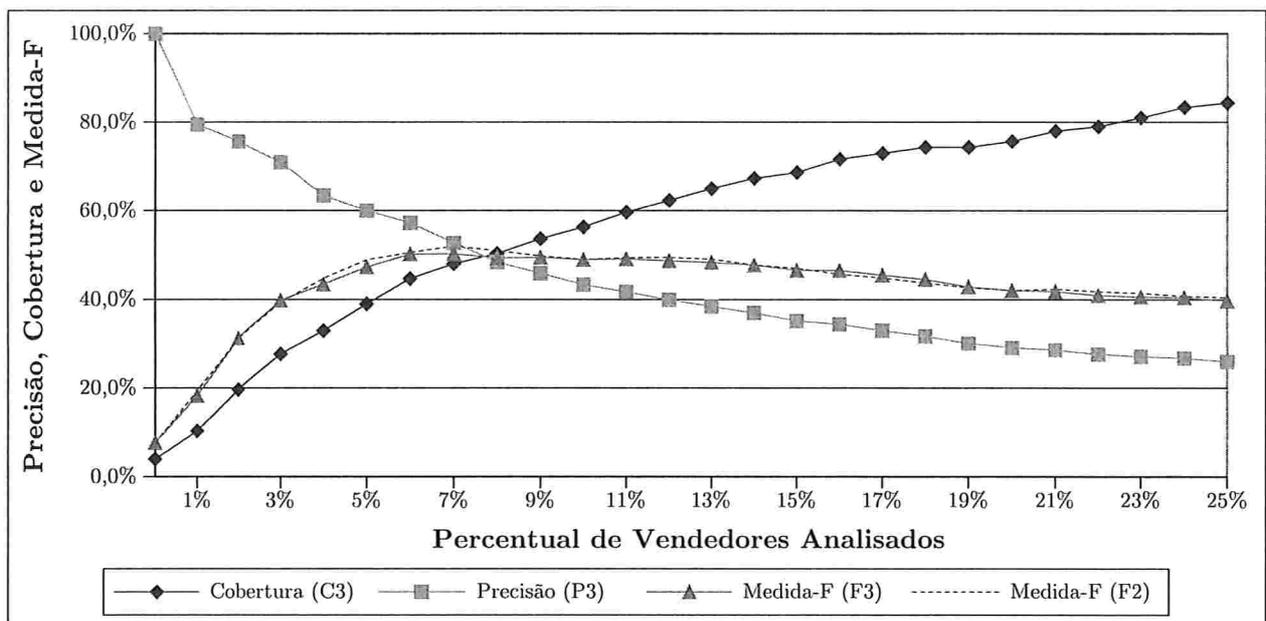


Figura 6.10: Avaliação da Estratégia 3

Podemos observar no gráfico da Figura 6.10 que praticamente não houve variação nos valores da medida-F comparando-se os resultados das Estratégias 2 e 3. Inclusive, analisando a variação exibida na Tabela 6.8, vemos uma ligeira piora nos valores das primeiras posições

²⁰Por coincidência, observamos que obtivemos o mesmo número (17) de equações da Estratégia 1, mas isso foi mera coincidência.

% Vendedores	C3	P3	F3	F2	(F3-F2)/F2
1%	10,3%	79,5%	0,183	0,195	-6,1%
2%	19,7%	75,6%	0,312	0,312	0,0%
3%	27,7%	70,9%	0,398	0,393	1,2%
4%	33,0%	63,5%	0,434	0,447	-2,9%
5%	39,0%	60,0%	0,473	0,489	-3,3%
6%	44,7%	57,3%	0,502	0,506	-0,7%
7%	48,0%	52,7%	0,503	0,520	-3,4%
8%	50,3%	48,4%	0,493	0,510	-3,2%
9%	53,7%	45,9%	0,495	0,498	-0,6%
10%	56,3%	43,3%	0,490	0,490	0,0%
11%	59,7%	41,7%	0,491	0,494	-0,6%
12%	62,3%	40,0%	0,487	0,495	-1,6%
13%	65,0%	38,5%	0,483	0,491	-1,5%
14%	67,3%	37,0%	0,478	0,478	0,0%
15%	68,7%	35,2%	0,466	0,470	-1,0%
16%	71,7%	34,5%	0,465	0,457	1,9%
17%	73,0%	33,0%	0,455	0,449	1,4%
18%	74,3%	31,8%	0,445	0,437	1,8%
19%	74,3%	30,1%	0,428	0,427	0,5%
20%	75,7%	29,1%	0,420	0,420	0,0%
21%	78,0%	28,6%	0,418	0,411	1,7%
22%	79,0%	27,6%	0,409	0,399	2,6%
23%	81,0%	27,1%	0,406	0,389	4,3%
24%	83,3%	26,7%	0,405	0,385	5,0%
25%	84,3%	25,9%	0,397	0,383	3,7%

Tabela 6.8: Resultados da Estratégia 3

da ordenação, o que não é uma situação favorável para a resolução do problema proposto neste trabalho. Acreditamos que isso se deva ao fato de que o valor de AIC , que é o critério de otimização adotado, procura privilegiar modelos mais simples, com menos variáveis, como podemos observar na Seção 3.2.3.

Além disso, se compararmos os resultados das Tabelas 6.7 e Tabelas 6.8, que exibem os resultados obtidos nas Estratégias 2 e 3, observamos que não houve diferenças significativas também em relação à precisão e cobertura. Em relação ao valor de AIC , caiu de 1.430,0 para 1.401,7, indicando uma ordenação um pouco melhor que a anterior. Em relação à precisão média, tivemos uma perda de 1,4%, obtendo um valor de 52,3% nessa medida. A saída dessa execução feita no *pacote R* pode ser vista em detalhes no Apêndice C.3.

Comparando as precisões obtidas à medida que a cobertura em FRS aumenta, observamos no gráfico da Figura 6.11 que a curva da precisão calculada na Estratégia 2 (P2) é ligeiramente

mais eficiente se comparada com as da Estratégia 3 (P3) e ambas são significativamente mais eficientes que a Estratégia 1 (P1).

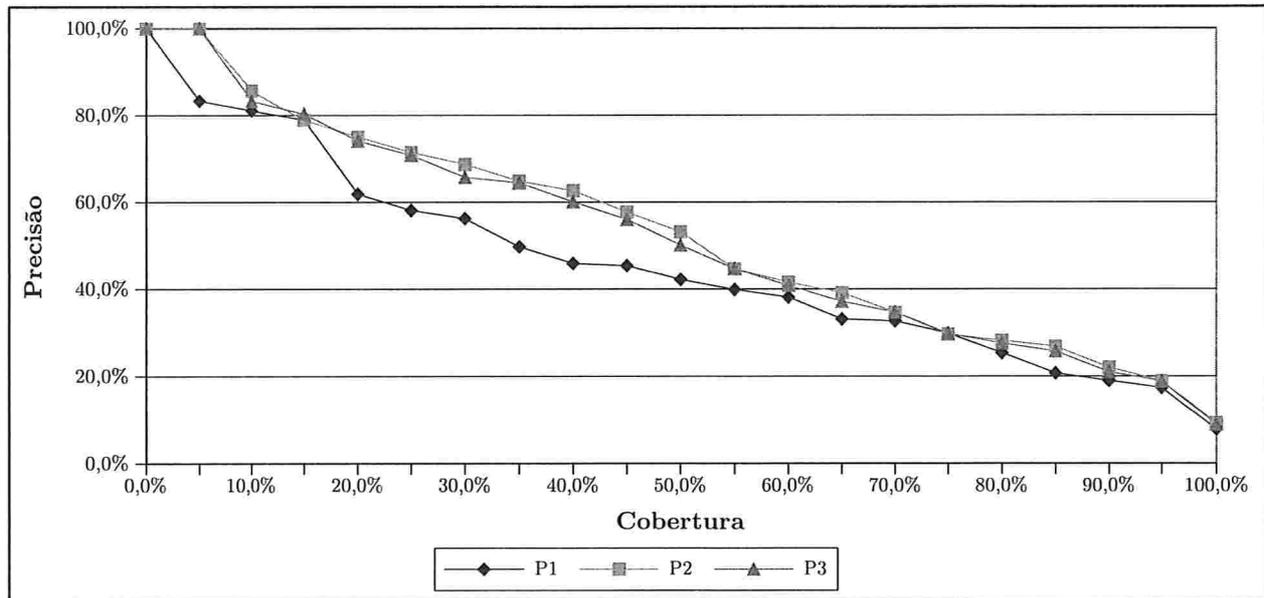


Figura 6.11: Comparação das Precisões P1, P2 e P3 em Função da Cobertura

Considerando as três estratégias adotadas até aqui, podemos observar na Tabela 6.9 que houve melhora no valor do *AIC*, em virtude do aumento do número de características (das 17 características da Estratégia 1 para os 37 da Estratégia 2) e posterior seleção dessas 37 características por meio de procedimento de otimização, que se baseia em *AIC*. Em relação à precisão média, vemos que o aumento do número de características contribuiu para uma melhora nessa medida, mas a otimização, por sua vez, trouxe um ligeiro decréscimo nessa medida de avaliação.

Estratégia	<i>AIC</i>	Precisão Média
1	1.490,9	45,1%
2	1.430,0	53,0%
3	1.401,7	52,3%

Tabela 6.9: *AIC* e Precisão Média nas Estratégias 1, 2 e 3

Diante dos valores obtidos até aqui, principalmente em relação às medidas de precisão e precisão média que são melhores na Estratégia 2, antes da seleção de características por meio de Regressão *Stepwise*, e cientes de que havia fraudadores anotados como vendedores legítimos, solicitamos uma avaliação manual dos especialistas que nos permitisse ou identificar mais características e repetir os passos adotados até aqui, ou recalculas as medidas de

eficiência com base nos dados revisados. A próxima seção fornecerá mais detalhes sobre essa etapa do estudo de caso.

Resultado da Aplicação da Estratégia 3: Observamos que a utilização do modelo otimizado, com as variáveis consideradas mais relevantes, ainda que simplificando significativamente o modelo, não trouxe ganhos significativos nas medidas de eficiência²¹

6.2.4 Estratégia 4: Revisão dos Elementos do Conjunto *FRS*

Estratégia 4 *Solicitar a revisão das anotações feitas pelos especialistas e aplicar o modelo desenvolvido na Estratégia 3 às novas anotações e verificar se as medidas de eficiência são superiores às obtidas na Estratégia 3 ou se é necessário extrair outras características para uma melhor identificação de fraudadores.*

Nessa estratégia, solicitamos o auxílio dos especialistas para verificarem se a lista de vendedores fraudadores obtida como resultado até aqui poderia ser utilizada como uma ferramenta na identificação de fraude em suas atividades diárias ou se novas características deveriam ser extraídas, para que isso seja possível (essa solicitação é um dos passos da metodologia descrita no Capítulo 5).

Após essa revisão dos especialistas, concluímos que havia muitos fraudadores anotados como vendedores legítimos e que não havia necessidade de extrair novas características, ou seja, não havia características faltantes. Entretanto, alguns pontos dessa revisão merecem destaque:

- Não informamos aos especialistas quais eram as características que levavam determinado vendedor ter maior probabilidade de ser considerado fraudador do que outro;
- Existiam limitações para análise de alguns vendedores, como por exemplo, necessidade de maior investigação, especialmente para usuários com muitas transações. Essas limitações acabaram influenciando a maneira com que os especialistas revisavam a lista produzida na Estratégia 3, fazendo que a análise não seguisse exatamente a ordem dessa listagem;
- Um aumento de 31,5% do conjunto dos fraudadores (*FRS*) foi obtido analisando a listagem exatamente na ordem em que ela foi produzida na Estratégia 3. Essa análise corresponde aos primeiros 3,12% do conjunto completo de todos vendedores;

²¹Veremos nas seções seguintes que essa melhora não existiu em função da descoberta de fraudadores que estavam anotados como legítimos. Concluímos que a otimização do modelo, por meio de seleção de características, oferece possibilidades de melhoria do modelo, e o motivo da não obtenção dessa melhoria até essa etapa é consequência da anotação inicial, que considerava menos fraudadores do que de fato existiam.

- A partir desse ponto, a revisão não foi feita seguindo fielmente a ordem da listagem. Ao final da revisão, o conjunto *FRS* aumentou em 112,3%.

Outro fator que contribuiu para não seguir fielmente a ordenação da Estratégia 3 foi o fato de que entre o processo de validação das características (descrito na Seção 6.1.4) e a aplicação das estratégias de utilização do método de Regressão Logística, os especialistas continuaram investigando a listagem de vendedores ordenada pela contagem de características positivas de fraude, pois essa era a ferramenta que existia até o momento. Além disso, em alguns casos, devido à dificuldade em analisar determinados usuários e transações, os especialistas preferiram seguir avançando na investigação sem se preocupar com a ordem da listagem, objetivando maior cobertura em detrimento da precisão. Por fim, alguns fraudadores denunciados entre a obtenção da amostra e a revisão foram considerados no novo conjunto *FRS*, já que eram casos que os especialistas consideravam importantes para análises futuras.

Mesmo com a revisão não sendo feita da maneira ideal, decidimos por continuar os experimentos com a alteração final no conjunto *FRS*, que aumentou em 112,3% se comparado aos dados anotados inicialmente.

A Figura 6.12 mostra um histograma do percentual de vendedores revisados a cada parte da listagem obtida a partir da Estratégia 3, e exibe também o aumento em percentual no conjunto *FRS* para essas partes. Podemos verificar que o número de vendedores revisados

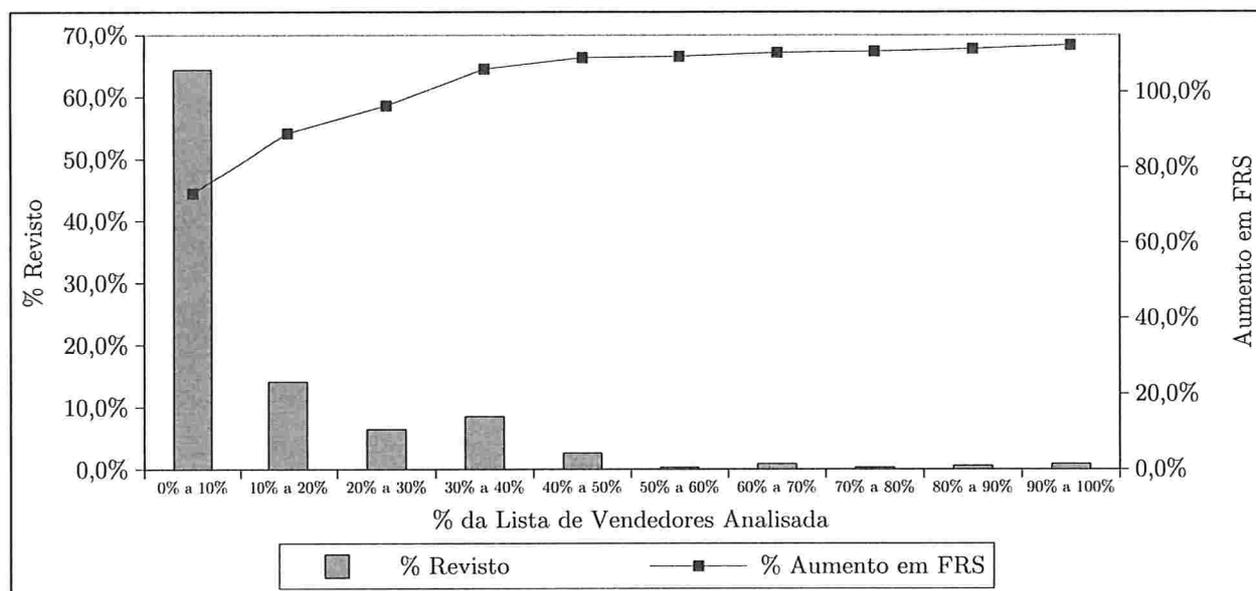


Figura 6.12: Revisão dos Especialistas

diminui à medida que se avança na lista, assim como os incrementos nos elementos do conjunto *FRS* são menores e o aumento mais significativo se dá no topo dessa listagem.

Considerando a revisão feita da maneira como descrevemos anteriormente, calculamos novamente as medidas de eficiência (precisão, cobertura, medida-F e precisão média), exceto o valor de AIC , pois não tivemos alteração no modelo de regressão.

O gráfico da Figura 6.13 exibe as medidas de eficiência considerando a ordenação obtida na Estratégia 3, mas passa a considerar as mudanças nos conjuntos FRS (que aumentou) e NFr (que diminuiu, por consequência). A variável de referência deixa de ser o valor original anotado e passa a considerar o valor revisado.

