

Universidade Presbiteriana Mackenzie
Centro de Ciências Sociais Aplicadas
Programa de Pós-Graduação em Administração de Empresas

Simulação de Monte Carlo para Mensuração do Risco
Operacional: Aplicação do Modelo LDA

Arthur Monteiro Gabbay

São Paulo

2010

Arthur Monteiro Gabbay

**Simulação de Monte Carlo para Mensuração do Risco Operacional:
Aplicação do Modelo LDA**

**Dissertação apresentada ao Programa de
Pós-graduação em Administração de
Empresas da Universidade Presbiteriana
Mackenzie para a obtenção do título de
Mestre em Administração de Empresas**

Orientador: Prof. Dr. Herbert Kimura

SÃO PAULO-SP

2010

G112s Gabbay, Arthur Monteiro.

Simulação de Monte Carlo para mensuração do risco operacional:
aplicação do modelo LDA / Arthur Monteiro Gabbay - 2010.

71f. : il. ; 30 cm + 1 CD-ROM

Dissertação (Mestrado em Administração de Empresas) –
Universidade Presbiteriana Mackenzie, São Paulo, 2010.

Bibliografia: f. 64-67.

1. Risco operacional. 2. Loss Distribution Approach. 3. Mercado
financeiro global. I. Título.

CDD 363.11

Reitor da Universidade Presbiteriana Mackenzie

Professor Dr. Manassés Claudino Fonteles

Decano de Pesquisa e Pós-Graduação

Professora Dra. Sandra Maria Dotto Stump

Coordenador de Pós-Graduação

Professor Dr. Marcos Rizolli

Coordenadora do Programa de Pós-Graduação em Administração de Empresas

Professora Dra. Darcy Mitiko Mori Hanashiro

Dedico esta conquista aos meus pais, que me ensinaram a lutar por meus objetivos.

Agradeço,

Aos meus pais, que enaltecem minhas virtudes, mas acima de tudo reconhecem minhas limitações e me orientam diante das mais importantes decisões.

Ao Prof. Dr. Herbert Kimura, pela orientação, apoio e dedicação. Deixo registrada minha enorme admiração pelo profissionalismo e pela afetividade com que conduz o processo de aprendizado de quem compartilha do seu convívio.

À minha irmã, pelo exemplo.

À minha namorada, pelo apoio.

Ao meu irmão, amigos e familiares pela segurança de sempre poder contar com todos.

SUMÁRIO

1. INTRODUÇÃO	11
1.1. Descrição da Pesquisa	11
1.2. Objetivos da Pesquisa.....	12
2. REFERENCIAL TEÓRICO	14
2.1. O Risco Operacional.....	14
2.2. A Importância do Risco Operacional	17
2.3. A Mensuração do Risco Operacional	19
2.3.1. Metodologias de Mensuração do Risco Operacional.....	19
2.3.1.1. Abordagem do Indicador Básico.....	20
2.3.1.2. Abordagem Padronizada	20
2.3.1.3. Abordagem de Mensuração Avançada (AMA)	21
2.3.1.3.1. Modelo de Mensuração Interna	22
2.3.1.3.2. Abordagem Scorecard.....	23
2.3.1.3.3. Abordagem Distribuição de Perdas (Loss Distribution Approach, LDA)	23
2.3.2. O Modelo LDA (Loss Distribution Approach)	23
2.3.2.1. O Modelo de Crámér-Lundberg	24
2.3.2.2. Definições Básicas	26
2.3.2.3. Estimação da Severidade	27
2.3.2.4. Estimação da Frequência.....	28
2.3.2.5. Distribuição de Perda Agregada	28
2.3.2.6. Requerimento de Capital	29
2.3.3. Valor em Risco (value-at-risk, VaR).....	31
2.3.4. A Correlação entre Perdas e os Valores Extremos.....	31
2.3.5. Estudos e Testes Empíricos sobre o LDA	32
2.3.6. Simulação de Monte Carlo.....	33
2.3.6.1. Simulação	34
2.3.6.2. O Método de Simulação de Monte Carlo	35
2.3.6.3. Aplicações do Método de Monte Carlo em Estudos Científicos.....	37
2.3.6.4. Aplicações do Método de Monte Carlo em Finanças	37
2.3.6.5. Aplicações do Método de Monte Carlo em Risco Operacional	38
2.3.7. Geração de Variáveis Aleatórias	38
3. PROCEDIMENTOS METODOLÓGICOS	39
3.1. Origem dos Dados.....	39
3.2. Descrição e Ajustes dos Dados.....	39

3.3.	Freqüência das Perdas	39
3.4.	Severidade das Perdas	40
3.5.	Simulações	40
3.5.1.	Simulação de Monte Carlo	40
3.5.1.1.	Parâmetros para Simulação de Monte Carlo	41
3.5.1.2.	Simulação de Monte Carlo: Freqüência	41
3.5.1.3.	Simulação de Monte Carlo: Severidade	42
3.5.1.4.	Simulação de Monte Carlo: Perdas Agregadas e VaR	42
3.5.1.5.	Simulação de Monte Carlo: Resultados	43
4.	ANÁLISES DE RESULTADOS	45
4.1.	Origem dos Dados	45
4.2.	Descrição dos Dados	45
4.3.	Base de Dados Original: Primeiros Ajustes	46
4.4.	Freqüência das Perdas	49
4.5.	Severidade das Perdas	49
4.6.	Simulações	51
4.6.1.	Simulação de Monte Carlo	52
4.6.2.	Programa de Simulação	52
4.6.3.	Parâmetros para Simulação de Monte Carlo	54
4.6.4.	Simulação de Monte Carlo: Freqüência	55
4.6.5.	Simulação de Monte Carlo: Severidade	55
4.6.6.	Simulação de Monte Carlo: Perdas Agregadas e VaR	56
4.6.7.	Simulação de Monte Carlo: Resultados	57
5.	CONSIDERAÇÕES FINAIS	62
6.	REFERÊNCIAS	64
	APÊNDICE	68

LISTA DE TABELAS

Tabela 1: Fatores beta associados às linhas de negócio.....	21
Tabela 2: Dados Originais de Perdas.....	46
Tabela 3: Dados de Perdas após Ajuste 1.....	47
Tabela 4: Dados de Perdas após Ajuste 2.....	48
Tabela 5: Segmentação dos Dados de Perdas por Setor.....	48
Tabela 6: Análise da Frequência de Perdas.....	49
Tabela 7: Análise da Severidade de Perdas.....	49
Tabela 8: As 10 Maiores Perdas da Base de Dados.....	50
Tabela 9: VaR da Base de Dados.....	50
Tabela 10: Parâmetros da Frequência (Quinzenal)	54
Tabela 11: Parâmetros da Severidade.....	54
Tabela 12: Simulações de VaR a partir Base de Dados Ajustada de 1.687 eventos.....	57
Tabela 13: Parâmetros da Frequência (Quinzenal).....	58
Tabela 14: Parâmetros da Severidade.....	58
Tabela 15: Simulações de VaR.....	58
Tabela 16: Dispersão média (VaR simulado (n) – VaR histórico).	60

LISTA DE FIGURAS

Figura 1 – Modelo de agregação da severidade e da frequência.....	29
Figura 2 – Histograma das Perdas da Base de Dados Ajustada (1.687 eventos).....	51
Figura 3 – Interface de Definição dos Parâmetros.....	53
Figura 4 – Interface de Simulação dos Cenários.....	53
Figura 5 – Histograma das Perdas para Poisson e Gama.....	59
Figura 6 – Histograma das Perdas para Binomial Negativa e Gama.....	60

RESUMO

O risco operacional é considerado por muitos autores uma variável determinante para a manutenção do equilíbrio do mercado financeiro global. O objetivo desta dissertação é estudar o desenvolvimento de um modelo de Abordagem de Mensuração Avançada (AMA), mais especificamente a *Loss Distribution Approach* (LDA), sobre um banco de dados reais de perdas operacionais. Mais especificamente este estudo promove uma análise sobre os resultados e sobre eventuais limitações relacionadas à aplicação do modelo. Para realização destes objetivos, abordam-se as definições do risco operacional, simulação de Monte Carlo e *value-at-risk* (VaR), haja vista que estes são conceitos cruciais para a aplicação do LDA.

Palavras-chaves: Risco Operacional, *Loss Distribution Approach*, Monte Carlo, VaR

ABSTRACT

Many authors consider Operational Risk as a key variable for maintaining the balance of the global financial market. The objective of this dissertation is to study the development of a Advanced Measurement Approach (AMA), specifically the Loss Distribution Approach (LDA) on a database of actual operational losses. Being more specifically, this study promotes an analysis about the results and possible limitations related to the implementation of the model. To achieve these goals, it is needed to discuss the definitions of Operational Risk, Monte Carlo Simulation and value-at-risk (VaR), considering that these concepts are crucial to the implementation of the LDA.

Key-words: Operational Risk, Loss Distribution Approach, Monte Carlo, VaR

1. INTRODUÇÃO

1.1. Descrição da Pesquisa

A recente crise financeira que atinge o mundo desde o final de 2008 pode ser atribuída a diversos fatores, desde a crise imobiliária americana até questões de ineficiência de controle no segmento financeiro.

Diante deste cenário, nota-se uma movimentação intensa dos governos ao redor do mundo, que visa regulamentar a atividade financeira de bancos, seguradoras e outras instituições, no sentido de incrementar controles que possam gerar menor suscetibilidade do mercado financeiro a novas grandes crises econômicas.

Todavia, a preocupação com o incremento dos controles sobre a atuação das instituições financeiras tem sido enfatizada bem antes da crise iniciada em 2008.

A história do mercado financeiro aponta inúmeros casos de perdas ligadas a riscos que não necessariamente vêm sendo mensurados precisamente pelos modelos quantitativos tradicionais, modelos estes historicamente mais direcionados a riscos de crédito e a riscos de mercado.

Casos clássicos de perdas em instituições financeiras como Barings em 1995 e Société Générale em 2008, trouxeram ao mercado o conceito de risco operacional, já abordado de forma mais consubstanciada em normas recentes de regulamentação como Basiléia II, voltada ao segmento de bancos, e Solvência II, voltado ao segmento de seguradoras.

Conforme Basiléia II, por exemplo, o risco operacional envolve o risco de perda resultante de processos internos, pessoas e sistemas inadequados ou deficientes bem como de eventos externos.

Para a abordagem destes riscos, alguns modelos foram sugeridos na Basiléia II e na Solvência II, visando à alocação de capital para fazer frente a eventuais perdas. Estes modelos seguem diversas metodologias, desde simples indexadores sobre a receita bruta média anual, até modelos de *value-at-risk* (VaR) para distribuições de perdas.

Em particular, uma das abordagens avançadas para risco operacional, o LDA (*loss distribution approach* ou abordagem de distribuição de perdas), busca a definição de distribuições conceituais para as distribuições reais de frequência e severidade das perdas para, posteriormente, obter-se a distribuição das perdas agregadas e o conseqüente VaR com determinado grau de confiança.

Considerando-se que a metodologia LDA parece conciliar a sofisticação de um modelo mais robusto de mensuração do risco operacional com a boa aplicabilidade em um banco de dados de estruturação relativamente simples, este estudo pretende utilizar a abordagem LDA em uma base de dados de risco operacional em empresas.

Nesse contexto, de forma sintética, busca-se investigar um modelo de mensuração de risco operacional (LDA) através das seguintes etapas:

- i. Obtenção de banco de dados de perdas atribuídas ao risco operacional, análise e eventual adequação deste para as necessidades do modelo proposto;
- ii. Análise probabilística das distribuições de frequência e severidade das perdas relacionadas no banco de dados;
- iii. Construção de algoritmos para simulação de frequência e severidade de perdas, bem como geração de distribuição agregada das perdas;
- iv. Análise dos resultados: contribuições e limitações do modelo.

Adicionalmente, com uma medida de VaR, ou seja, de perda máxima potencial em um determinado horizonte de tempo e com determinado grau de confiança, pode-se subsidiar planejamentos e estratégias, bem como atender aos requisitos regulatórios que impõem montante de capital mínimo para que a empresa faça frente a eventuais perdas operacionais.

A utilização da simulação como parte importante deste estudo se reforça na assertiva de Ehrentreich (2008), que aponta a simulação como uma metodologia alternativa à dedução e indução. Neste sentido, o autor se refere à simulação como uma terceira metodologia para realização de pesquisas, que apesar de não pode ser utilizada para provar teoremas, costuma ser útil para incrementar o entendimento sobre fenômenos complexos que estejam fora do alcance de teorias dedutivas.

1.2. Objetivos da Pesquisa

A definição dos problemas, objetivos e hipóteses do trabalho se reforça na escassa literatura nacional sobre o tema, ao recente desenvolvimento dos conceitos no âmbito internacional (as regulamentações mais relevantes datam de meados de 1990), bem como na necessidade de implementação dos modelos face ao desenvolvimento das exigências dos órgãos reguladores sobre um capital de solvência que faça frente aos riscos operacionais para diversos segmentos da economia.

Neste sentido, a estruturação de um modelo sobre determinado banco de dados visa incrementar a relevância do estudo proposto, admitindo-se que o teste empírico do LDA para qualquer banco de dados já corresponde a uma contribuição pouco encontrada no âmbito nacional.

Esta dissertação tem por objetivo principal:

- i. O desenvolvimento de um modelo de Abordagem de Mensuração Avançada (AMA), mais especificamente a Loss Distribution Approach (LDA), desde o tratamento de um banco de dados bruto, passando pela análise probabilística dos dados, a simulação de Monte Carlo para perdas e a análise dos resultados.

Como objetivos específicos, esta pesquisa visa:

- i. Discutir as definições de risco operacional e apresentação dos modelos de Abordagem de Mensuração Avançada;
- ii. Desenvolver um modelo LDA através da simulação de Monte Carlo, e;
- iii. Realizar análise dos resultados da aplicação prática do LDA.

Assim, o problema principal deste trabalho passa pelo fato de que grandes perdas econômicas em instituições globalizadas têm sido geradas por ações relacionadas aos conceitos de riscos operacionais, gerando inclusive um risco sistêmico. A este fato, adiciona-se que os modelos de mensuração de riscos operacionais estão em estágio incipiente, tanto no desenvolvimento de teorias quanto na regulamentação e aplicação prática.

Em resumo, entende-se que o tema deste estudo tem relevância em função de pelo menos dois fatores:

- i. O elevado impacto financeiro de perdas relacionadas aos riscos operacionais;
- ii. O estágio incipiente do desenvolvimento, regulamentação e aplicação prática de teorias sobre a abordagem LDA.

2. REFERENCIAL TEÓRICO

O risco tem sido alvo de diversas pesquisas acadêmicas ao longo do tempo, o que vem incrementando a solidez dos modelos de mensuração e gestão com base no reforço contínuo do embasamento teórico sobre o assunto.

Segundo Crouhy, Galai e Mark (2004), as bases da análise moderna de risco estão contidas no trabalho de Markowitz (1952) relativo aos princípios de seleção de carteira, onde foi demonstrado que um investidor que se comporta de forma consistente com a maximização da utilidade esperada de Von Neuman-Morgenstern deve analisar carteiras alternativas com base em sua média e na variância de suas taxas de retorno.

Porém, além dos riscos financeiros ligados à volatilidade de carteiras de investimentos, outros tantos tipos de risco têm sido identificados por pesquisadores.

Crouhy, Galai e Mark (2004) apontam vários nomes para descrever os diferentes tipos de riscos: risco de negócios, risco financeiro, risco de mercado, risco de liquidez, risco de inadimplência, risco sistêmico, risco específico, risco residual, risco de crédito, risco de contraparte, risco operacional, risco de compensação, risco país, risco de carteira, risco sistêmico, risco de reputação, entre outros.