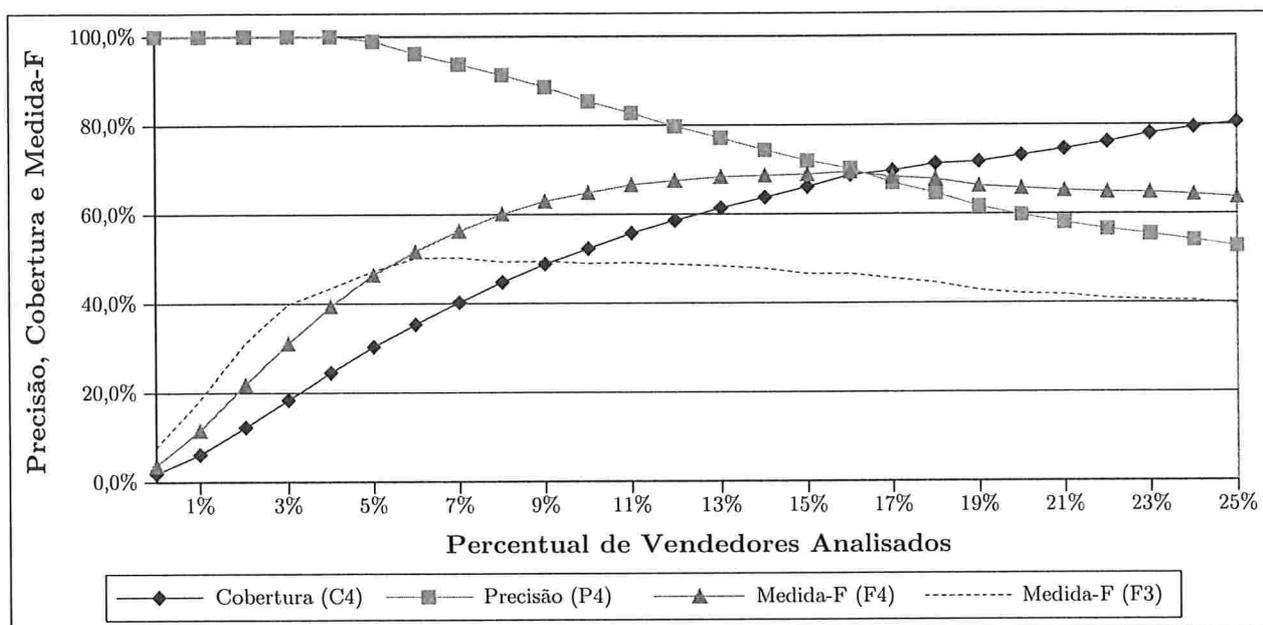


Figura 6.13: Avaliação da Estratégia 4

No gráfico da Figura 6.13 também observamos a comparação entre os valores obtidos para medida-F nas Estratégias 3 (F3) e 4 (F4). Analisando os resultados, vemos que na Estratégia 4 esta medida se torna mais eficiente a partir da análise de 5% da listagem de vendedores. Entretanto, não podemos afirmar que houve diminuição de eficiência entre as duas estratégias antes de atingir os 5% da lista de vendedores, pois houve uma alteração significativa nos elementos dos conjuntos FRS e NFr , com a descoberta e identificação de outros fraudadores. A Tabela 6.10 exibe mais detalhes sobre estes resultados, e vemos que o maior valor da medida-F é quando analisamos 16% dos vendedores ($F4=0,695$). Se relembrarmos os resultados das estratégias anteriores, o maior valor dessa medida fica entre 7% e 12%.

Em relação à precisão, podemos verificar no gráfico da Figura 6.14 e na Tabela 6.11 que houve um aumento considerável e consistente nos valores dessa medida ao longo da lista ordenada de vendedores. Essa situação acontece pois o que julgávamos inicialmente

% Vendedores	C4	P4	F4	F3	(F4-F3)/F3
1%	6,1%	100,0%	0,115	0,183	-36,9%
2%	12,2%	100,0%	0,218	0,312	-30,1%
3%	18,4%	100,0%	0,310	0,398	-22,0%
4%	24,5%	100,0%	0,393	0,434	-9,4%
5%	30,3%	99,0%	0,464	0,473	-1,9%
6%	35,3%	96,2%	0,517	0,502	2,9%
7%	40,2%	93,8%	0,563	0,503	11,9%
8%	44,7%	91,3%	0,601	0,493	21,7%
9%	48,8%	88,6%	0,630	0,495	27,3%
10%	52,3%	85,4%	0,648	0,490	32,4%
11%	55,7%	82,8%	0,666	0,491	35,6%
12%	58,6%	79,7%	0,675	0,487	38,6%
13%	61,4%	77,1%	0,684	0,483	41,4%
14%	63,7%	74,4%	0,686	0,478	43,7%
15%	66,1%	72,0%	0,689	0,466	48,0%
16%	68,8%	70,2%	0,695	0,465	49,3%
17%	69,7%	67,0%	0,683	0,455	50,2%
18%	71,3%	64,7%	0,678	0,445	52,3%
19%	71,7%	61,7%	0,663	0,428	54,8%
20%	73,2%	59,7%	0,658	0,420	56,5%
21%	74,6%	58,0%	0,652	0,418	56,0%
22%	76,1%	56,5%	0,649	0,409	58,5%
23%	78,0%	55,4%	0,648	0,406	59,6%
24%	79,4%	54,1%	0,643	0,405	59,0%
25%	80,5%	52,6%	0,636	0,397	60,4%

Tabela 6.10: Resultados da Estratégia 4

serem vendedores legítimos se confirmaram fraudadores, elevando assim a precisão da análise. Observamos também que alcançamos uma precisão de 100% quando analisamos os 4% dos vendedores com maior probabilidade de fraude contra o sistema de reputação, precisão essa não confirmada nas estratégias anteriores. Em relação à precisão média, obtivemos o valor de 78,0%, que representa um aumento 49,2% após a revisão das anotações.

Mesmo com o incremento nas medidas de eficiência, consideramos ser necessário e possível melhorar a listagem obtida até essa etapa. Sendo assim, o próximo passo é otimizar o modelo considerando como referência os dados revisados, a fim de verificar se é possível aumentar a cobertura mantendo precisões altas no topo da lista.

Na próxima seção modificamos o modelo de regressão a partir da alteração que tivemos nos conjuntos *FRS* e *NFr*.

Resultado da Aplicação da Estratégia 4: Verificamos que a revisão feita pelos espe-

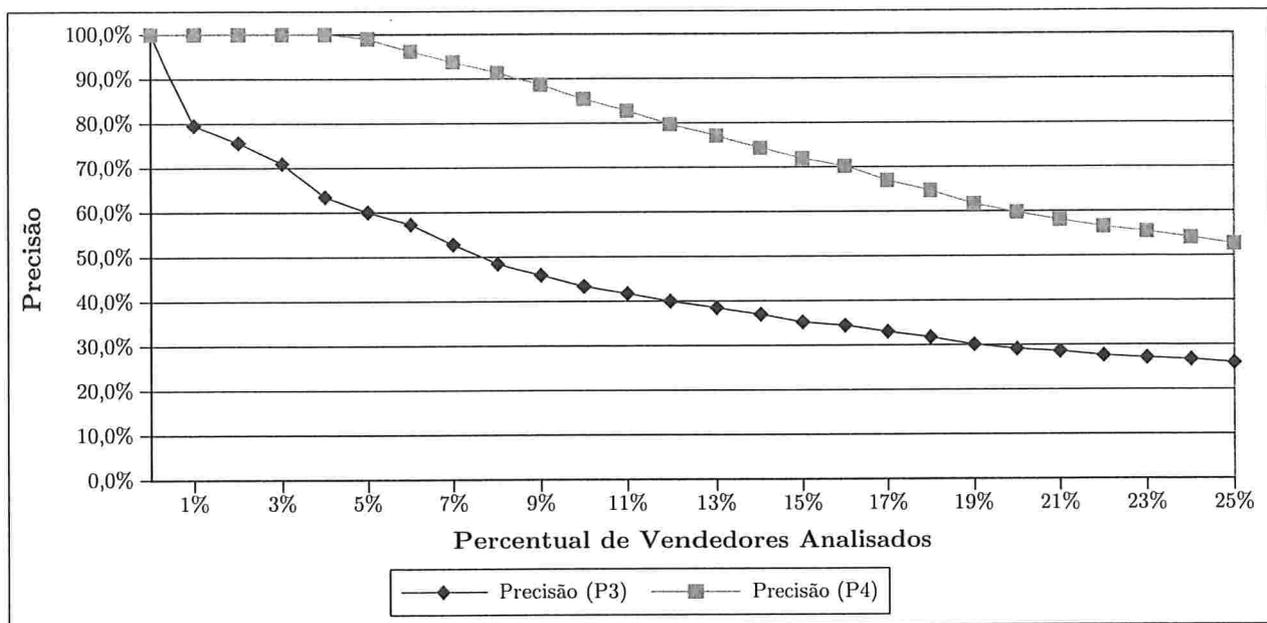


Figura 6.14: Comparação de Precisão entre Estratégias 3 e 4

cialistas confirmou que as características utilizadas na identificação de fraude se mostram efetivas e, com a alteração nos elementos do conjunto *FRS*, um novo modelo deve ser construído e analisado, sem necessidade de levantar novas características.

6.2.5 Estratégia 5: Modificar a Variável Resposta para *FRS* Revisado

Estratégia 5 Manter a seleção de variáveis obtida na Estratégia 3 e modificar a variável resposta para *FRS* Revisado (com anotação revisada) e gerar um novo modelo de Regressão Logística.

Nesta seção, o objetivo é gerar um novo modelo de Regressão Logística com as mesmas variáveis das Equações 6.3, que são aquelas que compõem o modelo mais otimizado para a variável resposta *FRS*. Como o conjunto *FRS* aumentou em 112,3%, analisamos como a ordenação obtida por esse modelo se compara à ordenação anterior. Para isso, comparamos as medidas de eficiência obtidas nesse novo modelo com as medidas da Estratégia 4.

O gráfico da Figura 6.15 e a Tabela 6.12 exibem os resultados obtidos nessa nova aplicação da Regressão Logística e podemos verificar que há um aumento consistente nos valores da medida-F. Observamos também que a precisão ficou em 100% para 5% dos vendedores (na Estratégia 4 se mantinha em 100% até 4% dos vendedores), mostrando que a alteração da variável resposta e a geração de um novo modelo trouxe um ganho em precisão no topo da lista. Em relação ao valor de *AIC*, obtivemos 1.133,7 (era de 1.401,7 na Estratégia 3). A saída dessa execução feita no *pacote R* pode ser vista em detalhes no Apêndice C.4. Nessa

% Vendedores	P4	P3	(P4-P3)/P3
1%	100,0%	79,5%	25,8%
2%	100,0%	75,6%	32,2%
3%	100,0%	70,9%	41,0%
4%	100,0%	63,5%	57,6%
5%	99,0%	60,0%	65,0%
6%	96,2%	57,3%	67,9%
7%	93,8%	52,7%	77,8%
8%	91,3%	48,4%	88,7%
9%	88,6%	45,9%	93,2%
10%	85,4%	43,3%	97,0%
11%	82,8%	41,7%	98,3%
12%	79,7%	40,0%	99,5%
13%	77,1%	38,5%	100,5%
14%	74,4%	37,0%	101,0%
15%	72,0%	35,2%	104,4%
16%	70,2%	34,5%	103,7%
17%	67,0%	33,0%	102,7%
18%	64,7%	31,8%	103,6%
19%	61,7%	30,1%	104,9%
20%	59,7%	29,1%	105,3%
21%	58,0%	28,6%	103,0%
22%	56,5%	27,6%	104,6%
23%	55,4%	27,1%	104,5%
24%	54,1%	26,7%	102,4%
25%	52,6%	25,9%	102,8%

Tabela 6.11: Comparação de Precisão entre Estratégias 3 (P3) e 4 (P4)

estratégia, também obtemos um aumento de 9,5% na precisão média, alcançando então o valor de 91,4%.

Uma conclusão que podemos tirar na aplicação da Estratégia 5 é que o modelo se ajustou ao novo conjunto de fraudadores e produziu uma listagem melhor que a anterior, onde as variáveis resposta eram diferentes.

Mesmo com a melhoria obtida na Estratégia 5, precisamos verificar se a ordenação pode ser melhorada se modificarmos as variáveis do modelo, uma vez que temos ao todo 37 características disponíveis e conhecidas, listadas nas Equações 6.1 e 6.2, e nessa aplicação utilizamos somente 17 delas, as mesmas da Estratégia 3.

Na próxima seção otimizamos o modelo em função da variável resposta *FRS* Revisado, e verificaremos se há ganho de eficiência na comparação com a listagem produzida na Estratégia 5.

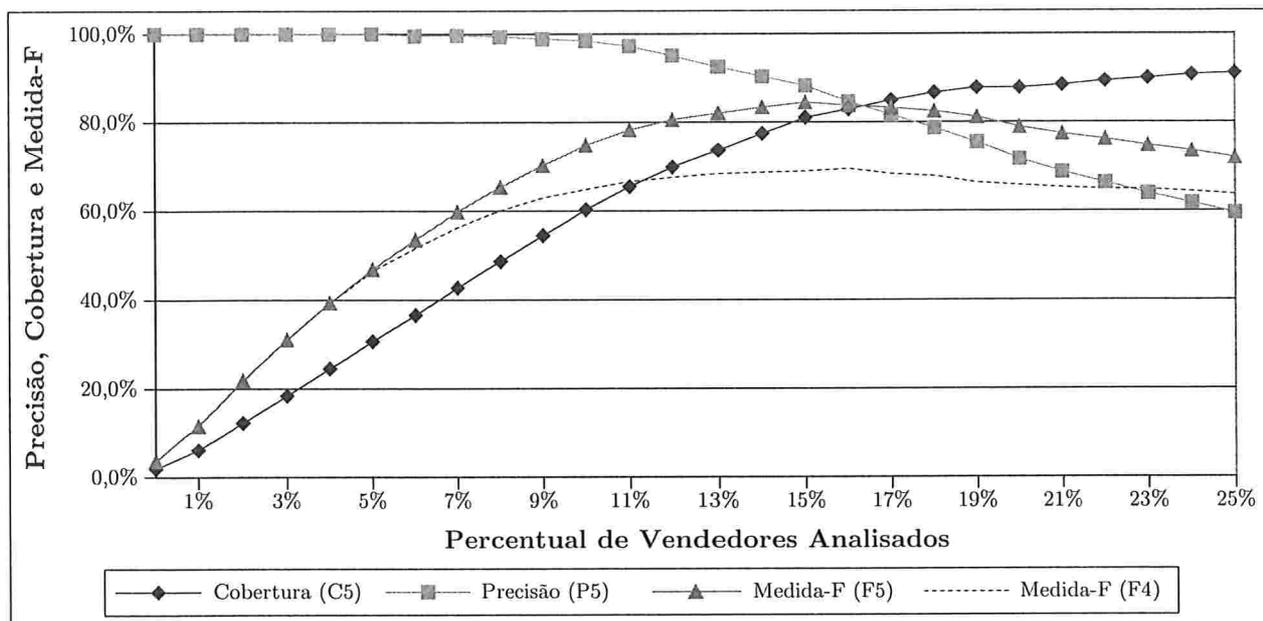


Figura 6.15: Avaliação da Estratégia 5

Resultado da Aplicação da Estratégia 5: Como esperado, a geração de um modelo otimizado de Regressão Logística, considerando a mudança da variável resposta para *FRS* Revisado, aumentou a eficiência da lista ordenada, se compararmos com a listagem produzida na Estratégia 4.

6.2.6 Estratégia 6: Otimização do Modelo de Regressão para *FRS* Revisado

Estratégia 6 *A partir das 37 características, aplicar e otimizar o modelo de Regressão Logística considerando a variável resposta como *FRS* Revisado.*

Nesta seção obtemos um novo modelo de Regressão Logística e o aplicamos novamente na amostra de dados. Uma vez que levantamos 37 características que contribuem para identificação de fraudadores contra o sistema de reputação (as mesmas que aplicamos na Estratégia 2), e como houve uma alteração significativa na quantidade de vendedores no conjunto *FRS* após a revisão das anotações, aplicamos o mesmo procedimento utilizado na Estratégia 3 (*Regressão Stepwise*) para verificar se o modelo otimizado sugerido, ou seja, o modelo com o menor valor de *AIC*, é mais ou menos eficiente do que aquele utilizado na Estratégia 5.