Diante de tantos nomes e tipos de risco, os diferentes mercados e respectivos reguladores buscam padronizar conceitos e definições para que os riscos possam ser mensurados de forma mais uniforme entre diferentes empresas.

2.1. O Risco Operacional

No que compreende a definição do que é o risco operacional, a British Bankers' Association (BBA) definiu um conceito para riscos operacionais através de um artigo de setembro de 2001, chamado Working Paper on the Regulatory Treatment of Operational Risk, que aponta que risco operacional corresponde ao risco de perda resultante de processos internos falhos ou inadequados, pessoas e sistemas, ou eventos externos.

O Basel Committee on Banking Supervision (Comitê de Basiléia) especificou ainda que a definição do BBA deva incluir o conceito de risco legal, mas excluir riscos sistêmicos, estratégicos e de reputação, o que propõe uma definição de abordagem mínima para assuntos relacionados ao risco operacional.

Manning e Gurney (2005) acreditam que, para se precisar o que envolve o risco operacional, deve-se expandir a noção de perda na atividade operacional, ou seja, perdas deverão incluir danos diretos e indiretos.

Em contraponto com o conceito clássico do BBA e do Comitê de Basileia, os referidos autores crêem que “falhas em processos, sistemas ou pessoas” devem incluir eventos que envolvam danos a reputação ou riscos que envolvam estratégia, por exemplo.

A interpretação dos autores sobre risco operacional inclui: fraude interna e externa; segurança do trabalho e práticas dos empregados; práticas de clientes, produtos e do negócio; danos a ativos (físicos); interrupção dos negócios e falhas em sistemas, e; gestão da execução, da entrega e dos procedimentos.

A partir destas e de outras definições, o Parlamento Europeu, em Resolução legislativa de 22 de abril de 2009 (ou simplesmente Solvência II), na Seção 3 – Definições, Artigo 13º, item 27, definiu o risco operacional como o risco de perdas resultantes de procedimentos internos inadequados ou deficientes, do pessoal ou dos sistemas, ou ainda de acontecimentos externos (o Artigo 101º determina ainda a inclusão dos riscos jurídicos, mas exclusão dos resultantes de decisões estratégicas e os riscos de reputação).

A Resolução 3.380 do Banco Central do Brasil definiu risco operacional como:

“Possibilidade de ocorrência de perdas resultantes de falha, deficiência ou inadequação de processos internos, pessoas e sistemas, ou de eventos externos. A definição (...) inclui o risco legal associado à inadequação ou deficiência em contratos firmados pela instituição, bem como a sanções em razão de descumprimento de dispositivos legais e a indenizações por danos a terceiros decorrentes das atividades desenvolvidas pela instituição.”

Existem claras semelhanças entre as definições do Comitê de Basileia, do Solvência II e da Resolução 3.380 do Banco Central do Brasil. Deve-se notar que o risco legal tende a ser especialmente relevante no contexto brasileiro, o que pode ser ratificado pelo fato de que a Resolução 3.380 do BACEN reserva um parágrafo específico para descrever e definir o risco legal dentro do contexto de risco operacional.

Sinteticamente, Afambo (2006) aponta dois fatos importantes para que os estudos sobre o risco operacional se desenvolvessem até os presentes modelos avançados de mensuração quantitativa, fatos estes que envolvem tanto a complexidade recente gerada por fatores tecnológicos e de dinamismo do mercado, quanto a incidência crescente de perdas não-previstas nos monitoramentos clássicos de risco de mercado e de crédito.

O primeiro fato se define mais precisamente pela combinação do aumento da complexidade da tecnologia empregado no setor financeiro e a baixa regulamentação e intensa globalização que tornaram as práticas bancárias mais sofisticadas e desafiadoras. Diante disto, a indústria financeira passou a apresentar novos riscos multifacetados, distintos dos conceitos clássicos de risco de mercado ou de crédito.

Os desafios deste cenário passaram a envolver segurança de sistemas e informações, risco de fraudes, risco de sistemas em virtude da intensa automatização de processos, além de riscos que envolvem a intensa terceirização nas atividades operacionais do setor. Deve-se levar em conta ainda a dinâmica intensa das técnicas de mitigação de risco que envolve derivativos, swaps e securitização de ativos (BCBS, 2003).

O segundo fato se justifica diante da indústria financeira apresentar aumento da insolvência e de grandes perdas decorrentes de “outros riscos”, ou seja, de riscos que fugiam do conceito clássico de risco de mercado ou de crédito. Conforme o BCBS (2003), houve em 1998 mais de US\$ 20 bilhões em perdas decorrentes de “outros riscos” nas grandes empresas financeiras mundiais.

Estes dois fatos importantes fizeram que executivos dos grandes conglomerados econômicos dispensassem mais atenção a “outros riscos”, em detrimento das práticas até então mais comuns em controlar de forma mais aguda os riscos mais clássicos, como risco de mercado e risco de crédito (BCBS, 2003).

Diante da intensa diversidade de conceitos e de delimitações para o risco operacional, e como forma de padronizar os eventos de perdas atribuídos a este risco, o Comitê de Basileia, conforme sua terceira revisão de abril de 2003 (BCBS, 2003 – Anexos), em seu Anexo 7, descreve as classificações dos tipos de eventos de perda, conforme segue:

1. Fraude Interna;
2. Fraude Externa;
3. Práticas dos Empregados e Segurança do Trabalho;
4. Clientes, Produtos e Práticas de Negócios;
5. Danos a Ativos Físicos;
6. Interrupção dos Negócios e Falhas de Sistemas;
7. Execução, Entrega e Gestão dos Processos.

A estes 7 itens, deve-se somar a descrição contida no Anexo 6 do mesmo documento do Comitê de Basileia, que descreve o mapa de linhas de negócios, conforme segue:

1. Finanças Corporativas;

2. Negociações e Vendas;
3. Atividades Bancárias de Varejo;
4. Atividades Bancárias Comerciais;
5. Pagamentos e Liquidações;
6. Serviços de Agência;
7. Gestão de Ativos;
8. Corretagens.

Estas informações das linhas de negócios e tipos de eventos de perdas, apesar de originadas pelo Comitê de Basileia (direcionado especificamente ao setor bancário), são estruturais para os principais modelos de Abordagem Padronizada e Abordagem de Mensuração Avançada disponíveis no meio acadêmico e no mercado financeiro, podendo, por conseguinte, servir de base estudo do risco operacional para diversas áreas inclusive não-financeiras.

2.2. A Importância do Risco Operacional

Segundo Gourier, Farkas e Abbate (2009), o Société Générale, um dos maiores bancos da Europa, sofreu uma grave crise em 2008, quando o seu funcionário Jérôme Kerviel executou uma série de operações não autorizadas que custaram à companhia mais de € 4,9 bilhões, a maior perda gerada por um único funcionário da história da indústria financeira.

O banco Barings, em 1995, sofreu um colapso após seu funcionário Nick Leeson gerar perdas de US\$ 1,4 bilhão em especulações sobre contratos futuros. Deve-se ressaltar que existiram indícios de que Leeson manteve posições perdedoras sem conhecimento da administração do Barings. Muitos eventos similares têm atormentado continuamente os mercados financeiros mundiais ao longo da história. Neil, Häger e Andersen (2009) citam ainda os casos do banco Daiwa em 1995 e do banco Allied Irish em 2002.

Esses casos exemplificam dimensões de risco operacional ligado a problemas de conduta pessoal que exploram deficiências em controle. No entanto, o risco operacional envolve muitas outras dimensões como, por exemplo, falhas em sistemas, erros humanos, acidentes, problemas legais, entre outros (MOOSA, 2007).

Face ao potencial impacto de eventos de risco operacional, Tripp et al. (2004) sugere ser necessária uma nova abordagem mais profissional e científica para negócios e gestão de riscos.

Neste sentido, Afambo (2006) aponta que, desde meados de 1990, a complexidade recente gerada por fatores tecnológicos, o dinamismo do mercado, bem como a incidência crescente de perdas não-previstas nos monitoramentos clássicos de risco de mercado e de crédito demandaram dos grandes conglomerados econômicos um esforço maior para a gestão de “outros riscos”, uma vez que as práticas até então mais comuns, que buscavam controlar de forma mais aguda os riscos mais clássicos, como risco de mercado e risco de crédito, já não se faziam mais suficientes para evitar grandes perdas imprevistas.

Cruz (2002) considera que a falência do Barings trouxe pela primeira vez ao público o termo risco operacional, passando então a gerar interesse de pesquisadores e gestores do mercado financeiro, haja vista que este risco passaria a se relacionar diretamente com eventuais perdas financeiras consideráveis não relacionadas aos riscos de crédito e de mercado.

Cruz (2002) aponta ainda que alguns estudos, de forma geral e simplista, sugerem uma divisão dos riscos em empresas financeiras de 50% para risco de crédito, 15% para riscos de mercado e liquidez e 35% para risco operacional. Certamente não devemos julgar a precisão destes índices, mas sim a importância da gestão do risco operacional para atividades financeiras.

Adicionalmente, nota-se que os órgãos regulatórios passaram a exercer maior controle diante do assunto, o que certamente passa a demandar maior adequação das empresas quanto a eventuais normas que busquem incrementar o controle dos riscos operacionais, tais como Sarbanes Oxley, Basiléia II, Solvência II, entre outras.

Diante do desafio imposto aos órgãos regulatórios, em especial após os dilemas enfrentados durante a recente crise financeira mundial iniciada em 2008, Neil, Häger e Andersen (2009) sugerem que a chave para a regulação nas empresas financeiras passa pela necessidade das mesmas em modelar seus riscos operacionais, especialmente em termos da variedade de tipos de eventos, para que se possa existir uma gestão efetiva do risco e uma alocação apropriada de capital para fazer frente a estes mesmos riscos.

Para medir os riscos operacionais e se criar regras de proteção para as empresas e para a sociedade, como alocação de reservas de capital para estas despesas, é necessário que se desenvolvam técnicas precisas de mensuração sobre bases de dados confiáveis.

Um dos problemas mais comuns em mensurar risco operacional passa pela dificuldade de isolar o elemento ‘perda operacional’ de perdas em outras categorias, ou seja, existe uma correlação entre as distintas perdas e a mensuração deste nível de correlação costuma ser um grande desafio quando se estuda os riscos operacionais.

Falhas ligadas aos riscos operacionais em geral resultam em outros tipos de perdas que não são ‘operacionais’ no primeiro plano, como por exemplo, perdas atribuídas aos riscos de mercado, geradas por um erro de sistema ou incremento do risco de crédito em virtude de controles inadequados.

Em resumo, embora seja possível notar progressos importantes no desenvolvimento de pesquisas sobre o risco operacional nos últimos anos, tanto a prática quanto a ciência ainda procuram identificar o método mais apropriado para controlar e administrar tais riscos.

Outros riscos já avançaram mais significativamente do que o risco operacional no que diz respeito ao desenvolvimento de modelos de mensuração e gestão, como os modelos de gestão de riscos de mercado e de riscos de crédito. A incipiência das ferramentas de administração de riscos operacionais envolve não somente a modelagem quantitativa como também os mecanismos qualitativos.

Sundmacher e Ford (2004) apontam a ironia no fato de modelos para gestão do risco operacional ainda serem pouco desenvolvidos e disseminados, uma vez que, segundo os autores, a maior parte das perdas no segmento bancário ao longo do tempo decorre de eventos operacionais.

2.3. A Mensuração do Risco Operacional

Os modelos de mensuração de risco operacional ainda se estruturam amplamente em estudos científicos voltados às características dos mercados bancário e de seguros, haja vista que os órgãos reguladores deste mercado vêm incrementando as exigências voltadas à prevenção de perdas sistêmicas relacionadas ao risco operacional das instituições.

Certamente os conceitos e modelos desenvolvidos para cada mercado específico podem ser reformulados para atender a demanda de outros tipos de instituições.

Desta forma, os itens seguintes apresentam os principais modelos de mensuração do risco operacional.

2.3.1. Metodologias de Mensuração do Risco Operacional

O setor bancário, diante de alguns eventos de perdas operacionais importantes e do risco sistêmico que grandes perdas podem representar, considerando ainda a intensa regulamentação do setor, buscou reunir técnicas científicas que promovam a mensuração do risco operacional dos bancos.

Diante disto, o Comitê de Basileia estabelece três modelos de mensuração deste nível de exposição: abordagem do indicador básico (*Basic Indicator Approach* – BIA), abordagem padronizada (*Standardised Approach* – TSA) e abordagem de mensuração avançada (*Advanced Measurement Approach* – AMA).

2.3.1.1. Abordagem do Indicador Básico

O modelo mais simples utilizado para alocação do capital relacionado ao risco operacional denomina-se Abordagem do Indicador Básico (*Basic Indicator Approach* – BIA). Além de simples, o BIA apresenta a peculiaridade de não apresentar dados de risco operacional.

A obtenção da exigência de capital próprio para esta abordagem é realizada através da utilização de um índice (taxa) sobre o resultado bruto de toda a instituição. Ou seja, a definição do requisito de capital devido ao risco operacional para o BIA corresponde a aplicação de um fator, denominado alfa (α), sobre o resultado bruto médio em um horizonte de tempo predeterminado.

Conforme aponta Cruz (2002), o carregamento de capital KBIA, conforme a abordagem do indicador básico, pode ser expresso como:

$$K_{BIA} = \alpha \times GI$$

Onde GI expressa a receita bruta média anual dos três anos anteriores e α o coeficiente determinado pelo Comitê da Basileia em 15%.

2.3.1.2. Abordagem Padronizada

A Abordagem Padronizada (*Standardised Approach* – TSA) é semelhante à Abordagem do Indicador Básico. A grande diferença está no fato de que as atividades bancárias passam a ser categorizadas em linhas de negócio, sendo que cada linha apresenta um fator beta de ajustes do cálculo do requisito de capital, conforme ilustrado na tabela a seguir:

Tabela 1: Fatores beta associados às linhas de negócio

J	Linhas de Negócios	Beta (β_j)
1	Finanças corporativas	18,0%
2	Negociação e vendas	18,0%
3	Pagamentos e liquidações	18,0%
4	Comercial	15,0%
5	Serviços de agente financeiro	15,0%
6	Varejo	12,0%
7	Administração de ativos	12,0%
8	Corretagem de varejo	12,0%

Fonte: Cruz (2002)

Segundo Afambo (2006), a abordagem padronizada determina que o carregamento de capital seja igual a:

$$K_{SA} = \sum_{i=1}^8 \beta(i) GI(i)$$

Onde $GI(i)$ expressa a receita bruta média anual dos três anos anteriores para o negócio e $\beta(i) \in [12\%, 18\%]$, $i = 1, 2, \dots, 8$ conforme determinado pelo Comitê de Basiléia e expresso na tabela 1 acima.

2.3.1.3. Abordagem de Mensuração Avançada (AMA)

As Abordagens de Mensuração Avançadas (*Advanced Measurement Approaches - AMA*) dizem respeito a metodologias ancoradas em critérios qualitativos e quantitativos, que possibilitam o cálculo de requisito de capital em consonância com o risco operacional, medido a partir de certos eventos de risco.

Cruz (2002) define a AMA como fruto da permissão de que fossem utilizados modelos de mensuração interna para risco operacional em relação ao capital regulatório, permissão esta aprovada pelo Comitê de Basiléia a partir de setembro de 2001.

Permitindo tais modelos, o Comitê de Basileia reconheceu a existência de uma intensa diversidade de abordagens para quantificar os riscos operacionais, incentivando assim as áreas de pesquisa e desenvolvimento das empresas financeiras.