Para isso, executamos novamente o comando `stepAIC` do pacote *R*, obtendo outras variáveis que formam o modelo considerado mais otimizado para a variável resposta *FRS* Revisado em função de todas as 37 características possíveis. Após a seleção, com $p = 25$, temos

% Vendedores	C5	P5	F5	F4	(F5-F4)/F4
1%	6,1%	100,0%	0,115	0,115	0,0%
2%	12,2%	100,0%	0,218	0,218	0,0%
3%	18,4%	100,0%	0,310	0,310	0,0%
4%	24,5%	100,0%	0,393	0,393	0,0%
5%	30,6%	100,0%	0,469	0,464	1,0%
6%	36,6%	99,6%	0,535	0,517	3,6%
7%	42,7%	99,6%	0,598	0,563	6,2%
8%	48,7%	99,4%	0,653	0,601	8,8%
9%	54,5%	98,9%	0,702	0,630	11,6%
10%	60,3%	98,5%	0,748	0,648	15,3%
11%	65,5%	97,2%	0,782	0,666	17,5%
12%	69,9%	95,1%	0,805	0,675	19,3%
13%	73,6%	92,5%	0,820	0,684	19,9%
14%	77,4%	90,3%	0,833	0,686	21,4%
15%	81,0%	88,2%	0,845	0,689	22,6%
16%	82,9%	84,6%	0,837	0,695	20,5%
17%	84,9%	81,6%	0,832	0,683	21,8%
18%	86,7%	78,6%	0,824	0,678	21,6%
19%	87,8%	75,4%	0,811	0,663	22,3%
20%	87,8%	71,7%	0,789	0,658	20,0%
21%	88,4%	68,7%	0,773	0,652	18,5%
22%	89,3%	66,3%	0,761	0,649	17,3%
23%	90,0%	63,9%	0,747	0,648	15,3%
24%	90,7%	61,8%	0,735	0,643	14,2%
25%	91,1%	59,5%	0,720	0,636	13,1%

Tabela 6.12: Resultados da Estratégia 5

as seguintes variáveis:

$$\begin{aligned}
x_1 &= \text{pctITAT}, x_2 = \text{MEAC}, x_3 = \text{pctMEAC}, x_4 = \text{MEAT}, x_5 = \text{pctMEAQ}, \\
x_6 &= \text{MEVC}, x_7 = \text{MEVT}, x_8 = \text{MEVQ}, x_9 = \text{MDCV}, x_{10} = \text{pctMDCV}, \\
x_{11} &= \text{pctMIAC}, x_{12} = \text{MIAT}, x_{13} = \text{MIVC}, x_{14} = \text{pctMIVC}, x_{15} = \text{MIVT}, \\
x_{16} &= \text{pctMIVT}, x_{17} = \text{MIVQ}, x_{18} = \text{ARCT}, x_{19} = \text{pctARCT}, x_{20} = \text{UDTC}, \\
x_{21} &= \text{pctUDTC}, x_{22} = \text{BTVT}, x_{23} = \text{TCPS}, x_{24} = \text{AVGQ}, x_{25} = \text{REC1}. \quad (6.4)
\end{aligned}$$

Com as variáveis definidas nas Equações 6.4, que representam 25 características (eram 17 nas Estratégias 3 e 5), executamos novamente o modelo de Regressão Logística no *pacote R* e a saída dessa execução feita pode ser vista em detalhes no Apêndice C.5.

O gráfico da Figura 6.16 e a Tabela 6.13 exibem esses resultados e observamos que nova-

mente obtemos um ganho na medida-F, mas não tão significativo como na comparação feita nas outras estratégias. Observamos também que foi possível obter uma precisão de 100,0%

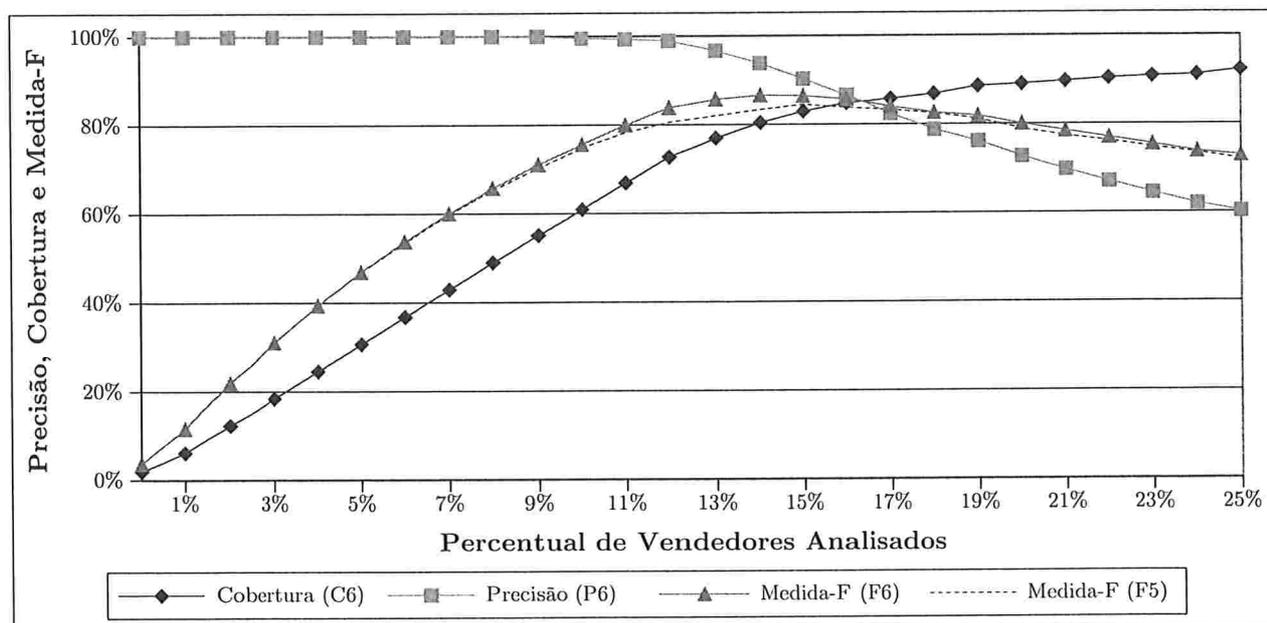


Figura 6.16: Avaliação da Estratégia 6

para quase 10% do topo da lista de vendedores (mais precisamente em 9,14%), cobrindo mais da metade dos fraudadores (56,7%). Isso nos leva a concluir que a lista ordenada obtida após a otimização do modelo tendo como referência o conjunto *FRS* Revisado é melhor que a listagem obtida na Estratégia 5. Com relação ao valor de *AIC*, obtivemos o menor valor em todas as aplicações do método Regressão Logística nos experimentos até aqui, sendo igual a 1.002,1.

Em relação à precisão média, obtemos o valor de 93,0%, que representa um aumento de 1,8% em relação a estratégia que não tinha o modelo otimizado para a anotação revisada.

Da mesma forma que mostramos a precisão em função da cobertura para as Estratégias de 1 a 3 no gráfico da Figura 6.11, comparamos no gráfico da Figura 6.17 os valores calculados de precisão nas Estratégias 4, 5 e 6, além do resultado da Estratégia 3, calculado antes da revisão das anotações.

Dado que os resultados que obtivemos com a Estratégia 6 foram para nós bastante satisfatórios, optamos por interromper o processo de aperfeiçoamento dos modelos que, no entanto, poderiam ser continuados tentativamente por meio da extração de novas características, revisões adicionais com os especialistas ou outros critérios de otimização do modelo que não utilize *AIC*, por exemplo.

Resultado da Aplicação da Estratégia 6: Com a otimização do modelo de Regressão

% Vendedores	C6	P6	F6	F5	(F6-F5)/F5
1%	6,1%	100,0%	0,115	0,115	0,0%
2%	12,2%	100,0%	0,218	0,218	0,0%
3%	18,4%	100,0%	0,310	0,310	0,0%
4%	24,5%	100,0%	0,393	0,393	0,0%
5%	30,6%	100,0%	0,469	0,469	0,0%
6%	36,7%	100,0%	0,537	0,535	0,4%
7%	42,9%	100,0%	0,600	0,598	0,4%
8%	49,0%	100,0%	0,658	0,653	0,6%
9%	55,1%	100,0%	0,711	0,702	1,2%
10%	60,9%	99,5%	0,756	0,748	1,0%
11%	66,9%	99,3%	0,799	0,782	2,2%
12%	72,7%	98,9%	0,838	0,805	4,0%
13%	76,9%	96,6%	0,857	0,820	4,5%
14%	80,4%	93,8%	0,866	0,833	3,9%
15%	82,9%	90,3%	0,864	0,845	2,3%
16%	84,8%	86,5%	0,856	0,837	2,3%
17%	85,7%	82,4%	0,840	0,832	0,9%
18%	86,8%	78,8%	0,826	0,824	0,2%
19%	88,5%	76,1%	0,819	0,811	0,9%
20%	89,0%	72,7%	0,800	0,789	1,4%
21%	89,6%	69,7%	0,784	0,773	1,4%
22%	90,3%	67,0%	0,769	0,761	1,1%
23%	90,7%	64,4%	0,754	0,747	0,9%
24%	91,1%	62,0%	0,737	0,735	0,3%
25%	92,2%	60,2%	0,728	0,720	1,2%

Tabela 6.13: Resultados da Estratégia 6

Logística, a partir da análise de todas as 37 variáveis disponíveis, o modelo obtido nessa estratégia foi o que produziu a ordenação de vendedores mais eficiente entre todos experimentos, considerando 25 características obtidas a partir da *Regressão Stepwise*.

Até aqui, todas as estratégias foram avaliadas sobre os mesmos dados que foram utilizados para treinar e desenvolver os modelos, e o procedimento da Estratégia 6 foi aquele que leva aos melhores resultados. Contudo, é boa prática, para evitar sobreajuste, que seja separada a amostra de treinamento e teste.

Nas duas próximas estratégias, reservamos apenas 70% das transações para desenvolver os modelos. Na Estratégia 7 avaliamos o modelo sobre os mesmos dados usados no treinamento (70% dos dados) como nas estratégias anteriores, enquanto que na Estratégia 8 avaliamos sobre os 30% restantes. Aproveitamos para simular uma situação mais frequente na identificação de fraudes, à medida que novas transações ocorrem, e conseqüentemente

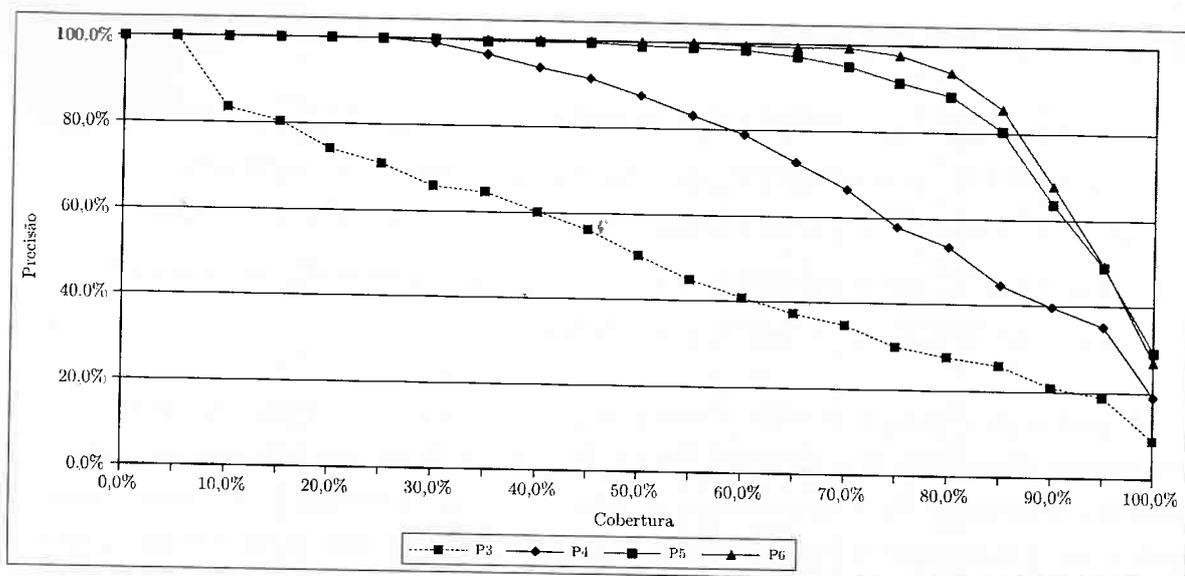


Figura 6.17: Comparação das Precisões P3, P4, P5 e P6 em Função da Cobertura

avaliações/qualificações também, já que adotamos um critério cronológico para separar os dados de treinamento e de teste.

6.2.7 Estratégia 7: Divisão da Amostra em Dados de Treinamento e Teste

Estratégia 7 *Dividir a amostra de dados em duas partes, reservando apenas 70% das transações para desenvolver o modelo de Regressão Logística.*

Com essa estratégia, queremos verificar quão estável é o modelo desenvolvido na Estratégia 6, repetindo os mesmos procedimentos, mas somente para apenas 70% de todas transações.

O primeiro passo foi definir o conjunto de dados de treinamento, utilizando como critério de seleção as primeiras transações em ordem cronológica. Isso correspondeu a 70% de todas as transações existentes na amostra de dados²².

Com a amostra de treinamento definida, adotamos os mesmos procedimentos descritos nesse capítulo, especialmente na Estratégia 6, os quais relembramos a seguir.

Primeiramente, a partir dos dados de transações, expandimos a análise para os vendedores, criando assim uma listagem de vendedores e suas respectivas características, idêntico ao que fizemos na Seção 6.1.3. Em seguida, utilizando a seleção de variáveis por meio de Regressão *Stepwise*, obtivemos o modelo mais otimizado para essa amostra de treinamento, partindo das 37 características existentes. Após a otimização, chegamos em um modelo com

²²Consideramos que a variação desse percentual possa ser objeto de trabalho futuro.

23 variáveis ($p = 23$), representadas nas Equações 6.5, a seguir:

$$\begin{aligned}
 x_1 &= \text{pctITAT}, x_2 = \text{MEAC}, x_3 = \text{pctMEAC}, x_4 = \text{pctMEAT}, x_5 = \text{MEAQ}, \\
 x_6 &= \text{MEVC}, x_7 = \text{pctMEVC}, x_8 = \text{MEVT}, x_9 = \text{MEVQ}, x_{10} = \text{MDCV}, \\
 x_{11} &= \text{pctMDCV}, x_{12} = \text{MIAT}, x_{13} = \text{MIVC}, x_{14} = \text{pctMIVT}, x_{15} = \text{MIVQ}, \\
 x_{16} &= \text{ARCT}, x_{17} = \text{pctARCT}, x_{18} = \text{UDTC}, x_{19} = \text{pctUDTC}, x_{20} = \text{BTVT}, \\
 x_{21} &= \text{pctBTVT}, x_{22} = \text{TCPS}, x_{23} = \text{AVGQ}.
 \end{aligned} \tag{6.5}$$

O gráfico da Figura 6.18 exibe a comparação entre o modelo otimizado para todos os vendedores (Estratégia 6) e o modelo otimizado para os dados que selecionamos para treinamento (Estratégia 7). Observamos que a medida-F da Estratégia 7 (F7) é ligeiramente melhor até a análise de 11% dos vendedores e, depois desse ponto, os valores da medida-F da Estratégia 6 (F6) são ligeiramente melhores. Esses valores também podem ser observados na Tabela 6.18.

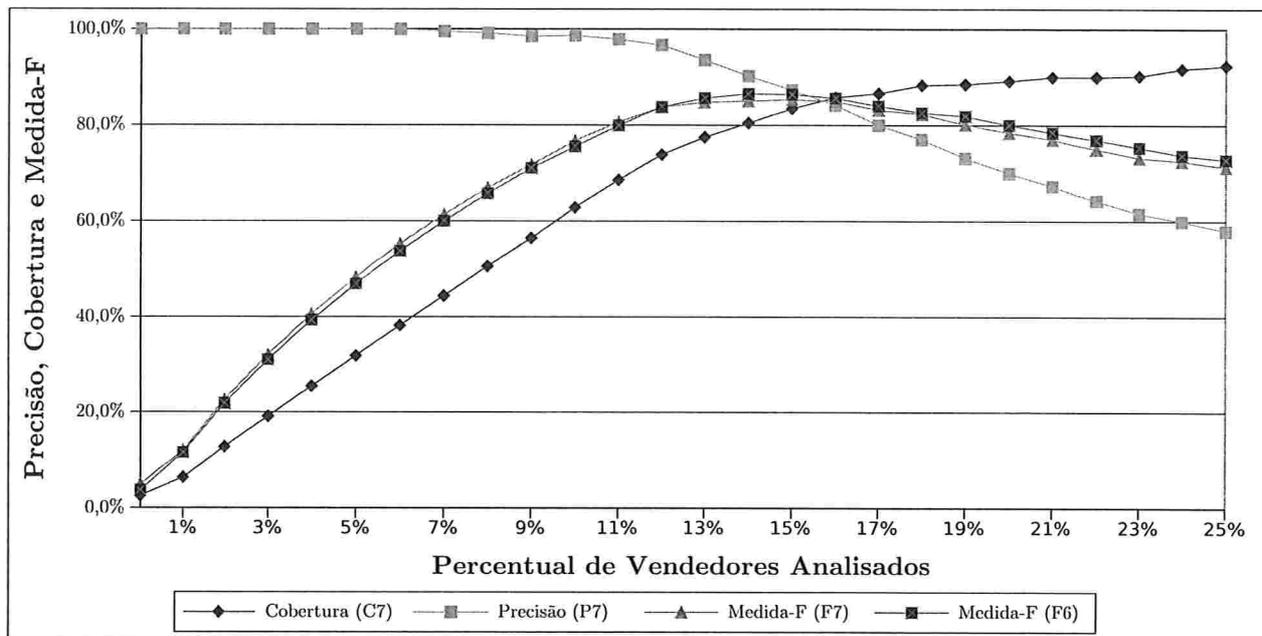


Figura 6.18: Avaliação da Estratégia 7 - Amostra de Treinamento

Em relação à precisão média, a Estratégia 6 obtém 93,0%, enquanto que a Estratégia 7 possui 92,2%, mostrando uma variação mínima, o que não chega a ser grande surpresa, pois os dois modelos foram obtidos por meio dos mesmos procedimentos a partir de 100% das transações, cada um com sua respectiva amostra de treinamento. Com essas medidas, concluímos que esse modelo pode ser utilizado como referência para aplicação na amostra

% Vendedores	C7	P7	F7	F6	(F7-F6)/F6
1%	6,4%	100,0%	0,120	0,115	3,8%
2%	12,7%	100,0%	0,226	0,218	3,6%
3%	19,1%	100,0%	0,321	0,310	3,4%
4%	25,5%	100,0%	0,406	0,393	3,2%
5%	31,8%	100,0%	0,483	0,469	3,1%
6%	38,2%	100,0%	0,553	0,537	2,9%
7%	44,4%	99,5%	0,614	0,600	2,3%
8%	50,5%	99,2%	0,669	0,658	1,8%
9%	56,5%	98,5%	0,718	0,711	1,0%
10%	62,8%	98,7%	0,768	0,756	1,6%
11%	68,6%	97,9%	0,806	0,799	0,9%
12%	73,9%	96,7%	0,838	0,838	-0,1%
13%	77,5%	93,6%	0,848	0,857	-1,0%
14%	80,5%	90,2%	0,851	0,866	-1,7%
15%	83,4%	87,3%	0,853	0,864	-1,2%
16%	85,8%	84,2%	0,850	0,856	-0,8%
17%	86,6%	80,0%	0,832	0,840	-1,0%
18%	88,3%	77,0%	0,823	0,826	-0,4%
19%	88,5%	73,2%	0,801	0,819	-2,1%
20%	89,2%	70,0%	0,784	0,800	-2,0%
21%	90,0%	67,3%	0,770	0,784	-1,8%
22%	90,0%	64,2%	0,750	0,769	-2,5%
23%	90,2%	61,6%	0,732	0,754	-2,8%
24%	91,7%	60,0%	0,725	0,737	-1,6%
25%	92,4%	58,0%	0,713	0,728	-2,2%

Tabela 6.14: Resultados da Estratégia 7 - Amostra de Treinamento

de teste, e esses experimentos serão descritos na próxima seção.

Resultado da Aplicação da Estratégia 7: As medidas obtidas na Estratégia 7, em comparação com a Estratégia 6, mostram que há uma estabilidade do modelo mesmo quando o conjunto de transações e vendedores é modificado.

6.2.8 Estratégia 8: Aplicação do Modelo de Treinamento na Amostra de Teste

Estratégia 8 *Avaliar o modelo de regressão otimizado para a amostra com as 70% primeiras transações mais antigas sobre 30% das transações mais recentes.*

Nesta seção o objetivo é aplicar o modelo de regressão obtido na Estratégia 7, que foi otimizado para os dados de treinamento, em um conjunto de transações que não contribuíram para a construção e otimização desse mesmo modelo. Essa situação é a que consideramos

ser a mais frequente quando um sistema de identificação e detecção de fraude estiver em funcionamento²³.

No gráfico da Figura 6.19 podemos observar que os valores obtidos nos cálculos da medida-F para a amostra de treinamento são melhores do que na amostra de teste até a análise de 14% dos vendedores e, depois desse patamar a situação se inverte. Isso não chega a ser surpresa, já que o modelo não está otimizado para os dados de treinamento. Em

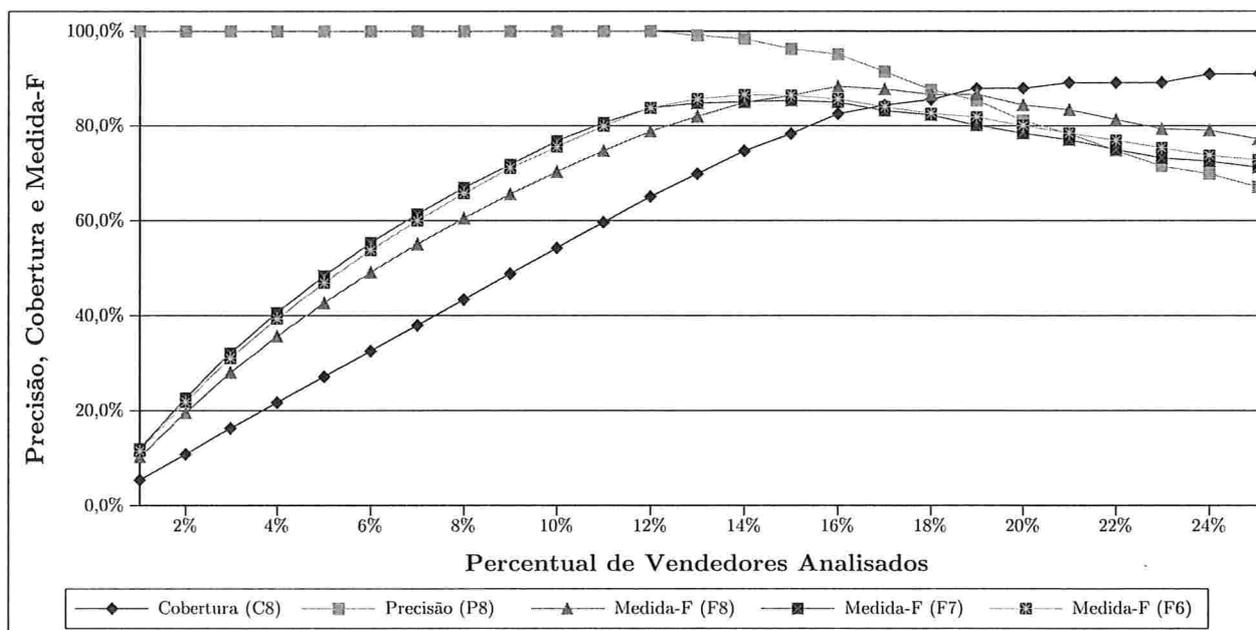


Figura 6.19: Avaliação da Estratégia 8 - Amostra de Teste

relação à precisão média, a amostra de treinamento (Estratégia 7) tinha 92,2%, enquanto que a amostra de teste (Estratégia 8) tem 94,4%, mostrando que apesar da ordenação da Estratégia 7 ser ligeiramente melhor no topo da listagem, no geral, a ordenação da Estratégia 8 até chega a aumentar a precisão média. O gráfico também exibe os valores da medida-F da Estratégia 6 (F6), que foi a melhor estratégia utilizando toda a amostra de dados. A Tabela 6.15 exibe com mais detalhes os valores obtidos nesse experimento, incluindo a variação no valor das medidas-F dessa estratégia (F8), com os da Estratégia 7 (F7) e 6 (F6). Podemos observar também que a precisão de 100% é mantida até a análise de 12% da lista de vendedores, o que é positivo.

Essa situação observada nos resultados da aplicação da Estratégia 8, permite-nos concluir que a metodologia adotada, na qual selecionamos o modelo otimizado para um determinado conjunto de dados, pode ser aplicada a um outro conjunto com novas transações, algo que é

²³A criação de um sistema automático para identificação de fraudes que avalie incrementalmente novas transações é objeto de trabalho futuro.

% Vendedores	C8	P8	F8	F7	(F8-F7)/F7	F6	(F8-F6)/F6
1%	5,4%	100,0%	0,103	0,120	-14,1%	0,115	-10,9%
2%	10,8%	100,0%	0,196	0,226	-13,4%	0,218	-10,3%
3%	16,3%	100,0%	0,280	0,321	-12,8%	0,310	-9,8%
4%	21,7%	100,0%	0,356	0,406	-12,2%	0,393	-9,4%
5%	27,1%	100,0%	0,427	0,483	-11,7%	0,469	-9,0%
6%	32,5%	100,0%	0,491	0,553	-11,2%	0,537	-8,6%
7%	38,0%	100,0%	0,550	0,614	-10,4%	0,600	-8,3%
8%	43,4%	100,0%	0,605	0,669	-9,6%	0,658	-8,0%
9%	48,8%	100,0%	0,656	0,718	-8,6%	0,711	-7,7%
10%	54,2%	100,0%	0,703	0,768	-8,4%	0,756	-6,9%
11%	59,6%	100,0%	0,747	0,806	-7,4%	0,799	-6,5%
12%	65,1%	100,0%	0,788	0,838	-5,9%	0,838	-5,9%
13%	69,9%	99,1%	0,820	0,848	-3,3%	0,857	-4,3%
14%	74,7%	98,4%	0,849	0,851	-0,2%	0,866	-1,9%
15%	78,3%	96,3%	0,864	0,853	1,2%	0,864	0,0%
16%	82,5%	95,1%	0,884	0,850	4,0%	0,856	3,2%
17%	84,3%	91,5%	0,878	0,832	5,5%	0,840	4,5%
18%	85,5%	87,7%	0,866	0,823	5,2%	0,826	4,8%
19%	88,0%	85,4%	0,866	0,801	8,2%	0,819	5,9%
20%	88,0%	81,1%	0,844	0,784	7,6%	0,800	5,5%
21%	89,2%	78,3%	0,834	0,770	8,3%	0,784	6,3%
22%	89,2%	74,7%	0,813	0,750	8,5%	0,769	5,7%
23%	89,2%	71,5%	0,794	0,732	8,4%	0,754	5,3%
24%	91,0%	69,9%	0,791	0,725	9,0%	0,737	7,2%
25%	91,0%	67,1%	0,772	0,713	8,4%	0,728	6,1%

Tabela 6.15: Resultados da Estratégia 8 - Amostra de Teste

um cenário típico dos mercados eletrônicos.

Embora as características tenham sido extraídas a partir da amostra de dados completa, não acreditamos que as características pudessem ser outras caso fossem utilizados apenas 70% dos dados para extraí-las, uma vez que a seleção das características diz respeito à aplicação em si, não a uma parte dos dados utilizados para realizar o treinamento da técnica.

Resultado da Aplicação da Estratégia 8: A aplicação do modelo otimizado para os dados de treinamento na amostra de teste manteve os patamares de eficiência próximos aos obtidos na Estratégia 6, onde considerávamos todas transações e vendedores no desenvolvimento e na avaliação do modelo, bem como na Estratégia 7.

6.3 Influência das Características nos Modelos

Um outro aspecto desejável na identificação de fraude é a confirmação do poder discriminatório das características extraídas. Um processo pontual de validação do conjunto das características já foi feito quando a listagem de vendedores ordenada por indícios de fraude foi fornecida aos especialistas e, posteriormente, o seu topo foi confirmado como contendo apenas fraudadores. Um processo mais metucioso de verificação da influência de cada característica no modelo também pode ser feito.

Na Tabela 6.16 vemos os Z -valores (Z -values) associados a cada variável dos modelos de regressão logística obtidos nas Estratégias de 1 a 8, que foram extraídos das execuções do pacote R relatados no Apêndice C. Z -valores negativos indicam influência *contrária* à fraude no modelo obtido, enquanto que Z -valores positivos indicam influência *favorável* à fraude. Valores absolutos maiores que 2 indicam influência *significativa* (P -valor $< 5\%$) na composição do modelo obtido. Todas as 37 características estão listadas, a começar pelas duas características negativas de fraude TCPS e REC1. Observamos que a característica negativa TCPS se mostrou de fato útil à formação do modelo (como esperado, seu Z -valor é negativo), enquanto que a característica negativa REC1 não consta da maior parte dos modelos, mas aparece de forma mais discreta na composição do modelo da Estratégia 6. Isto pode sugerir a possibilidade de melhorias no processo de julgamento editorial que veio a formar a variável REC1.

A não ser por estas duas características negativas de fraude, TCPS e REC1, e pela variável contínua AVGQ, todas as demais 34 variáveis são formadas ou pelas 17 características positivas, e portanto são variáveis binárias, ou por suas respectivas variáveis derivadas 'pct', e portanto são variáveis contínuas que informam a porcentagem da presença da característica binária nas transações do vendedor. Devido à forte correlação esperada entre uma destas 17 características positivas e sua respectiva percentagem, a Tabela 6.16 agrupa estas 34 variáveis em 17 pares. Assim, podemos observar, por exemplo, que a variável ITAT aparece significativamente na composição do modelo na Estratégia 1, mas que sua variável derivada (pctITAT) a substitui com semelhante destaque na composição dos demais modelos. Convém destacar que a maior influência que observamos se dá para o par de variáveis ARCT/pctARCT, comparecendo ambas de forma significativa na composição de todos os modelos em que foram consideradas. No que diz respeito às demais características positivas de fraude, podemos observar que elas ou suas respectivas variáveis derivadas aparecem significativamente na composição do modelo. Destacam-se também as fortes influências das variáveis MIAT, pctMDCV e o par BTVT/pctBTVT. Em seguida, as variáveis pctMDCV e MEAC também mostram influência relevante.

Variável	Est 1	Est 2	Est 3-4	Est 5	Est 6	Est 7-8
ARCT	11,008	7,094	7,142	7,707	6,520	5,357
pctARCT	—	4,278	4,669	4,659	4,781	2,403
BTVT	3,162	2,476	4,292	5,051	5,393	3,401
pctBTVT	—	0,979	—	—	—	1,559
ITAT	5,459	1,635	1,737	3,257	—	—
pctITAT	—	4,097	4,947	3,869	7,520	5,163
UDTC	-3,473	-0,576	—	—	3,316	2,238
pctUDTC	—	-1,976	-2,780	-1,599	-3,308	-1,998
MDCV	4,403	1,397	—	—	2,847	1,917
pctMDCV	—	2,978	4,585	6,525	4,830	3,609
MEAC	-0,091	1,888	3,037	9,225	3,961	4,300
pctMEAC	—	-2,330	-2,530	-1,848	-1,894	-1,633
MEAQ	0,294	0,349	—	—	—	1,951
pctMEAQ	—	0,182	—	—	3,320	—
MEAT	1,248	-0,021	—	—	2,263	—
pctMEAT	—	0,884	3,221	6,325	—	2,064
MEVC	0,541	0,411	—	—	4,068	3,332
pctMEVC	—	0,480	—	—	—	-1,692
MEVQ	-0,417	-0,113	—	—	1,469	2,543
pctMEVQ	—	-0,54	—	—	—	—
MEVT	0,654	-0,670	—	—	2,799	1,914
pctMEVT	—	1,131	—	—	—	—
MIAC	-2,430	-2,374	-2,602	-0,398	—	—
pctMIAC	—	0,79	—	—	1,492	—
MIAQ	-1,936	-1,908	-1,934	2,337	—	—
pctMIAQ	—	0,224	—	—	—	—
MIAT	4,342	3,464	3,907	5,252	8,287	9,437
pctMIAT	—	-0,376	—	—	—	—
MIVC	2,053	2,009	1,588	5,525	3,423	2,273
pctMIVC	—	-1,356	—	—	-2,570	—
MIVQ	1,841	0,637	—	—	3,392	2,361
pctMIVQ	—	0,216	—	—	—	—
MIVT	-0,924	-1,429	—	—	-1,852	—
pctMIVT	—	1,285	2,422	2,864	2,386	1,540
AVGQ	—	3,635	3,673	1,633	1,466	1,483
REC1	—	0,032	—	—	-1,415	—
TCPS	—	-2,642	-2,666	-1,823	-2,503	-2,132

Tabela 6.16: Z-valores das Variáveis dos Modelos

Em geral, apesar de terem grande razão de chances tanto nas transações quanto nos vendedores, as 12 variáveis (respectivamente agregadas às suas 12 derivadas) que apresentaram mesmo identificador de estação de trabalho ou IP, a não ser pelas duas MIAT e MEAC já comentadas, destacaram-se menos, talvez devido à esperada correlação²⁴ entre diversas delas. Provavelmente isto explique a ausência das variáveis MIAC e MIAQ como variáveis significativas nos modelos finais das Estratégias 6 e 7-8. Acreditamos que deva haver uma forte correlação entre MIAT e ambas. Isto talvez possa explicar porque estas duas variáveis positivas tiveram influência contrária nos modelos das Estratégias de 1 a 5. Fenômeno talvez igualmente inesperado só pudemos observar com a variável UDTC/pctUDTC, talvez devido também ao fato de que se esta variável possui alta razão de chances nas transações, ela possui baixa razão de chances entre os vendedores.

Destacamos ainda que no modelo obtido na Estratégia 6, a não ser pela ausência do par de MIAQ, todos os demais pares de variáveis tiveram um representante com presença final no modelo, algo que não acontece no modelo da Estratégia 3, onde as anotações iniciais não haviam sofrido revisão, já que 5 pares de variáveis não comparecem no modelo final. Ademais, o par relativo a MIAC, que já não tinha influência significativa no modelo da Estratégia 6, é eliminado no processo de otimização da Estratégia 7-8.

Na próxima seção faremos outras análises e comparações dos resultados obtidos ao longo deste Capítulo.