Os processos que envolvem a identificação, agregação e monitoramento dos eventos de risco operacional, que são parte do importante do desenvolvimento dos modelos avançados relacionados à AMA, possibilitam conseqüentemente importantes ganhos de gestão para as empresas que buscam implementá-los, haja vista que quanto mais informações sobre a exposição a riscos operacionais, maior a capacidade de desenvolvimento de mecanismos de controle mais efetivos.

É importante ressaltar que, no documento final da Basileia II, não foram abordados modelos específicos para a AMA. Porém, em um documento preliminar (BIS, 2001), o Comitê da Basileia discute rapidamente três modelos que podem ser classificados como AMA: Abordagens de Mensuração Interna (IMA), Abordagens baseadas em *Scorecards* e Abordagens de Distribuição de Perdas (LDA).

2.3.1.3.1. Modelo de Mensuração Interna

Na Abordagem de Mensuração Interna (*Internal Measurement Approach* – IMA), os bancos deveriam estimar o capital devido ao risco operacional a partir de medidas de perdas esperadas. Apesar de serem aceitas diversas metodologias sofisticadas para calibrar as estimativas, podemos utilizar uma versão simplificada conforme descreve Afambo (2006):

$$K_{IMA} = \sum_{i=1}^8 \sum_{j=1}^7 \gamma(i,j) e(i,j)$$

Onde para cada linha de negócio e evento de perda tem-se (i,j) , para a perda esperada $e(i,j)$ e para fator de escala $\gamma(i,j)$.

Em resumo, o modelo acima se refere as oito linhas de negócios e sete eventos de perdas apresentadas neste trabalho (páginas 16 e 17). Desta forma, o produto da fórmula acima representa a soma das perdas esperadas de cada combinação de linha de negócio e evento de perda.

2.3.1.3.2. Abordagem Scorecard

Na Abordagem de Scorecard (*Scorecard Approach* – SCA), nota-se que os bancos estabelecem um nível inicial para o capital direcionado ao risco operacional, que é segregado por linha de negócio (ou para a empresa como um todo), seja através da utilização da Abordagem do Indicador Básico ou da Abordagem Padronizada. Valores para o nível de capital são ajustados ao longo do tempo, utilizando-se *scorecards* que buscam capturar o perfil de risco e o ambiente de controle das diversas linhas de negócio.

Afambo (2006) afirma que, para a abordagem *Scorecard*, o carregamento de capital é igual a:

$$K_{SCA} = \sum_{i=1}^B \sum_{j=1}^T GI(i,j) \times \omega(i,j) \times RS(i,j)$$

Onde para a linha de negócio e tipo de evento de perda (i,j), $GI(i,j)$ denota a receita média anual dos três anos anteriores, $\omega(i,j)$ como fator de escala e $RS(i,j)$ como medida do risco (*risk score*).

2.3.1.3.3. Abordagem Distribuição de Perdas (Loss Distribution Approach, LDA)

De forma simplificada, para a Abordagem de Distribuição de Perdas (*Loss Distribution Approach* – LDA), os bancos precisam estimar, para cada linha de negócio e tipo de risco, a distribuição de perdas devido a riscos operacionais, para um determinado horizonte de tempo.

Esta abordagem será tratada de forma mais aprofundada no item seguinte, haja vista que sua implementação em uma base de dados de empresas constitui uma das hipóteses mais importante a ser testada por este estudo.

2.3.2. O Modelo LDA (Loss Distribution Approach)

De acordo com Giacometti et al. (2008), LDA é a abordagem mais precisa do ponto de vista estatístico, uma vez que utiliza as perdas históricas – frequência e severidade – e é baseada no banco de dados interno de perdas de cada instituição.

Isto implica que o modelo pode capturar o grau de controle interno e prevenção de perdas de cada instituição, gerando diferentes níveis de exposição a risco a serem medidos pelo modelo, bem como diferentes montantes para carregamento de capital que faça frente às perdas esperadas e não-esperadas.

O principal fundamento do LDA, ainda segundo Giacometti et al. (2008), é o valor em risco (value-at-risk – VaR), que é mensurado no princípio de agregação das distribuições de frequência e severidade das perdas para um horizonte de tempo de um ano.

O LDA é, de longe, a mais proeminente entre as abordagens de mensuração avançada, apoiada em técnicas bem conhecidas das aplicações atuariais (Klugman et al (2004)).

2.3.2.1. O Modelo de Crámér-Lundberg

O modelo básico de risco de seguro, segundo Embrechts, Furrer e Kaufmann (2003), se remonta ao trabalho de Filip Lundberg, que em sua famosa tese de 1903 determinou a fundação da teoria atuarial de risco.

Lundberg concluiu que processos de Poisson atingiam o ponto central dos modelos de riscos não-vida. Através de uma transformação sutil do tempo (também chamada de tempo operacional) ele foi capaz de restringir sua análise para o processo homogêneo de Poisson.

Embrechts, Furrer e Kaufmann (2003) considera que esta descoberta é semelhante ao reconhecimento de Bachelier em 1900 de que o movimento Browniano era a chave para a construção dos modelos financeiros.

Posteriormente, Harald Cramér incorporou as idéias de Lundberg para a teoria emergente de processos estocásticos. Ao realizar isto, Cramér contribuiu consideravelmente para a estruturação tanto da matemática para seguros não-vida quanto para a teoria da probabilidade.

Embrechts, Furrer e Kaufmann (2003) apresenta então o modelo básico que derivou destas contribuições, descrito como modelo de Cramér-Lundberg, que apresenta a seguinte estrutura:

1. Os tamanhos das perdas $\{(X)_k\}_{k \in \mathbb{N}}$ são variáveis aleatórias positivas distribuídas de forma idêntica e independente e com média e variâncias finitas;
2. Os tempos das perdas ocorrem em momentos aleatórios $0 < T_1 < T_2 < \dots$;
3. A contagem das perdas, definida como um número no intervalo $[0, t]$, é expressa como $\{(N)_t\} = \sup\{n \geq 1: T_n \leq t\}, t \geq 0$, onde, por convenção, $\sup \emptyset = 0$;

4. Os tempos de chegada $Y_1 = T_1, Y_k = T_k - T_{k-1}, k = 2, 3, \dots$, são idêntica e independentemente distribuídos exponencialmente com média finita $EY_1 = \frac{1}{\lambda}$;
5. As seqüências $\{X_k\}$ e $\{Y_k\}$ são independentes entre si.

Embrechts, Furrer e Kaufmann (2003) adiciona a estrutura determinada acima que:

1. Uma consequência das definições acima é que $(N(t))$ é um processo homogêneo de Poisson com intensidade $\lambda > 0$, portanto

$$P(N(t) = k) = e^{-\lambda t} \frac{(\lambda t)^k}{k!}, \quad k = 0, 1, 2, \dots$$

2. O modelo renovado é uma generalização do modelo de Cramér-Lundberg que permite um processo renovado de contagem. Este último é mais geral que o processo de Poisson para perdas. O processo do montante total de perdas $(S(t))_{t \geq 0}$ passa a ser definido como

$$S(t) = \begin{cases} \sum_{i=1}^{N(t)} X_i, & N(t) > 0 \\ 0, & N(t) = 0 \end{cases}$$

Esta generalização do modelo de Cramér-Lundberg apresenta estrutura muito próxima do modelo de LDA, como pode ser visto através de Frachot, Roncalli e Salomon (2004), que expressa a metodologia usual do LDA através da perda agregada definida como a soma aleatória das perdas individuais, conforme a equação

$$L = \sum_{n=1}^N X_n = X_1 + \dots + X_N$$

Onde L é a perda agregada, N é o número anual de perdas (frequência dos eventos) e X_n e o montante das perdas (severidade dos eventos). Seguindo os conceitos clássicos do Comitê de Basiléia, conforme descrito nos itens anteriores deste estudo, pode-se afirmar que a perda agregada deverá se referir a perda incorrida a classe de risco, onde a classe designa uma célula entre os 7 tipos de riscos e as 8 linhas de negócios definidas anteriormente por Basiléia

II. Sendo assim, a perda agregada é resultante de duas fontes aleatórias distintas (frequência e severidade), onde ambas devem ser modeladas.

2.3.2.2. Definições Básicas

Segundo Frachot, Roncalli e Salomon (2004), a essência do modelo de LDA, conforme usado no risco operacional ou nas ciências atuariais, assume as seguintes premissas em cada classe de risco:

1. N e (X_1, X_2, \dots) são variáveis aleatórias independentes;
2. X_1, X_2, \dots são um conjunto de variáveis aleatórias independentes;
3. X_1, X_2, \dots seguem a mesma distribuição marginal.

A primeira premissa significa que a frequência e a severidade são duas fontes aleatórias independentes, apesar de que intuitivamente pode-se afirmar que possa existir alguma correlação entre o número de perdas e os montantes de cada perda.

Existem modelos que tratam da correlação, inclusive através de uma extensão do LDA, porém este estudo se limita a assumir a primeira premissa como verdadeira.

As premissas 2 e 3 descrevem que duas perdas diferentes, com a mesma classe homogênea, são idêntica e independentemente distribuídas.

Considerando que o processo de coleta de dados seja confiável e que a homogeneidade pode ser verdadeira, as premissas 2 e 3 podem ser consideradas válidas.

Conforme Frachot, Moudoulaud e Roncalli (2003), um modelo LDA que satisfaça as três premissas acima descritas constitui uma ferramenta sólida em especial pelas seguintes razões:

1. Em primeiro lugar o LDA padrão, descrito acima, tem sido o arcabouço teórico mais utilizado pela indústria de bancos e seguros;
2. Em seguida, modelos LDA padrão são factíveis de serem utilizados na prática real em bancos de dados, bem como têm sido implementados nos softwares disponíveis no mercado;
3. Por fim, qualquer extensão do LDA pode vir a gerar um mecanismo super sofisticado em relação ao padrão dos dados disponíveis para calibração.

Desta forma, o modelo LDA se inicia na determinação das distribuições discreta (frequência) e contínua (severidade) independentes.

2.3.2.3. Estimação da Severidade

Segundo Cruz (2002), a utilização de variáveis aleatórias permite a utilização de modelos matemáticos para tratar questões de probabilidade. Neste sentido, devem-se encontrar as distribuições teóricas que se adéquem mais apropriadamente aos dados empíricos que compõem a distribuição de severidade.

Cruz (2002) cita como distribuições de probabilidade populares para a severidade das perdas a distribuição normal, log-normal, normal invertida, exponencial, weibull, pareto, gamma, entre outras. As diversas distribuições de probabilidade descritas por Cruz (2002) tratam o tema de forma extensiva, porém somente algumas costumam encaixar de forma mais apropriada às distribuições empíricas de severidade de perdas.

Kuhn e Neu (2003), de forma mais objetivo, sugerem como escolhas mais populares para a distribuição de severidade a log-normal, gamma, beta e weibull.

Frachot, Moudoulaud e Roncalli (2003) apontam que a estimação da severidade torna-se mais difícil uma vez que técnicas padronizadas não podem ser utilizadas, haja vista que os bancos de dados costumam apresentar diversos vieses.

Simplicidade e precisão, neste caso, podem representar correlação negativa uma vez que, conforme Fontnouvelle et al. (2003), tratar os dados de forma simples pode gerar baixa precisão. Apesar de alguma complexidade passar a compor o tratamento das distribuições de severidade, é razoável que algumas premissas simplificadoras sejam assumidas, o que reduziria a precisão do conseqüente carregamento de capital para um nível aceitável.

Um exemplo importante de simplificação da determinação da distribuição de severidade diz respeito às diferentes fontes de distribuições de severidade para cada linha de negócio que deveriam ser re-escaloadas antes de serem unidas por um mesmo modelo, haja vista que, segundo Frachot, Moudoulaud e Roncalli (2003), os dados de severidade são fundamentalmente diferentes pela sua própria natureza.

Por outro lado, Fontnouvelle et al. (2003) demonstra empiricamente que vieses da necessidade de re-escalamento não são tão relevantes, haja vista que existem fortes evidências empíricas das similaridades entre diferentes fontes de dados.

2.3.2.4. Estimação da Frequência

A estimação da frequência segue premissas semelhantes à estimação da severidade. Para este caso também se deve encontrar uma distribuição teórica que melhor se adéque à distribuição obtida através do banco de dados.

Cruz (2002) cita como distribuições de probabilidade populares para a frequência das perdas a distribuição de Poisson, binomial negativa, binomial, hipergeométrica, geométrica, entre outras. As diversas distribuições de probabilidade descritas por Cruz (2002), conforme dito também sobre a estimação da severidade, tratam o tema de forma extensiva, porém somente algumas costumam encaixar de forma mais apropriada às distribuições empíricas de frequência de perdas.

Kuhn e Neu (2003) determinam que entre as escolhas mais populares para a distribuição de frequência destacam-se Poisson e binomial negativa.

Segundo Frachot, Moudoulaud e Roncalli (2003), se a escolha se direcionar pela simplicidade do modelo, deve-se optar por uma distribuição Poisson. Esta distribuição torna-se mais conveniente por ser muito usada na indústria de seguros na modelagem de problemas similares ao risco operacional, além de demandar um único parâmetro (λ).

2.3.2.5. Distribuição de Perda Agregada

Após a obtenção da distribuição de severidade e frequência, deve-se obter uma distribuição resultante para a obtenção da distribuição de perdas agregadas, para cada classe de risco. Em geral utiliza-se a simulação de Monte Carlo para determinação da distribuição de perdas agregadas, conforme representado no gráfico abaixo:

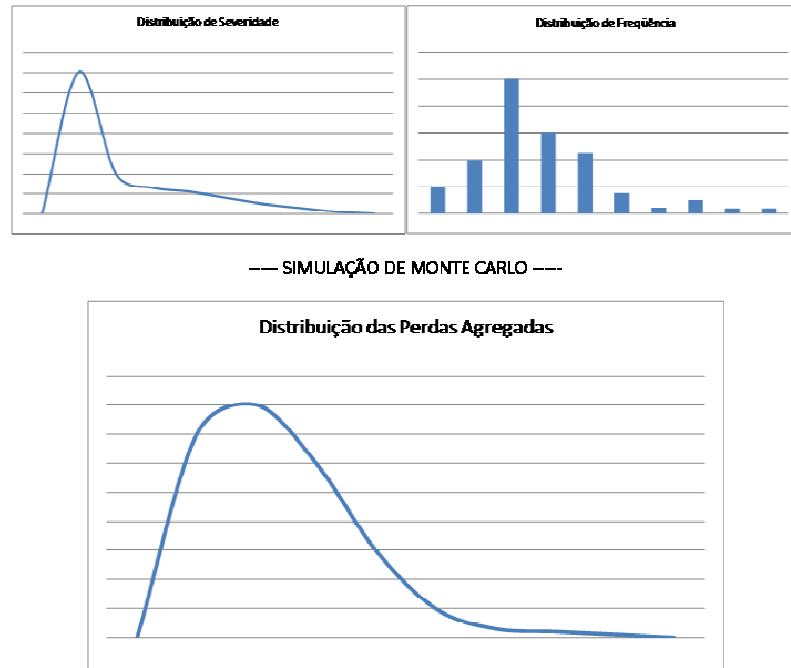


Figura 1 - Modelo de agregação da severidade e da frequência

Segundo McNeil et al. (2005), o método de Monte Carlo é uma denominação geral para qualquer abordagem de mensuração de risco que envolva a simulação de um modelo paramétrico explícito para mudanças em fatores de risco.

O método pode vir a ser condicionado ou não condicionado, dependendo se o modelo adotado apresentar uma série temporal dinâmica para mudanças nos fatores de risco ou se o mesmo apresentar uma distribuição estática.

2.3.2.6. Requerimento de Capital

A partir da distribuição de perdas agregadas, obtém-se o requerimento de capital regulatório para cobertura de perdas operacionais através do Valor em Risco (VaR).