6.4 Avaliação Final dos Resultados

Com a aplicação da metodologia descrita no Capítulo 5 ao longo do Capítulo 6, conseguimos contribuir para o processo de identificação de fraudadores contra o sistema de reputação, seja com as características que foram extraídas, seja com a descoberta de novos fraudadores e também com a produção de uma listagem ordenada de vendedores pela probabilidade estimada de fraude. Essa lista se tornou cada vez mais precisa e eficiente à medida que revisamos os resultados e otimizamos o modelo de Regressão Logística.

Na Seção 6.3 observamos uma análise mais detalhada da influência de cada característica extraída na composição dos modelos referentes a cada uma das estratégias. Em particular, vimos quais características se mostraram mais importantes e quais se mostraram mais irrelevantes. Ainda assim, podemos observar que praticamente todas as características extraídas fizeram parte do modelo final obtido na Estratégia 6, mesmo após a otimização baseada em seleção de características. No restante da seção, analisamos os resultados com base nas medidas de eficiência descritas na Seção 3.2.

No gráfico da Figura 6.20 observamos uma comparação dos valores calculados de precisão,

²⁴ Acreditamos que a análise de correlação possa ser objeto de trabalho futuro.

desde a ordenação obtida na Estratégia 1 até a Estratégia 6, que foi a última estratégia antes de dividir os dados em amostras de treinamento e teste, além da comparação das precisões obtidas nas estratégias 7 e 8, onde houve a divisão da amostra. Podemos observar

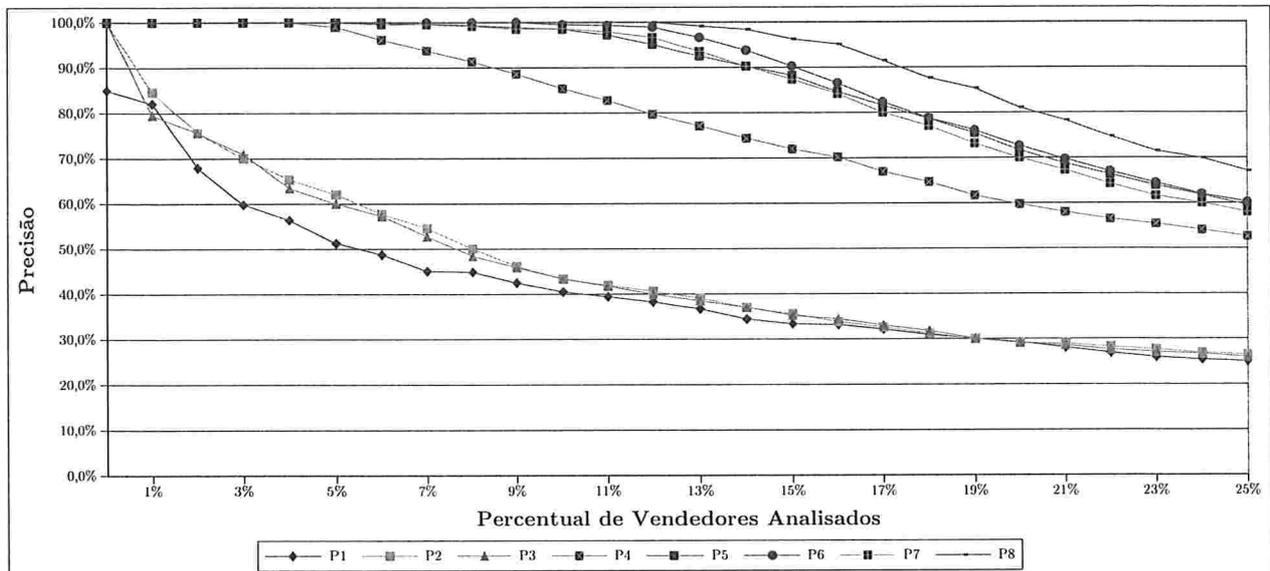


Figura 6.20: Comparação de Precisão entre Estratégias

um aumento gradativo da precisão ao avançar nos experimentos, aplicando as diferentes estratégias apresentadas ao longo da Seção 6.2.

Em relação à precisão média e valor de AIC observamos na Tabela 6.17 um decréscimo do valor de AIC , o que significa uma melhora nessa medida, e um aumento da precisão média, que também é positivo.

Estratégia	AIC	Precisão Média
4	1.401,7	78,0%
5	1.133,7	91,4%
6	1.002,1	93,0%

Tabela 6.17: AIC e Precisão Média nas Estratégias 4, 5 e 6

Outra comparação que pode ser feita é em relação à cobertura. A Tabela 6.18 exhibe a comparação entre a cobertura no conjunto FRS , com as anotações revisadas, após a aplicação das Estratégias 4, 5 e 6 (as coberturas obtidas nas Estratégias 1, 2 e 3 não serão comparadas aqui pois houve aumento significativo de vendedores no conjunto FRS , já que as anotações de fraude e os conjuntos mudaram entre as estratégias 3 e 4). Observamos que, ao passo que a ordenação é aprimorada, além da precisão, o percentual de vendedores analisados necessário para se atingir determinada cobertura (*cobertura desejada*) se torna cada vez menor, como

vemos na Tabela 6.18. Tal situação também pode ser observada principalmente a partir de 50% de cobertura desejada. Para cobrir 80% dos vendedores fraudadores, por exemplo, a

Cobertura Desejada	Percentual de Vendedores Analisados		
	Estratégia 4	Estratégia 5	Estratégia 6
10,0%	1,6%	1,6%	1,6%
20,0%	3,2%	3,2%	3,2%
30,0%	4,9%	4,9%	4,9%
40,0%	6,9%	6,5%	6,5%
50,0%	9,2%	8,2%	8,1%
60,0%	12,3%	9,9%	9,7%
70,0%	17,0%	11,9%	11,4%
80,0%	24,2%	14,6%	13,8%
90,0%	36,6%	22,8%	21,4%
100,0%	97,1%	96,4%	59,4%

Tabela 6.18: Percentual de Vendedores Analisados em Função da Cobertura Desejada nas Estratégias 4, 5 e 6

análise da Estratégia 4 precisava considerar 24,2% da listagem de vendedores, enquanto que a Estratégia 5 necessita de 14,6% e a Estratégia 6 de 13,8%, diminuindo-se assim o esforço e o custo de investigação. Para a cobertura de 100%, por exemplo, na Estratégia 6 é necessário analisar 59,4%, enquanto que nas Estratégias 4 e 5, a análise precisa considerar 97,1% e 96,4%, respectivamente. Se o objetivo for maximizar a cobertura, podemos observar que a cada otimização menos vendedores precisam ser analisados, elevando-se assim as precisões, nos diferentes topos da listagem.

Observamos também que, para obter uma ordenação precisa, é necessário extrair boas características e continuamente otimizar o modelo de Regressão Logística, ajustando-o à medida que novos fraudadores são identificados. Por consequência, modificam-se os elementos dos conjuntos FRS e NFr . Acreditamos que um processo rotineiro e até automático de atualização do modelo pode ser empregado nesse contexto, o qual pode ser objeto de trabalho futuro e continuidade desta pesquisa.

Outra possibilidade para os mercados eletrônicos é a definição de um limiar para inabilitação e suspensão automática dos fraudadores à medida que o modelo se torna mais preciso e eficiente no topo das listagens produzidas. Acreditamos que seja possível definir um tal limite, com base na probabilidade estimada do vendedor ser fraudador, para em seguida efetuar esse procedimento de inabilitação ou suspensão. Os vendedores que tiverem uma probabilidade estimada de fraude inferior a esse limiar careceriam de uma investigação manual para comprovação da fraude e posteriormente contribuiriam para a construção de um novo modelo. Também acreditamos que a avaliação para determinação desses limites possa

ser objeto de trabalho futuro.

Por fim, concluímos que o estudo de caso descrito neste capítulo comprovou que a metodologia proposta no Capítulo 5 contribuiu, na prática, para a identificação de fraudadores contra o sistema de reputação, melhorando a ordenação da listagem de vendedores a cada estratégia adotada. Observamos que as características extraídas foram determinantes para a identificação e ordenação dos fraudadores. As otimizações e ajustes nos modelos de Regressão Logística aplicados ao longo dos experimentos por meio de seleção de características também contribuíram para aperfeiçoar os modelos. Observamos também quão críticas foram as revisões dos especialistas em detecção de fraude para a avaliação de que a metodologia proposta foi bem sucedida em seu propósito de contribuir para a identificação de fraudadores, tanto na extração de características quanto na classificação estatística. A diferença de resultados entre as estratégias de 1 a 3 e de 4 a 6, observada no gráfico da Figura 6.20, é uma demonstração dessa afirmativa.

Dividindo os dados em dois conjuntos, treinamento (baseado nas 70% primeiras transações) e teste (baseado nas 30% transações finais), verificamos pouca alteração nas medidas de eficiência nas ordenações obtidas pelas Estratégias 6, 7 e 8, mostrando que o modelo otimizado para a amostra de treinamento, quando aplicado em novas transações, produz uma ordenação com alta precisão no topo da listagem dessas novas transações. Acreditamos que isto nos aponta também para uma boa estabilidade dos modelos desenvolvidos com todos os dados disponíveis.

Além disso, acreditamos que a metodologia aplicada neste trabalho pode ser aplicada seguindo a estratégia de validação adotada para aperfeiçoar os resultados neste ou em outros cenários, envolvendo fraudes contra o sistema de reputação ou outros tipos de fraude. Acreditamos que é uma oportunidade de trabalho futuro buscar um aumento ainda maior de precisão no topo da listagem sem perder em cobertura.

No próximo capítulo faremos as considerações finais e elencaremos algumas oportunidades de melhoria e continuidade deste trabalho.

Capítulo 7

Conclusões

7.1 Considerações Finais

O crescimento do comércio eletrônico tem sido significativo ao longo dos últimos anos, e um segmento importante desse comércio é o de mercados eletrônicos, onde transações entre compradores e vendedores (em geral de pequeno e médio porte) ocorrem através da Web. Dentro desses mercados, o sistema de reputação é parte fundamental no processo de decisão de compra dos usuários, além de refletir a credibilidade desses *sites* e de seus respectivos compradores e vendedores.

Por movimentar um volume financeiro crescente e atrair um número maior de usuários e transações com o passar do tempo, esses mercados se tornaram alvo de fraudadores, como por exemplo, vendedores interessados em melhorar sua reputação artificialmente. O objetivo desses vendedores pode ser simplesmente obter um incremento em suas vendas, ou preparar a execução de outros tipos de fraude contra os compradores.

Dada a importância dos sistemas de reputação nos mercados eletrônicos e as ocorrências de fraude existentes nesses *sites*, avaliamos alguns trabalhos relacionados à identificação de fraude em mercados eletrônicos, mas que não se mostraram efetivos na aplicação com a amostra de dados que possuímos do mercado eletrônico *TodaOferta*. É importante ressaltar que a anotação de fraudadores na amostra de dados era extremamente confiável, enquanto que os vendedores considerados legítimos careceriam de confirmação, uma vez que existia a suspeita (posteriormente confirmada) de que alguns fraudadores não haviam sido devidamente identificados. Por tudo isso, decidimos propor uma metodologia que lidasse com o problema em questão.

A metodologia proposta, resumidamente, inicia-se com o levantamento e extração de características e posteriormente classifica os vendedores. Na classificação, aplicamos o método de Regressão Logística para produzir uma listagem de vendedores ordenada pela probabilidade estimada de fraude contra o sistema de reputação. Essa lista é o principal requisito

dos especialistas em identificação de fraude e objetivo principal deste trabalho.

Com base nos resultados dos experimentos, concluímos que a metodologia proposta se mostrou efetiva na identificação de fraudadores contra sistemas de reputação no mercado eletrônico *TodaOferta* e acreditamos que essa metodologia possa ser empregada em outras aplicações que fazem uso de um sistema de reputação ou também tratando outros tipos de fraude, já que os procedimentos propostos por ela não são dependentes do contexto de mercados eletrônicos. Obviamente características novas precisarão ser extraídas, pois esse procedimento é altamente dependente do contexto do problema.

Entre os fatores que contribuíram para o sucesso da aplicação da metodologia está o processo de extração de características, que avaliou outros eventos de interação dos usuários com o mercado eletrônico além da própria transação em si, abrangendo assim um número maior de situações. Observamos que não foi necessário retornar ao processo de extração de características ao longo dos experimentos, o que nos faz afirmar que as características selecionadas e o processo como um todo foram bem sucedidos. Em outras palavras, não nos deparamos com a situação de características faltantes após o procedimento de extração.

Outro fator de sucesso também foi não considerar apenas as informações fornecidas pelos especialistas em detecção de fraude, avaliando e validando outros cenários. Essa avaliação foi baseada em nosso conhecimento das regras de negócio dos mercados eletrônicos.

Verificamos que a produção de uma listagem de vendedores ordenada pela probabilidade estimada de fraude contribuiu para o processo de identificação de fraude contra o sistema de reputação. Essa lista foi sendo otimizada e melhorada a cada experimento, utilizando técnicas de regressão já existentes na literatura. A avaliação da qualidade da ordenação foi feita por meio das medidas de precisão, cobertura, medida-F, precisão média e valor de *AIC*, medidas clássicas utilizadas nas áreas de Recuperação de Informação e Aprendizado Computacional. Para exemplificar, o último experimento efetuado com todos os vendedores disponíveis obteve uma precisão média de 93,0% (Estratégia 6), o que é considerado bastante alta e representativa. Além dos experimentos considerando todos os vendedores disponíveis, dividimos a amostra em dados de treinamento e teste, simulando um cenário incremental, pois essa é a situação rotineira de identificação de fraudes em mercados eletrônicos, onde transações novas acontecem e carecem de análise para determinação da fraude. Os experimentos com essa abordagem também se mostraram eficazes, obtendo uma precisão média de 94,4% (Estratégia 8), sendo mais um fator positivo na validação da metodologia proposta.

Uma diferença fundamental deste trabalho em relação a outros que se propuseram a identificar fraudes em mercados eletrônicos é a validação dos resultados com pessoas, especialistas em identificação de fraude. Outros trabalhos relacionados utilizavam as informações

públicas fornecidas pelo sistema de reputação, em geral o número de pontuações negativas, como critério para determinação dos conjuntos de fraudadores e vendedores legítimos, fazendo inferência sobre essa pontuação para determinar os elementos de tais conjuntos. Neste trabalho, tivemos a oportunidade de validar os resultados diretamente com esses especialistas, fortalecendo ainda mais os resultados obtidos.

Contribuímos também para um aumento significativo no número de fraudadores identificados no mercado eletrônico *TodaOferta*, que antes deste trabalho eram considerados vendedores legítimos. Ao solicitarmos a revisão das anotações, novos fraudadores foram descobertos, auxiliando também no aprimoramento da construção do modelo de regressão. Comparando a anotação original com a revisão desses dados, houve um aumento de 112% no conjunto de fraudadores. Tais vendedores, até antes da existência deste trabalho, operavam livremente no mercado eletrônico, fraudando o sistema de reputação. Ademais, se por um lado com a anotação inicial, 5 das 17 características positivas de fraude que foram previstas vieram a ser descartadas no modelo otimizado da Estratégia 3, após a revisão das anotações, pudemos observar que praticamente todas as características extraídas fizeram parte do modelo final obtido na Estratégia 6, o que confirma a qualidade das características extraídas e do processo de identificação de fraudes como um todo.

A seguir, listamos algumas oportunidades de pesquisas futuras para continuidade deste trabalho.

7.2 Sugestões para Pesquisas Futuras

Os itens listados a seguir abordam oportunidades para continuidade dessa pesquisa, bem como itens que podem ser abordados por qualquer interessado nos assuntos deste trabalho:

- Aplicação e aprimoramento da metodologia proposta para identificação de outros tipos de fraude em mercados eletrônicos, além da fraude contra o sistema de reputação que foi tratada neste trabalho. Isso permitirá considerar todas as transações, independentemente da qualificação existente nelas;
- Extração de novas características para melhorar o processo de identificação de fraude, como as particulares aos anúncios, por exemplo. Podemos também continuar a análise das atividades dos vendedores feita por Pereira e outros [27] nos dados do *TodaOferta*, mas com o objetivo de extrair características de fraude;
- Avaliação e comparação de outros métodos de classificação além do método de Regressão Logística, como GEE (*Generalized Estimating Equations*) [31] e SVM^{rank} (*Support Vector Machine for Ranking*) [21];

- Alteração e variação dos limiares utilizados ao longo desta pesquisa, como por exemplo, na razão de chances da avaliação de cada característica e nas separações das amostras de dados para treinamento e teste, permitindo um número maior de comparações e otimizações em pesquisas futuras;
- Emprego de técnicas de análise de relacionamento e correlação das variáveis que representam as características, explorando outras possibilidades que possam contribuir para o processo de identificação de fraudadores;
- Criação de um sistema automático que empregue a metodologia proposta neste trabalho e que, além disso, possibilite construir e ajustar o modelo de regressão à medida que novas transações ocorrem. Esse sistema poderia automatizar também algumas operações e procedimentos dos especialistas após a detecção de fraude, como por exemplo, a suspensão das atividades do vendedor no *site*;
- Avaliação de um método, ou o aprimoramento do método de Regressão Logística, que leve em conta a questão temporal na construção do modelo, uma vez que os fraudadores tendem a criar novos mecanismos de fraude, diferenciando o peso das características que possuam maior ocorrência nas transações recentes;
- Aplicação da metodologia em dados de outros sistemas de reputação adotados em outros mercados eletrônicos;
- Otimização do modelo de regressão com outros critérios além do valor de *AIC*, como precisão média, por exemplo;
- Aprimoramento do modelo de regressão com base no produto vendido ou na categoria do produto - ou utilizar produto ou categoria como mais uma variável do modelo.