Ao adotarmos, para efeito didático, as regras do Comitê de Basiléia, conforme sua terceira revisão de abril de 2003 (BCBS, 2003 – Anexos), em seu Anexo 7, temos para os eventos de perdas as seguintes classes:

1. Fraude Interna;
2. Fraude Externa;
3. Práticas dos Empregados e Segurança do Trabalho;
4. Clientes, Produtos e Práticas de Negócios;
5. Danos a Ativos Físicos;

6. Interrupção dos Negócios e Falhas de Sistemas;
7. Execução, Entrega e Gestão dos Processos.

O Anexo 6 do mesmo documento do Comitê de Basileia descreve o mapa de linhas de negócios, conforme segue:

1. Finanças Corporativas;
2. Negociações e Vendas;
3. Atividades Bancárias de Varejo;
4. Atividades Bancárias Comerciais;
5. Pagamentos e Liquidações;
6. Serviços de Agência;
7. Gestão de Ativos;
8. Corretagens.

Seguindo então os conceitos do Comitê de Basileia, a abordagem LDA pode ser utilizada através da soma dos VaR de cada linha de negócio n , em função dos m tipos de eventos de risco, conforme segue:

$$K_{LDA} = \sum_{i=1}^n \sum_{j=1}^m VaR_{ij}$$

Onde K_{LDA} é o requisito de capital de acordo com o LDA e VaR_{ij} é o Valor em Risco com determinado grau de confiança para um horizonte de tempo de um ano, referente ao risco do evento j e para cada linha de negócio i .

Nada impede que qualquer tipo de empresa, inclusive não-financeira, utilize classificações semelhantes para os eventos de perdas e as linhas de negócio, conforme descreve o Comitê de Basileia. O ganho mais relevante se dá por conta da análise do risco operacional alicerçada sobre um modelo quantitativo, baseado em parâmetros probabilísticos que possam permear estratégias e decisões no sentido de mitigar os efeitos de eventos de perdas.

2.3.3. Valor em Risco (value-at-risk, VaR)

Segundo Crouhy, Galai e Mark (2004), o valor em risco (value-at-risk, VaR) pode ser definido como a pior perda que poderia ser esperada em decorrência de se deter um título ou uma carteira por um dado período de tempo, dado um nível específico de probabilidade.

Para exemplificar, Crouhy, Galai e Mark (2004) afirmam que se uma posição tem VaR diário de \$ 10 milhões no nível de confiança 99 por cento, pode-se afirmar que as perdas diárias realizadas pela posição serão, em média, maiores do que \$ 10 milhões em apenas 1 dia em cada 100 dias de negociação.

Segundo Khindanova e Rachev (2000), as formas mais comuns de abordagens do VaR são geradas a partir da metodologia de variância-covariância, simulação histórica, simulação de Monte Carlo e testes de stress.

Segundo os mesmos autores, para o VaR obtido através da simulação de Monte Carlo, deve-se obedecer o seguinte algoritmo:

- i. Especificar os processos estocásticos e paramétricos para todas as variáveis (e eventuais correlações);
- ii. Simular os valores hipotéticos para todas as variáveis de interesse. Mudanças nos valores das variáveis são obtidas conforme as distribuições de probabilidade especificadas;
- iii. Obter o valor das variáveis (tamanho das perdas, por exemplo) para o período T;
- iv. Repetir os passos ii e iii tantas vezes quanto necessário para formar a distribuição do portfólio ou conjunto de perdas estimadas;
- v. Medir o valor do VaRT como o valor negativo do item localizado no $(1 - \text{intervalo de confiança})$ percentil da distribuição gerada.

2.3.4. A Correlação entre Perdas e os Valores Extremos

O modelo de LDA descrito até este ponto do estudo considera correlações perfeitas entre tipos de risco ou linhas de negócios.

Segundo Frachot, Roncalli e Salomon (2004), apesar de correlações perfeitas serem aceitas, a soma do carregamento de capital das diferentes linhas de negócios e tipos de eventos devem ser somados, gerando um carregamento de capital maior do que se fosse

considerado qualquer efeito de correlação entre as distintas linhas de negócios e tipos de perdas.

Considerando esta eventual correlação, alguns autores utilizam modelos LDA que consideram correlações não-perfeitas ou correlações nulas, seja através da determinação de indicadores de correlação ou através de modelagem utilizando cópulas.

Para este estudo, porém, adota-se a premissa de que a correlação entre os tipos de eventos e linhas de negócios seja perfeita.

Neste sentido, ainda sobre limitações deste estudo, sabe-se que alguns estudos recentes buscam analisar eventos de baixíssima frequência e alta severidade. Por exemplo, Chavez-Demoulin e Embrechts (2004) apresentaram técnicas avançadas de Teoria de Valores Extremos para modelagem de risco operacional, o que permite analisar altas severidades e seus impactos nas distribuições de perdas operacionais.

Neste estudo não se tratará eventos de baixa frequência e alta severidade com técnicas baseadas na Teoria de Valores Extremos, cabendo apontar este tipo de pesquisa como possibilidade de incrementos futuros a esta pesquisa, tal qual a hipótese de correlação entre eventos de perdas.

2.3.5. Estudos e Testes Empíricos sobre o LDA

Muitos autores têm tratado do LDA como uma abordagem importante para o desenvolvimento de metodologias de mensuração relacionadas ao risco operacional.

Afambo (2006), em seu estudo denominado “Operational Risk Capital Provisions for Insurance Companies”, investiga as implicações da utilização de metodologias de abordagens avançadas (*Advanced Measurement Approaches – AMA*) como forma de medir o carregamento de capital para risco operacional de bancos e seguradoras.

Neslehova, Embrechts e Chavez-Demoulin (2006) também discorre sobre o LDA através de seu estudo intitulado “Infinite mean models and the LDA for operational risk”, no qual se propõe a discorrer sobre análises estatísticas para bancos de dados de risco operacional relacionadas a metodologias de abordagens avançadas (AMA).

Frachot, Georges e Roncalli (2001) discorre em seu estudo denominado “Loss Distribution Approach in Practice” sobre os avanços nos estudos relacionados a utilização prática do LDA como alternativa aos requerimentos do Comitê de Basileia para solvência em risco operacional.

Complementarmente, devem-se destacar dois estudos que utilizam o LDA em um banco de dados para realizar testes empíricos de sua aplicabilidade para um banco de dados de risco operacional, bem como os eventuais vieses e outras observações que possam surgir em decorrência da aplicação prática do modelo.

Em primeiro lugar, Frachot, Georges e Roncalli (2001), em seu estudo denominado “Loss Distribution Approach for Operational Risk”, explora o LDA para mensurar o carregamento de capital necessário para fazer frente ao risco operacional de um banco. Neste caso, o LDA consiste no método estatístico e atuarial para modelar a distribuição das perdas. Este estudo é emblemático por servir de referência à grande parte dos autores que estudam o assunto.

Em seguida, devem-se citar os autores Dutta e Perry (2006), que através do estudo intitulado “A Tale of Tails: An Empirical Analysis of Loss Distribution Models for Estimating Operational Risk Capital” demonstraram a utilização do LDA sobre um banco de dados com sete instituições financeiras, sendo mais de mil eventos de perdas para cada uma.

No Brasil, Silva (2006) realizou uma dissertação de mestrado intitulada “Modelagem Estocástica em Risco Operacional Aplicando a Teoria dos Valores Extremos”. Deve-se citar também Mendes (2006), que apresentou estudo denominado “Modelo de Previsão de Perdas por Risco Operacional Utilizando Séries Temporais”.

Diante do referido volume de literatura sobre o assunto, o presente estudo pretende contribuir com as análises sobre o modelo LDA como opção para mensuração do risco operacional em empresas.