Apêndice A

Sistema *NetProbe*

Em 2007, na décima sexta conferência sobre a *World Wide Web* (WWW2007¹), Pandit e outros apresentaram um trabalho denominado “*NetProbe – A Fast and Scalable System for Fraud Detection in Online Auction Networks*” [26], descrevendo um sistema com o objetivo de identificar anomalias e fraudes em uma grande rede de transações entre usuários no contexto de mercados eletrônicos. A ideia principal do sistema é inferir propriedades para um usuário baseado nas propriedades de outros usuários com que ele se relaciona, ou seja, dado um grafo que represente as transações entre usuários do mercado eletrônico, a probabilidade de um usuário ser fraudador é inferida baseada no comportamento deste com seus vizinhos.

Esse sistema se divide em dois módulos. O primeiro foi constituído de uma série de agentes que coletaram e consolidaram os dados obtidos diretamente do *site* do *eBay*, com cerca de 800 mil transações feitas por aproximadamente 66 mil usuários. Uma outra amostra de dados sintética foi criada com 7 mil usuários e 30 mil transações. O segundo módulo é composto pelo sistema que analisa os relacionamentos da rede de negociações para identificar a fraude.

Os autores do *NetProbe* modelaram as transações entre os usuários como um grafo, com os nós representando os usuários e uma ou mais arestas representando as transações entre os mesmos.

Essa abordagem é similar ao que encontramos na *Web*, em que uma ligação entre uma página e outra confere autoridade da página de origem para a página de destino [6]. Considerando o relacionamento entre os usuários dos mercados eletrônicos, a aresta possui uma semântica, que pode ser utilizada para propagar propriedades de um nó para seus vizinhos [26]. A Figura 4.1 mostra um exemplo dessa modelagem.

De acordo com essa semântica, uma aresta poderia ser considerada como um indicador de similaridade de comportamento - usuários honestos interagiriam com outros usuários honestos e os fraudadores interagiriam entre si em pequenos cliques. Tal interpretação é muito

¹<http://www2007.org>

similar à técnica utilizada pelo *TrustRank* [18], uma variante do *PageRank* [6], utilizado para combater *spam* em páginas *Web*.

Porém, de acordo com Pandit e outros [26], esse cenário em que honestos se relacionam com honestos e fraudadores com fraudadores, não pode ser aplicável nos sistemas de reputação de mercados eletrônicos, pois a intenção do fraudador é sempre aproveitar-se de usuários honestos, na maioria das vezes inexperientes, para obter ganhos financeiros. Os autores também publicaram trabalhos no qual comprovam a evidência de que esses cliques não eram formados pelos usuários fraudadores. Para maiores detalhes desses trabalhos é necessário verificar as referências publicadas no artigo do *NetProbe* [26].

Antes de prosseguir detalhando o *NetProbe*, apresentamos algumas definições relativas a grafos que serão utilizadas.

A.1 Grafos

Um *grafo* é um par (V, A) onde V é um conjunto qualquer e $A \subseteq V \times V$ é um conjunto de pares ordenados de elementos de V . Cada elemento de A é chamado *aresta de G* e cada elemento de V é chamado *vértice de G*.

Tipicamente, vértices são representados por letras minúsculas u, v e vizinhas enquanto que arestas são representadas por letras e, f, g , etc. [12] Na Figura A.1, por exemplo, temos um grafo com cinco vértices e dez arestas.

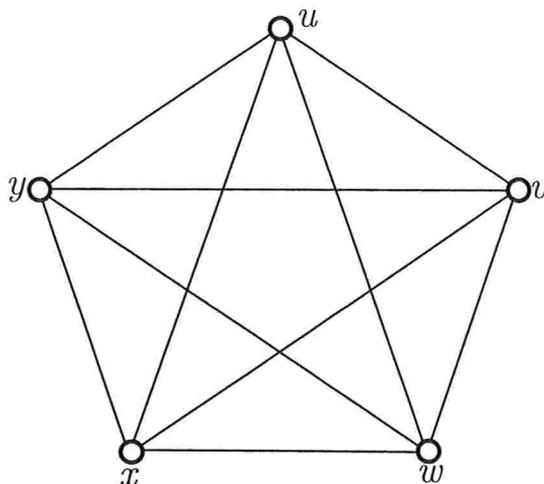


Figura A.1: Exemplo de Grafo

[htb]

Outra explicação preliminar é a definição de *subgrafo induzido*. Dizemos que um grafo H é um *subgrafo* de um grafo G se $V(H) \subseteq V(G)$ e $A(H) \subseteq A(G)$, e escrevemos apenas $H \subseteq G$. Se G é um grafo e $\emptyset \neq X \subseteq V(G)$, denotamos por $G[X]$ o grafo induzido por X ,

definido como subgrafo de G cujo conjunto de vértices é X e cujo termino de arestas consiste de todas as arestas de $A(G)$ que têm dois extremos em X .

Um *grafo bipartido* é um grafo cujos vértices podemos separar em dois conjuntos distintos V_1 e V_2 e as arestas sempre unem vértices de um conjunto com vértices de outro conjunto:

$$\begin{cases} V_1 \cup V_2 = V \\ V_1 \cap V_2 = \emptyset \\ \forall x_1, x_2 \in V_1, \forall y_1, y_2 \in V_2 \text{ não existe nenhuma aresta } e = (x_1, x_2) \text{ nem } e = (y_1, y_2) \end{cases}$$

A Figura A.2 mostra um exemplo de *grafo bipartido* para os conjuntos V_1 e V_2 .

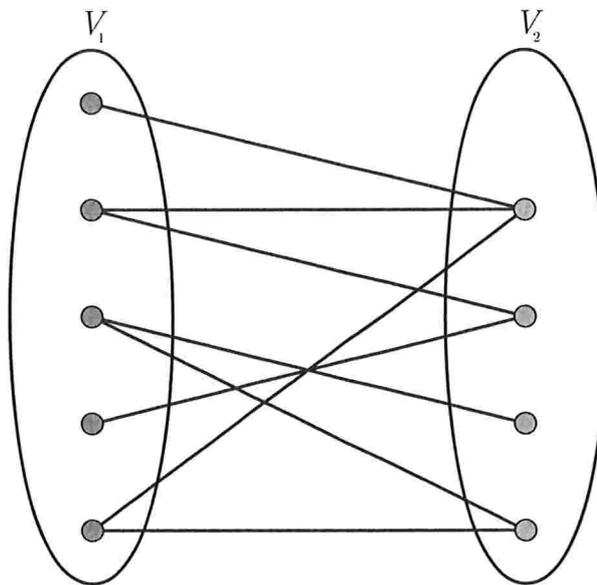


Figura A.2: Exemplo de Grafo Bipartido

Outra definição que utilizamos neste trabalho é relativa a *grafos bipartidos completos*.

Um *grafo bipartido completo* é um grafo bipartido cujos vértices podem ser divididos em dois conjuntos, E e D (de esquerda e direita), de modo que *cada* vértice de E tenha uma aresta *para cada* vértice em D . A Figura A.3 mostra um exemplo de um Grafo Bipartido Completo.

Um (i, j) -*núcleo bipartido* de um grafo bipartido (E, D) é um subconjunto E' de E de tamanho i e um subconjunto D' de tamanho j de modo que o subgrafo induzido (E', D') é um grafo bipartido completo.

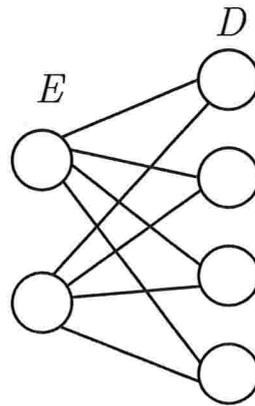


Figura A.3: Exemplo de Grafo Bipartido Completo

A.2 Descrição do *NetProbe*

Os autores do *NetProbe* descobriram que a maneira como os fraudadores agem nos mercados eletrônicos levam à formação de grafos com núcleos bi-partidos no grafo das transações, de modo que os fraudadores criam dois tipos de identidade e arbitrariamente se dividem em fraude e cúmplice.

As identidades de fraude são as utilizadas para completar a fraude, enquanto as identidades de cúmplices existem apenas para aumentar o percentual de avaliações/qualificações positivas dos fraudadores. Os cúmplices se comportam como usuários honestos, podendo interagir com outros do mesmo tipo, para também obter altos percentuais de qualificações positivas, mas por outro lado, também interagem com os usuários fraudadores. Tal característica, de criação de identidades para aumentar o número de qualificações positivas, também foi observada dentro da amostra de dados do *TodaOferta*.

Conforme Pandit e outros [26], essa abordagem dos fraudadores permite que as identidades fraudulentas possam até ser removidas, mas também permite que as identidades cúmplices sobrevivam e sejam reutilizadas em futuras fraudes.

Em termos de construção do sistema de análise e detecção de fraude que deu origem ao *NetProbe*, as transações são modeladas como *Campos Aleatórios Markovianos*, que em inglês é conhecido como *Markov Random Field* (MRF). Um MRF consiste em um grafo não-dirigido, em que cada nó pode ter um número finito de estados. O estado do nó depende estatisticamente dos seus vizinhos, e independe de outros nós no grafo, com o nó representando os usuários e as arestas correspondendo às transações, sendo que o nó pode assumir três estados: fraudador, cúmplice e honesto².

Em seguida, é instanciada uma matriz de propagação, baseada na seguinte intuição: um fraudador tende a possuir ligações com cúmplices, mas evita transações com outros

²Para mais detalhes sobre MFRs veja [30]

fraudadores; um cúmplice tende a se relacionar com usuários honestos e fraudadores, com maior afinidade com estes últimos; por outro lado, o usuário honesto se relaciona com outros honestos e com cúmplices (desde que pareçam ser honestos).

Nesse sistema, a dependência entre os nós e seus vizinhos é representada por uma matriz de propagação (ψ), tal que $\psi(i, j)$ é igual à probabilidade de um nó estar no estado j sabendo-se que seu vizinho está no estado i . Com esta representação e tendo conhecido alguns nós confiáveis inferidos manualmente, simplificadamente, a função de propagação envia mensagens entre os nós iterativamente baseada no conhecimento anterior, e segue alterando a probabilidade até convergir ou até se atingir um determinado número de execuções.

Para iniciar a matriz de propagação $\psi(i, j)$, é necessário partir de uma tabela que defina as probabilidades iniciais. Um exemplo está na Tabela A.1. O valor utilizado para ϵ_p nos experimentos do *NetProbe* foi de 0,05, mas os autores acreditam que o valor pode ser ajustado em experimentos futuros.

Estado do vizinho	Estado dos nós		
	Fraudador	Cúmplice	Honesto
Fraudador	ϵ_p	$1 - 2\epsilon_p$	ϵ_p
Cúmplice	0,5	$2\epsilon_p$	$0,5 - 2\epsilon_p$
Honesto	ϵ_p	$(1 - \epsilon_p)/2$	$(1 - \epsilon_p)/2$

Tabela A.1: Tabela de Exemplo da Instanciação do *NetProbe*

A execução do algoritmo consiste em iniciar os nós do grafo imparcialmente, ou seja, com a mesma probabilidade do usuário ser fraudador, honesto ou cúmplice. Em seguida, os nós enviam mensagens iterativamente e interferem na probabilidade anteriormente citada. Os autores ressaltam que, dessa maneira, a matriz de propagação utilizada proporciona uma chance maior de ter o estado de cúmplice para cada nó no grafo ao final da primeira iteração. Esses cúmplices forçam seus vizinhos a terem o estado de honesto ou fraudador dependendo da estrutura do grafo.

No caso de núcleos bi-partidos, metade do núcleo é empurrado na direção do estado de fraudador, levando a um equilíbrio. No grafo remanescente, é atingido o equilíbrio mais favorável por meio da anotação de alguns dos nós como honestos. Ao final da execução, os nós no núcleo bipartido são anotados como fraudadores ou cúmplices. A ideia central é de que modo os cúmplices forçam seus parceiros a serem fraudadores nos núcleos bipartidos, demonstrando portanto um bom mecanismo para sua detecção.

De acordo com os autores do *NetProbe*, embora a convergência não seja garantida em teoria, na prática o algoritmo convergiu rapidamente, apresentando uma cobertura próxima a 100%, o que mostra que o algoritmo detecta quase todos os núcleos bi-partidos, e uma previsão maior que 90%, o que indica que o *NetProbe* pode gerar alguns alarmes falsos.

A Figura A.4 ilustra o final da execução do *NetProbe* em uma amostra pequena, apenas para exemplificar. Para sermos fiéis ao que os autores publicaram, utilizamos exatamente a mesma figura publicada neste trabalho.

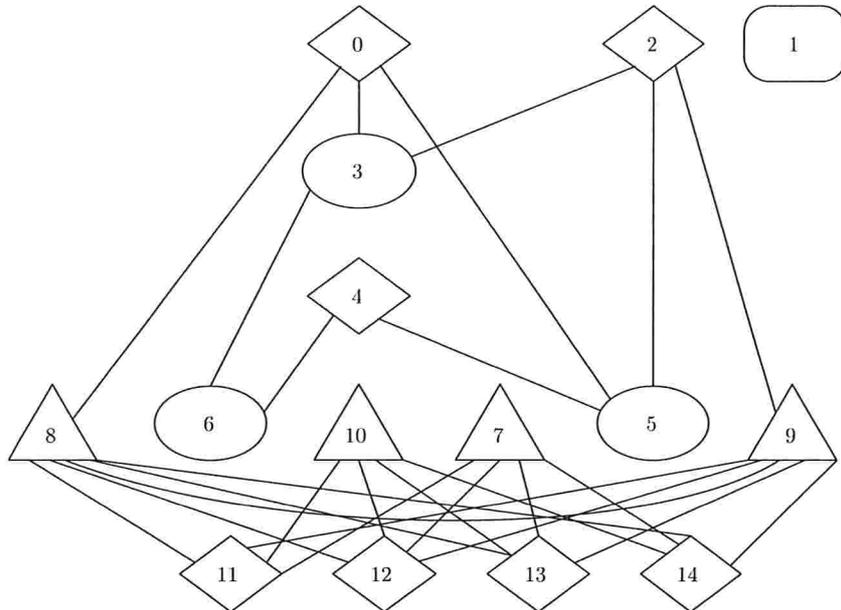


Figura A.4: Exemplo da Execução Final do *NetProbe*

Na Figura A.4 as elipses representam os usuários honestos, os triângulos os fraudadores, os losangos representam os cúmplices e o retângulo de cantos arredondados representa o usuário que não foi classificado em nenhuma das classes anteriores. No início da execução, as ligações entre os nós já existiam, mas apenas alguns tinham seu estado conhecido.

Segundo Pandit e outros [26], a vantagem do *NetProbe* está na sua habilidade em não somente localizar os fraudadores, mas também prognosticar usuários que tendem a cometer fraudes no futuro.

A.3 Experimentos com *NetProbe*

O primeiro experimento foi verificar entre os compradores o número de vendedores que eles realizaram alguma transação. A Tabela A.2 mostra o resultado dessa distribuição, e podemos observar que menos de 14% dos compradores realizaram transações com mais de um vendedor, ou seja, a grande maioria dos compradores transacionaram com apenas um vendedor.

O passo seguinte foi excluir da análise aqueles compradores que realizaram somente uma transação, já que este caso formaria um núcleo bi-partido onde uma partição tem apenas um vértice. Verificamos que 49,3% dos vendedores fraudadores possuíam ligação com compradores que também compraram de outros vendedores (fraudadores ou não). Os demais

Número de vendedores	% de compradores
1	86,8%
2	9,6%
3	2,3%
4	0,6%
5	0,3%
Mais que 5	0,4%

Tabela A.2: Número de Vendedores por Comprador

vendedores fraudadores (50,7%) venderam apenas a compradores que compraram de um único vendedor. Isso implica que uma eventual aplicação do *NetProbe* tem potencial de encontrar no máximo metade dos fraudadores já conhecidos.

Mesmo com esse percentual que consideramos insatisfatório frente aos objetivos do trabalho, decidimos continuar a investigação analisando manualmente exemplos dos grafos de transações, antes de decidir por implementar o algoritmo do *NetProbe* ou adotar outras abordagens.

Escolhemos 4 casos para essa análise manual e desenhamos o grafo das transações para todas elas, observando todas as transações do usuário, sempre considerando a anotação de fraudador ou não para esses usuários. O critério para essa escolha foi baseado no número de vendedores ligados ao comprador, pois acreditamos que essa decisão abrangeria uma cobertura maior desses vendedores.

Chegamos a validar com os especialistas em detecção de fraude do *TodaOferta* para verificar se não existiam no grafo fraudadores anotados como vendedores legítimos, mas em nenhum dos casos houve qualquer indício de descobrimento de novos fraudadores, ou seja, todos os usuários estavam corretamente anotados, tornando questionável a aplicação do *NetProbe*.

Outro experimento realizado foi selecionar todos os compradores que estivessem anotados a pelo menos dois vendedores anotados como fraudadores contra o sistema de reputação e, a partir deles, procurar no grafo transações que pudessem indicar a estrutura de núcleos bi-partidos. A Figura A.5 ilustra um exemplo da formação que procuramos – a linha contínua indica a transação existente enquanto as linhas tracejadas indicam as transações que procurávamos a fim de verificar o percentual de vendedores fraudadores que pudessem ser identificados com essa abordagem que é a base do *NetProbe*.

Considerando todos os vendedores que foram encontrados com essa abordagem, localizamos 17,1% dos vendedores anotados como fraudadores contra o sistema de reputação, o que avaliamos ser mais um indício de que o método do *NetProbe* não trará bons resultados considerando objetivo de identificação de fraudadores deste trabalho.

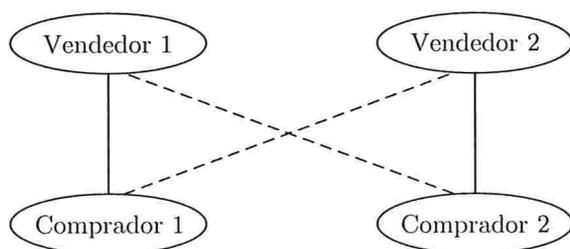


Figura A.5: Formação Procurada no Grafo de Transações

Nesse ponto, decidimos por abandonar a possibilidade de implementação do *NetProbe* e envolver os especialistas em detecção de fraude do *TodaOferta*, com o objetivo de levantar características das transações, que não fossem relacionadas ao grafo completo de transações. Na nossa visão, haveria um custo muito alto na reimplementação e testes, já que o artigo não mostrava detalhes do seu funcionamento, e com os experimentos e análises feitos anteriormente, não justificaria tal custo frente ao potencial existente até então.

Vale ressaltar que na descrição do artigo do *NetProbe*, os autores afirmam que a análise de ligações é mais promissora na identificação de fraudadores do que analisar características relacionadas a transação entre comprador e vendedor, mas essa era uma das opções que nos restava para prosseguir na identificação dos fraudadores. Posteriormente, no decorrer deste trabalho, vemos que essa foi uma decisão acertada e encontrou um número maior de fraudadores dentro do mercado eletrônico, com maior precisão e cobertura, principalmente.

Analisando os resultados que obtivemos até aqui e os resultados publicados no *NetProbe*, concluímos que a validação do usuário (comprador ou vendedor) em relação a ser fraudador ou não se deu com base na existência de um percentual de avaliações negativas nas últimas transações do usuário.

Em nossa opinião, isso não é suficiente para identificar fraudadores, já que avaliações negativas podem ocorrer independentemente de fraudes. Uma situação que pode ocorrer, por exemplo, é determinado vendedor ter problemas com seu estoque ou com o meio de entrega de seus produtos e demorar um tempo maior para entregar o produto para o comprador. Em casos como esses, é comum haver a qualificação negativa e isso não é certeza de fraude, seja qualquer tipo de fraude ou fraude contra o sistema de reputação, principalmente.

Entretanto, como não implementamos o *NetProbe* e nem conseguimos sua implementação para executá-lo na amostra de dados, não podemos afirmar também que os resultados publicados no *NetProbe* não podem ser aplicados em outros mercados eletrônicos ou até mesmo na amostra de dados que possuímos. O método parece bastante consistente e eventualmente pode ser adaptado ao cenário que temos na amostra de dados, mas sua aplicação nessa amostra não indicou ser promissora.

Acreditamos também que outro fator que pode ter contribuído para essa diferença de

resultados é o tempo de operação e volume dos dois mercados. O *eBay* foi fundado em 1995, enquanto o *TodaOferta* foi lançado no segundo semestre de 2007. Além disso, o *eBay* está inserido dentro do mercado americano, além de ramificações em outros países, como Canadá, Inglaterra, Austrália e França, onde o volume de transações de comércio eletrônico é bem superior à observada no Brasil [7, 14].

Resumindo o que descrevemos ao longo dessa seção, os seguintes fatores foram decisivos para abandonar a implementação do *NetProbe* e utilizar uma outra abordagem para identificação de fraudadores:

1. Baixo número de compradores ligados a mais de um vendedor (menos de 16%);
2. A procura por núcleos bi-partidos poderia atingir no máximo 17,1% dos fraudadores, deixando a grande maioria (quase 83%) sem detecção, necessitando que outros métodos fossem aplicados para atingi-los;
3. Avaliações manuais feitas por especialistas em detecção de fraude não forneceram indícios de que o método do *NetProbe* pudesse encontrar mais fraudadores do que os que estavam anotados na amostra de dados.
4. O critério utilizado para decidir se um vendedor é ou não fraudador é baseado no número e recorrência de qualificações negativas, o que não é conclusivo.
5. A avaliação de eficiência não levou em conta qualquer validação oficial, especialmente de especialistas em detecção de fraude do *eBay*;
6. Não há descrição sobre como os dados sintéticos foram criados para avaliar a eficiência do sistema
7. O modelo de negócio do *eBay* e *TodaOferta* possuem diferenças significativas na cobrança de taxas, além do volume de transações e do período de atuação do *eBay* ser significativamente maior .

Apêndice B

Pacote R - Comandos Utilizados

```
# Leitura dos dados de treinamento
DadosTreinamento <- read.table(CAMINHO_DO_ARQUIVO, col.names=c(COLUNAS))

# Aplicação da Regressão Logística
logit.out <- glm(FRS~CARACTERISTICA_1+CARACTERISTICA_2+...+CARACTERISTICA_N,
family=binomial(link=logit), data=DadosTreinamento)

# Leitura dos dados de execução
DadosDeExecucao<- read.table(CAMINHO_DO_ARQUIVO, col.names=c(COLUNAS))

# Cálculo das probabilidades
Prognostico<-predict(logit.out,newdata=DadosDeExecucao,type="response")

# Agregando o prognóstico aos dados de execução
resultado <-cbind(DadosDeExecucao,Prognostico)
resultado <- resultado[order(resultado$Prognostico,decreasing = TRUE,
na.last = TRUE), ]
```


Apêndice C

Resultado das Execuções dos *scripts* no *pacote R*

Nesta seção registramos o resultado obtido no *pacote R* quando executávamos os *scripts* que aplicavam as estratégias de utilização do método de Regressão Logística ocorrida na Seção 6.2.

C.1 Execução da Estratégia 1

Call:

```
glm(formula = FRS ~ ITAT + MEAC + MEAT + MEAQ + MEVC + MEVT +  
      MEVQ + MDCV + MIAC + MIAT + MIAQ + MIVC + MIVT + MIVQ + ARCT +  
      UDTC + BTVT, family = binomial(link = logit), data = HLdata)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-1.9832	-0.3921	-0.1303	-0.1303	3.3146

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-4.76459	0.19257	-24.742	< 2e-16 ***
ITAT	1.00157	0.18349	5.459	4.80e-08 ***
MEAC	-0.03031	0.33265	-0.091	0.927403
MEAT	0.54218	0.43443	1.248	0.212019
MEAQ	0.11897	0.40459	0.294	0.768709
MEVC	0.19776	0.36536	0.541	0.588324
MEVT	0.32713	0.50011	0.654	0.513042
MEVQ	-0.20077	0.48126	-0.417	0.676551
MDCV	0.99988	0.22707	4.403	1.07e-05 ***

MIAC	-0.81895	0.33708	-2.430	0.015117	*
MIAT	1.64554	0.37895	4.342	1.41e-05	***
MIAQ	-0.69694	0.35999	-1.936	0.052868	.
MIVC	0.93096	0.45356	2.053	0.040114	*
MIVT	-0.52932	0.57271	-0.924	0.355359	
MIVQ	0.99873	0.54263	1.841	0.065691	.
ARCT	2.23746	0.20326	11.008	< 2e-16	***
UDTC	-0.72453	0.20861	-3.473	0.000514	***
BTVT	0.46552	0.14722	3.162	0.001566	**

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter or binomial family taken to be 1)

Null deviance: 2122.9 on 3947 degrees of freedom
 Residual deviance: 1454.9 on 3930 degrees of freedom
 AIC: 1490.9

Number of Fisher Scoring iterations: 7

C.2 Execução da Estratégia 2

```
> summary(logit.out)
```

Call:

```
glm(formula = FRS ~ ITAT + pctITAT + MEAC + pctMEAC + MEAT +
     pctMEAT + MEAQ + pctMEAQ + MEVC + pctMEVC + MEVT + pctMEVT +
     MEVQ + pctMEVQ + MDCV + pctMDCV + MIAC + pctMIAC + MIAT +
     pctMIAT + MIAQ + pctMIAQ + MIVC + pctMIVC + MIVT + pctMIVT +
     MIVQ + pctMIVQ + ARCT + pctARCT + UDTC + pctUDTC + BTVT + pctBTVT +
     TCPS + AVGQ + REC1, family = binomial(link = logit), data = HLdata)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-----	----	--------	----	-----

-2.2329 -0.3310 -0.1451 -0.1144 3.2954

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-5.6610987	0.3184762	-17.776	< 2e-16	***
ITAT	0.4373357	0.2674684	1.635	0.102030	
pctITAT	0.0155582	0.0037977	4.097	4.19e-05	***
MEAC	0.8913893	0.4721994	1.888	0.059061	.
pctMEAC	-0.0174587	0.0074938	-2.330	0.019820	*
MEAT	-0.0128949	0.6108822	-0.021	0.983159	
pctMEAT	0.0082646	0.0093503	0.884	0.376760	
MEAQ	0.1872007	0.5366795	0.349	0.727230	
pctMEAQ	0.0016183	0.0088750	0.182	0.855317	
MEVC	0.2221240	0.5404247	0.411	0.681060	
pctMEVC	0.0037444	0.0077962	0.480	0.631019	
MEVT	-0.5051601	0.7542565	-0.670	0.503020	
pctMEVT	0.0119516	0.0105700	1.131	0.258180	
MEVQ	-0.0800341	0.7099864	-0.113	0.910248	
pctMEVQ	-0.0057941	0.0107381	-0.540	0.589485	
MDCV	0.4278465	0.3062453	1.397	0.162392	
pctMDCV	0.0197217	0.0066233	2.978	0.002905	**
MIAC	-1.1561095	0.4870679	-2.374	0.017615	*
pctMIAC	0.0063700	0.0080651	0.790	0.429630	
MIAT	1.8484506	0.5336006	3.464	0.000532	***
pctMIAT	-0.0032842	0.0087302	-0.376	0.706778	
MIAQ	-0.9782787	0.5127365	-1.908	0.056397	.
pctMIAQ	0.0019185	0.0085623	0.224	0.822707	
MIVC	1.5324558	0.7628718	2.009	0.044558	*
pctMIVC	-0.0135723	0.0100096	-1.356	0.175118	
MIVT	-1.5055312	1.0533042	-1.429	0.152906	
pctMIVT	0.0172926	0.0134623	1.285	0.198960	
MIVQ	0.6419864	1.0072123	0.637	0.523871	
pctMIVQ	0.0028709	0.0132999	0.216	0.829096	
ARCT	1.7999729	0.2537413	7.094	1.31e-12	***
pctARCT	0.0114040	0.0026656	4.278	1.88e-05	***
UDTC	-0.1543305	0.2679434	-0.576	0.564628	

pctUDTC	-0.0104873	0.0053077	-1.976	0.048169	*
BTVT	0.5157560	0.2083312	2.476	0.013299	*
pctBTVT	0.0028944	0.0029572	0.979	0.327691	
TCPS	-0.0412075	0.0155972	-2.642	0.008242	**
AVGQ	0.0025409	0.0006991	3.635	0.000278	***
REC1	0.0103327	0.3237277	0.032	0.974538	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
(Dispersion parameter for binomial family taken to be 1)

Null deviance: 2122.9 on 3947 degrees of freedom
Residual deviance: 1354.0 on 3910 degrees of freedom
AIC: 1430.0

Number of Fisher Scoring iterations: 7

C.3 Execução da Estratégia 3

Call:

```
glm(formula = FRS ~ ITAT + pctITAT + MEAC + pctMEAC + pctMEAT +
     pctMDCV + MIAC + MIAT + MIAQ + MIVC + pctMIVT + ARCT + pctARCT +
     pctUDTC + BTVT + TCPS + AVGQ, family = binomial(link = logit),
     data = HLdata)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-2.3167	-0.3302	-0.1441	-0.1156	3.3395

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-5.632426	0.309236	-18.214	< 2e-16 ***
ITAT	0.379297	0.218399	1.737	0.08244 .
pctITAT	0.016598	0.003355	4.947	7.53e-07 ***
MEAC	0.863184	0.284193	3.037	0.00239 **

pctMEAC	-0.012164	0.004807	-2.530	0.01139	*
pctMEAT	0.011711	0.003636	3.221	0.00128	**
pctMDCV	0.024563	0.005357	4.585	4.54e-06	***
MIAC	-0.911725	0.350327	-2.602	0.00925	**
MIAT	1.423549	0.364353	3.907	9.34e-05	***
MIAQ	-0.602422	0.311458	-1.934	0.05309	.
MIVC	0.589352	0.371016	1.588	0.11218	
pctMIVT	0.010186	0.004206	2.422	0.01544	*
ARCT	1.758252	0.246170	7.142	9.17e-13	***
pctARCT	0.012052	0.002581	4.669	3.02e-06	***
pctUDTC	-0.012057	0.004337	-2.780	0.00543	**
BTVT	0.659410	0.153650	4.292	1.77e-05	***
TCPS	-0.040355	0.015135	-2.666	0.00767	**
AVGQ	0.002431	0.000662	3.673	0.00024	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 2122.9 on 3947 degrees of freedom
 Residual deviance: 1365.7 on 3930 degrees of freedom
 AIC: 1401.7

Number of Fisher Scoring iterations: 7

C.4 Execução da Estratégia 5

Call:

```
glm(formula = real ~ ITAT + pctITAT + MEAC + pctMEAC + pctMEAT +
     pctMDCV + MIAC + MIAT + MIAQ + MIVC + pctMIVT + ARCT + pctARCT +
     pctUDTC + BTVT + TCPS + AVGQ, family = binomial(link = logit),
     data = HLdata)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-3.31511	-0.23680	-0.10359	-0.08684	3.40439

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-5.7256381	0.3426901	-16.708	< 2e-16	***
ITAT	0.7786917	0.2390599	3.257	0.001125	**
pctITAT	0.0147736	0.0038188	3.869	0.000109	***
MEAC	3.2257930	0.3496845	9.225	< 2e-16	***
pctMEAC	-0.0138810	0.0075097	-1.848	0.064543	.
pctMEAT	0.0372408	0.0058881	6.325	2.54e-10	***
pctMDCV	0.0418213	0.0064095	6.525	6.81e-11	***
MIAC	-0.1559063	0.3917165	-0.398	0.690624	
MIAT	2.3420825	0.4459633	5.252	1.51e-07	***
MIAQ	1.0038900	0.4295023	2.337	0.019422	*
MIVC	2.8309831	0.5123623	5.525	3.29e-08	***
pctMIVT	0.0239835	0.0083755	2.864	0.004190	**
ARCT	1.8980555	0.2462732	7.707	1.29e-14	***
pctARCT	0.0137560	0.0029529	4.659	3.19e-06	***
pctUDTC	-0.0074635	0.0046683	-1.599	0.109878	
BTVT	0.8649952	0.1712536	5.051	4.40e-07	***
TCPS	-0.0230063	0.0126180	-1.823	0.068260	.
AVGQ	0.0012151	0.0007441	1.633	0.102460	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 3489.2 on 3947 degrees of freedom
 Residual deviance: 1097.7 on 3930 degrees of freedom
 AIC: 1133.7

Number of Fisher Scoring iterations: 7

C.5 Execução da Estratégia 6

Call:

```
glm(formula = real ~ pctITAT + MEAC + pctMEAC + MEAT + pctMEAQ +
     MEVC + MEVT + MEVQ + MDCV + pctMDCV + pctMIAC + MIAT + MIVC +
     pctMIVC + MIVT + pctMIVT + MIVQ + ARCT + pctARCT + UDC + pctUDC +
     BTVT + TCPS + AVGQ + REC1, family = binomial(link = logit),
     data = HLdata)
```

Deviance Residuals:

	Min	1Q	Median	3Q	Max
	-2.62355	-0.20658	-0.08623	-0.07165	3.32507

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-6.0985209	0.3771136	-16.172	< 2e-16	***
pctITAT	0.0262700	0.0034935	7.520	5.49e-14	***
MEAC	2.0339388	0.5135211	3.961	7.47e-05	***
pctMEAC	-0.0160048	0.0084486	-1.894	0.058176	.
MEAT	0.9484382	0.4191927	2.263	0.023664	*
pctMEAQ	0.0220048	0.0066282	3.320	0.000901	***
MEVC	2.0131143	0.4948587	4.068	4.74e-05	***
MEVT	2.0147852	0.7197183	2.799	0.005120	**
MEVQ	0.9904384	0.6740564	1.469	0.141732	
MDCV	0.9062900	0.3183407	2.847	0.004414	**
pctMDCV	0.0388772	0.0080499	4.830	1.37e-06	***
pctMIAC	0.0100282	0.0067191	1.492	0.135573	
MIAT	2.7982252	0.3376537	8.287	< 2e-16	***
MIVC	3.9367974	1.1502685	3.423	0.000620	***
pctMIVC	-0.0384305	0.0149552	-2.570	0.010178	*
MIVT	-2.4948322	1.3467706	-1.852	0.063960	.
pctMIVT	0.0414827	0.0173842	2.386	0.017022	*
MIVQ	3.3193573	0.9784893	3.392	0.000693	***
ARCT	1.7816198	0.2732373	6.520	7.01e-11	***
pctARCT	0.0155731	0.0032571	4.781	1.74e-06	***
UDC	0.8621519	0.2600240	3.316	0.000914	***

pctUDTC	-0.0214753	0.0064926	-3.308	0.000941	***
BTVT	1.0054706	0.1864406	5.393	6.93e-08	***
TCPS	-0.0366887	0.0146569	-2.503	0.012309	*
AVGQ	0.0012186	0.0008312	1.466	0.142651	
REC1	-0.5040089	0.3562859	-1.415	0.157180	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 3489.22 on 3947 degrees of freedom
 Residual deviance: 950.07 on 3922 degrees of freedom
 AIC: 1002.1

Number of Fisher Scoring iterations: 8

C.6 Execução da Estratégia 7

Call:

```
glm(formula = real ~ pctITAT + MEAC + pctMEAC + pctMEAT + MEAQ +
     MEVC + pctMEVC + MEVT + MEVQ + MDCV + pctMDCV + MIAT + MIVC +
     pctMIVT + MIVQ + ARCT + pctARCT + UDC + pctUDTC + BTVT + pctBTVT +
     TCPS + AVGQ, family = binomial(link = logit), data = HLdata)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-2.7601	-0.2580	-0.1323	-0.1090	3.3175

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-5.3053919	0.3960033	-13.397	< 2e-16 ***
pctITAT	0.0206363	0.0039966	5.163	2.42e-07 ***
MEAC	2.3350023	0.5429867	4.300	1.71e-05 ***
pctMEAC	-0.0163948	0.0100396	-1.633	0.102467

pctMEAT	0.0158463	0.0076767	2.064	0.038998	*
MEAQ	0.8578861	0.4397286	1.951	0.051064	.
MEVC	3.6941036	1.1085995	3.332	0.000862	***
pctMEVC	-0.0238923	0.0141183	-1.692	0.090591	.
MEVT	1.3339422	0.6970177	1.914	0.055648	.
MEVQ	1.7600770	0.6920166	2.543	0.010978	*
MDCV	0.7354519	0.3836244	1.917	0.055223	.
pctMDCV	0.0330603	0.0091615	3.609	0.000308	***
MIAT	2.8452437	0.3014888	9.437	< 2e-16	***
MIVC	1.5629779	0.6875017	2.273	0.023001	*
pctMIVT	0.0216417	0.0140566	1.540	0.123655	.
MIVQ	2.7726058	1.1743234	2.361	0.018225	*
ARCT	1.4632586	0.2731432	5.357	8.46e-08	***
pctARCT	0.0085110	0.0035420	2.403	0.016268	*
UDTC	0.6282527	0.2806635	2.238	0.025191	*
pctUDTC	-0.0141152	0.0070657	-1.998	0.045749	*
BTVT	0.8714235	0.2562055	3.401	0.000671	***
pctBTVT	0.0060405	0.0038735	1.559	0.118891	.
TCPS	-0.0326230	0.0153029	-2.132	0.033022	*
AVGQ	0.0014056	0.0009481	1.483	0.138168	.

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 2618.84 on 3031 degrees of freedom

Residual deviance: 845.55 on 3008 degrees of freedom

AIC: 893.55

Number of Fisher Scoring iterations: 8

Apêndice D

Tabela de Mapeamento de Características

Algumas das características utilizadas nas Seções 6.1 e 6.2 foram publicadas [23, 24] com códigos/acrônimos em inglês. A Tabela D.1 faz a associação (*de-para*) entre os códigos das publicações dos artigos e o que foi utilizado neste trabalho.

Código em Português	Código em Inglês
MEAC	SWLB
MEVC	SWSB
MEAT	SWLT
MEAQ	SWLF
MEVQ	SWSF
MEVT	SWST
MIAC	SILB
MIVC	SISB
MIAT	SILT
MIAQ	SILF
MIVQ	SISF
MIVT	SIST
ARCT	QFB
BTVT	SVRT
ITAT	SITL
UDTC	UDTB
MDVC	SDBS

Tabela D.1: Correspondência entre Código de Características

Apêndice E

Comparação entre Contagem de Características e Regressão Logística

Como já dissemos na Seção 6.1.6, não julgamos que a abordagem de contagem de características, que foi utilizada para validar o processo de extração de características, seja um método robusto o suficiente para ordenação da lista de vendedores com o objetivo de identificar fraudadores. Entretanto, como publicamos um artigo [24] que comparava essa abordagem com o método de Regressão Logística, utilizado ao longo deste trabalho, julgamos ser necessário exibir e analisar uma comparação mínima entre as duas ordenações produzidas a partir dessas diferentes abordagens.

O gráfico da Figura E.1 mostra a comparação das medidas-F da abordagem de contagem

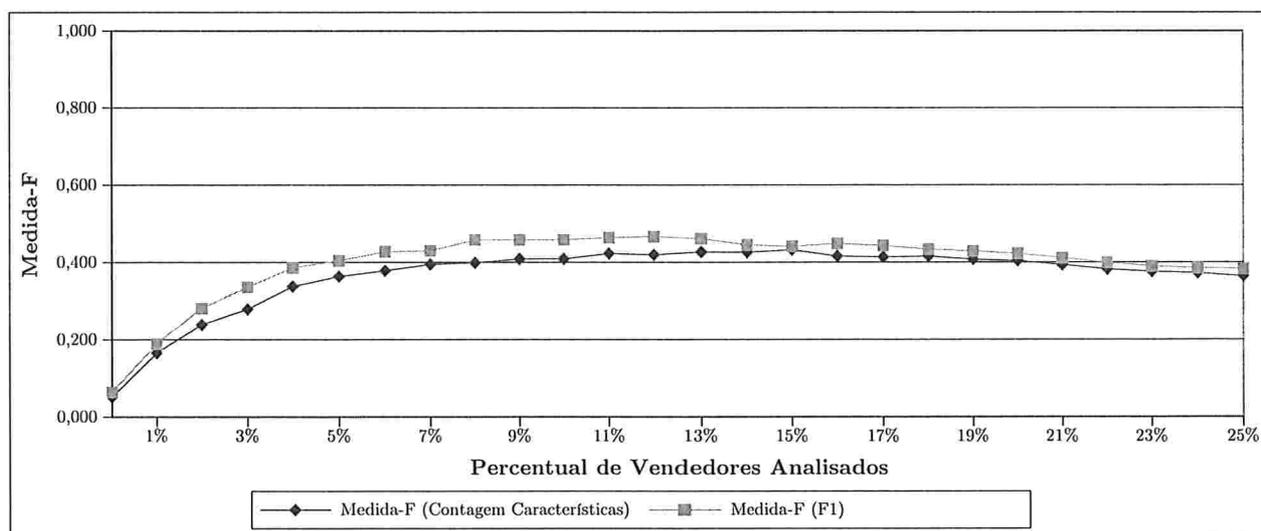


Figura E.1: Comparação de Medida-F entre Contagem de Características e Regressão Logística (Estratégia 1)

de características (FCC) e da primeira aplicação do método de Regressão Logística (F1), descrita na Estratégia 1 (Seção 6.2.1). Como se pode observar no gráfico e na Tabela E.1,

analisadas as mesmas porcentagens do topo das ordenações produzidas pelas duas abordagens, a medida-F para FCC é sempre inferior à medida-F para F1. Em relação à precisão

% Vendedores	FCC	F1	(F1-FCC)/FCC
1%	0,165	0,189	14,3%
2%	0,238	0,280	17,8%
3%	0,278	0,336	20,7%
4%	0,338	0,386	14,3%
5%	0,364	0,404	11,1%
6%	0,378	0,427	12,9%
7%	0,394	0,429	8,8%
8%	0,399	0,458	14,8%
9%	0,409	0,458	12,0%
10%	0,409	0,458	12,1%
11%	0,422	0,464	9,7%
12%	0,419	0,466	11,2%
13%	0,426	0,461	8,1%
14%	0,426	0,444	4,4%
15%	0,432	0,441	2,1%
16%	0,416	0,448	7,8%
17%	0,413	0,442	7,0%
18%	0,415	0,433	4,3%
19%	0,407	0,428	5,2%
20%	0,404	0,422	4,6%
21%	0,393	0,411	4,5%
22%	0,382	0,399	4,5%
23%	0,376	0,389	3,6%
24%	0,372	0,385	3,5%
25%	0,364	0,383	5,2%

Tabela E.1: Comparação de Medida-F entre Contagem de Características e Regressão Logística (Estratégia 1)

média, obtemos 38,9% na contagem de características e 45,1% na Estratégia 1, obtendo em um ganho de 16,1% nessa medida.

É importante lembrar que não utilizamos os dados revisados no gráfico da Figura E.1 e nem na Tabela E.1, mas a anotação original dos dados. Com a revisão das anotações seguindo o critério de contagem de características, para vendedores com ao menos 10 (dez) dessas características, a precisão média da ordenação por contagem de características é de 73,8%. Entretanto, mas a comparação com a precisão média da Estratégia 1 não seria adequada, pois a revisão foi tendenciosa para a primeira abordagem. De qualquer forma, a abordagem de ordenação por contagem de características contribuiu para a validação do

processo de extração dessas características, utilizadas ao longo de todos os experimentos deste trabalho.

Referências Bibliográficas

- [1] Mery Natali Silva Abreu, Arminda Lucia Siqueira, and Waleska Teixeira Caiaffa, *Regressão logística ordinal em estudos epidemiológicos*, Revista de Saúde Pública **43** (2009), 183 – 194 (pt). 25
- [2] H. Akaike, *A new look at the statistical model identification*, IEEE Transactions on Automatic Control **19** (1974), 716–723. 22, 26
- [3] Ricardo Baeza-Yates and Berthier Ribeiro-Neto, *Modern information retrieval*, 1st ed., Addison Wesley, 1999. 20, 22
- [4] Luca Becchetti, Carlos Castillo, Debora Donato, Stefano Leonardi, and Ricardo Baeza-Yates, *Using rank propagation and probabilistic counting for link-based spam detection*, In Proceedings of the Workshop on Web Mining and Web Usage Analysis (WebKDD, ACM Press, 2006. 33, 35
- [5] Richard J. Bolton, David J. Hand, and David J. H., *Statistical fraud detection: A review*, 2002. 12, 13, 32, 33
- [6] Sergey Brin and Lawrence Page, *The anatomy of a large-scale hypertextual web search engine*, Computer Networks and ISDN Systems, 1998, pp. 107–117. 13, 23, 30, 31, 32, 97, 98
- [7] IAB Interactive Advertising Bureau, *June 2008: Us retail e-commerce*, http://www.iab.net/insights_research/947883/1675/334589 - Acessado em 17/01/2010, Junho 2008. 1, 105
- [8] Duen H. Chau and Christos Faloutsos, *Fraud detection in electronic auction*, In European Web Mining Forum at ECML/PKDD, 2005. 34
- [9] Duen Horng Chau and Christos Faloutsos, *Fraud detection in electronic auction*, In European Web Mining Forum at ECML/PKDD, 2005. 33
- [10] André Luiz da Costa Carvalho, Paul Alexandru Chirita, Edleno Silva de Moura, Pável Calado, and Wolfgang Nejdl, *Site level noise removal for search engines*, WWW '06: Proceedings of the 15th international conference on World Wide Web (New York, NY, USA), ACM, 2006, pp. 73–82. 31
- [11] Chrysanthos Dellarocas, *Reputation mechanisms*, Handbook on Economics and Information Systems, Elsevier Publishing, 2006, p. 2006. 29

- [12] Alair Pereira do Lago and Imre Simon, *Tópicos em algoritmos sobre seqüências*, Publicações Matemáticas do IMPA. [IMPA Mathematical Publications], Instituto de Matemática Pura e Aplicada (IMPA), Rio de Janeiro, 2003, 24o Colóquio Brasileiro de Matemática. [24th Brazilian Mathematics Colloquium]. MR MR2028416 (2004m:68002) 98
- [13] Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern classification (2nd edition)*, 2 ed., Wiley-Interscience, November 2000. 13, 23, 24, 25
- [14] e-bit Informação, *Webshoppers*, 20a. Edição - <http://www.webshoppers.com.br/> - Acessado em 17/01/2010, 2009. 1, 105
- [15] Manoel Fernando Alonso Gadi, Xidi Wang, and Alair Pereira do Lago, *Comparison with parametric optimization in credit card fraud detection*, Seventh International Conference on Machine Learning and Applications, Proceedings of IEEE ICMLA'08 (Los Alamitos, CA, USA), IEEE Computer Society, December 2008, pp. 279–285. 13
- [16] Bezalel Gavish and Christopher L. Tucci, *Reducing internet auction fraud*, Commun. ACM **51** (2008), no. 5, 89–97. 16, 34
- [17] Dawn G. Gregg and Judy E. Scott, *The role of reputation systems in reducing on-line auction fraud*, Int. J. Electron. Commerce **10** (2006), no. 3, 95–120. 34
- [18] Zoltán Gyöngyi, Hector Garcia-Molina, and Jan Pedersen, *Combating web spam with trustrank*, VLDB '04: Proceedings of the Thirtieth international conference on Very large data bases, VLDB Endowment, 2004, pp. 576–587. 23, 31, 32, 98
- [19] David W. Hosmer and Stanley Lemeshow, *Applied logistic regression*, Wiley-Interscience Publication, September 2000, (Wiley Series in probability and statistics). 25, 26, 27
- [20] Daniel Houser and John Wooders, *Reputation in auctions: Theory, and evidence from ebay*, Journal of Economics and Management Strategy **15** (2006), no. 2, 353–369. 2, 10, 12
- [21] Thorsten Joachims, *Training linear svms in linear time*, KDD '06: Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining (New York, NY, USA), ACM, 2006, pp. 217–226. 95
- [22] Christopher D. Manning, Prabhakar Raghavan, and Hinrich Schütze, *Introduction to information retrieval*, 1 ed., Cambridge University Press, July 2008. 20, 21, 22, 23
- [23] Rafael Maranzato, Marden Neubert, Adriano Pereira, and Alair Pereira do Lago, *Feature extraction for fraud detection in electronic marketplaces*, LA-WEB 2009: 7th Latin American Web Congress (Mérida, México), IEEE Computer Society, 2009. 2, 4, 39, 43, 44, 48, 119
- [24] ———, *Fraud detection in reputation systems in e-markets using logistic regression*, SAC '10: Proceedings of the 2010 ACM symposium on Applied computing, ACM, 2010. 3, 4, 44, 48, 59, 119, 121

- [25] M. I. Melnik and J. Alm, *Does a seller's e-commerce reputation matter? evidence from ebay auctions*, Journal of Industrial Economics **50** (2002), no. 3, 337–349. 2, 12, 15, 30
- [26] Shashank Pandit, Duen Horng Chau, Samuel Wang, and Christos Faloutsos, *Netprobe: a fast and scalable system for fraud detection in online auction networks*, WWW '07: Proceedings of the 16th international conference on World Wide Web (New York, NY, USA), ACM, 2007, pp. 201–210. 30, 31, 32, 33, 35, 97, 98, 100, 102
- [27] Adriano M. Pereira, Diego Duarte, Wagner Meira Jr., Virgilio Almeida, and Paulo Góes, *Analyzing seller practices in a brazilian marketplace*, 18th International World Wide Web Conference, April 2009, pp. 1031–1041. 29, 30, 95
- [28] P. Resnick, R. Zeckhauser, J. Swanson, and K. Lockwood, *The value of reputation on ebay: A controlled experiment*, 2003. 2
- [29] Paul Resnick, Ko Kuwabara, Richard Zeckhauser, and Eric Friedman, *Reputation systems*, Communications of the ACM **43** (2000), no. 12, 45–48. 11, 14, 15, 29
- [30] Jonathan S. Yedidia, William T. Freeman, and Yair Weiss, *Understanding belief propagation and its generalizations*, (2003), 239–269. 100
- [31] Christopher J. W. Zorn, *Generalized estimating equation models for correlated data: A review with applications*, American Journal of Political Science **45** (2001), no. 2, 470–490. 95