2.3.6. Simulação de Monte Carlo

A principal intenção deste estudo é desenvolver uma metodologia que possa mensurar o risco operacional em empresas. A forma como este modelo será desenvolvido envolve a simulação de variáveis aleatórias para determinação de eventuais perdas, o que permite que o modelo seja testado e que, ao ser usado, possa expressar medidas de previsão de perdas para determinado período.

A geração de variáveis aleatórias para o modelo será desenvolvida através do método de simulação de Monte Carlo, que, segundo Glasserman (2003), consiste na modelagem de um sistema que tenha propriedades estocásticas para, em seguida, serem gerados números aleatórios que reproduzam o comportamento do sistema.

Este estudo prevê somente a utilização de Monte Carlo como opção para simulação de variáveis, apesar de ser sabido que existem outras formas de criação de algoritmos numéricos conforme citado por Frachot et al. (2001), como a abordagem recursiva de Panjer e o inverso da função característica.

2.3.6.1. Simulação

Ehrentreich (2008) sugere que a simulação constitui uma metodologia alternativa à dedução e indução. Neste sentido, o autor se refere à simulação como uma terceira metodologia para realização de pesquisas, que apesar de não pode ser utilizada para provar teoremas, costuma ser útil para incrementar o entendimento sobre fenômenos complexos que estejam fora do alcance para as teorias dedutivas.

Segundo Rubinstein (1981), a simulação tem sido uma importante ferramenta de planejamento para diversas áreas como, por exemplo, simulação de voo de um jato supersônico, desenvolvimento de sistema de comunicação telefônica, túneis de vento, batalhas militares, entre outros.

Desta forma, uma das grandes vantagens da simulação é a grande capacidade de adequação a diversas áreas de pesquisa. Neste sentido, Naylor et al. (1966) aponta que a simulação não exige que determinado modelo seja apresentado em um formato particular, pois ela permite um grau considerável de liberdade para que o modelo possa ostentar uma estreita correspondência com o sistema a ser estudado. Se bem estruturada, a simulação permite que os resultados obtidos sejam praticamente os mesmos que as observações ou medições feitas no próprio sistema.

Rubinstein (1981) aponta ainda que, embora muitas vezes a simulação seja vista como último recurso, a ser empregado somente quando alternativas não podem ser utilizadas, recentes avanços em metodologias de simulação, a disponibilidade de softwares, e os desenvolvimentos técnicos fizeram da simulação uma das ferramentas mais amplamente utilizadas e aceitas nas investigações científicas.

Naylor et al. (1966) aponta vários motivos que permitem-nos considerar a utilização da simulação como um importante instrumento de pesquisa científica. Entre estes motivos, destacam-se:

1. A simulação permite estudar e realizar experimentos sobre as complexas interações internas de um determinado sistema;

2. A simulação também permite que sejam estudados os efeitos das mudanças sobre o funcionamento de um determinado sistema, sejam estas mudanças organizacionais, de ambiente ou de informações;
3. A observação detalhada do sistema a ser simulado pode levar a uma melhor compreensão do mesmo, bem como a sugestões para melhorá-lo;
4. A experiência de projetar um modelo de simulação em computador pode ser mais valiosa do que a simulação em si. O conhecimento obtido na concepção de um estudo de simulação freqüentemente sugere mudanças no sistema que está sendo simulado. Os efeitos dessas mudanças podem então ser testados através de simulação antes de implementá-las no sistema real;
5. A simulação de sistemas complexos pode gerar um aprendizado valioso sobre quais variáveis são mais importantes que outras no sistema e como essas variáveis interagem entre si;
6. A simulação pode ser usada para experimentar novas situações sobre as quais temos pouca ou nenhuma informação a fim de preparar para o que pode acontecer;

Pode servir como um teste de pré-serviço para experimentar novas políticas e regras de decisão para um determinado sistema operacional, sem precisar correr o risco de experimentar o sistema real.

2.3.6.2. O Método de Simulação de Monte Carlo

A utilização do método de Monte Carlo, apesar de datada de muitos anos anteriores, foi revivida intensamente durante a II Guerra Mundial, com o intuito de investigar problemas militares em pesquisas sobre operações. Durante este mesmo período, este método foi revivido por Von Neumann, Ulam e outros, para pesquisas sobre problemas da Comissão de Energia Atômica, período o qual se admite que o codinome "Monte Carlo" passou a ser largamente utilizado.

Para tornar mais didática a compreensão do que trata o modelo de Monte Carlo, deve-se preliminarmente compreender que este modelo é alicerçado sobre a definição de simulação. Segundo Philippatos (1973), a simulação é a utilização de um modelo para aproximar o comportamento de um sistema do mundo real dentro de um ambiente artificial. Didaticamente, podemos representar um modelo através de uma simples definição:

$$Y = W + X$$

Este modelo pode ser a resposta para um problema, ou pode ser a previsão do futuro. Em qualquer caso, busca-se saber o valor Y . Para o referido caso, W e X são conhecidos como variáveis exógenas, porque seus valores são determinados fora do modelo. Temos que ter os valores de W e X , a fim de obter uma resposta de Y .

Contextualizando a este caso, Monte Carlo é apenas um tipo de simulação usado para gerar valores para as variáveis exógenas.

Glasserman (2003) descreve o modelo de Monte Carlo como o ato de coletar uma amostra aleatória sobre um universo de resultados possíveis, utilizando esta amostra para coletar estimativas de prováveis comportamentos. Segundo Okten (1997), em geral, qualquer quantidade que possa ser escrita como o valor esperado de uma variável aleatória definida em um espaço de probabilidade pode ser estimada por estes métodos.

Glasserman (2003) e Okten (1997) apontam a Lei Forte dos Grandes Números como base teórica de Monte Carlo, haja vista que esta lei garante que estas estimativas convirjam para o valor correto na medida em que o número de geração de amostras aumenta.

Complementarmente, Lai (2000) sugere que o método de Monte Carlo baseia-se na seguinte idéia: para um dado problema, constrói-se um modelo probabilístico para que a solução do problema possa ser representada como o valor esperado de alguma variável aleatória ξ de espaço de probabilidade específico Ω . Então, essa expectativa é estimada tomando a média da amostra ξ com a amostra de tamanho N , que são determinadas através de plataforma computacional utilizada.

Atualmente muitos softwares se propõem a gerar números aleatórios, o que permite que o modelo de Monte Carlo seja utilizado largamente para os mais diversos problemas. A definição de Lai (2000) aponta uma forma didática de se estruturar um problema e utilizar o modelo de Monte Carlo para se aferir o valor esperado de uma variável em determinado espaço amostral.

Resumidamente, a simulação de Monte Carlo gera eventos aleatórios para comporem um determinado espaço amostral e, a partir dos resultados obtidos, diversas análises possam ser feitas, seja com a intenção de analisar um fato passado, ou mesmo tentar prever o futuro com um determinado grau de confiança.

Neste sentido, McCarthy (2000) aponta que o objetivo da simulação de Monte Carlo não é simplesmente re-criar eventos aleatórios eletronicamente. Seu valor real vem da análise

dos resultados da simulação, que pode revelar o valor esperado do evento e da dispersão dos resultados em torno desse valor.

2.3.6.3. Aplicações do Método de Monte Carlo em Estudos Científicos

O método de Monte Carlo é muito utilizado em estudos científicos de diversas áreas, como biologia, física, matemática e finanças.

Para ilustrar a intensa utilização do método de Monte Carlo em pesquisas científicas, podemos destacar pesquisas e autores tais quais:

- a. Biologia: Luan (2010) e Rosenblad (2009);
- b. Física: Sanabria e Sechet (2010) e Wang (2010);
- c. Matemática: Brednikhin, Medvedev e Mikhailov (2010) e Kojadinovic e Yan (2010).

2.3.6.4. Aplicações do Método de Monte Carlo em Finanças

Segundo Nawrocki (2001), em 1964 o pesquisador Hertz sugeriu pela primeira vez o uso de simulação de Monte Carlo em aplicações de negócios. Este trabalho criou uma explosão do uso em todas as áreas de negócios, incluindo finanças.

A partir da intensificação contínua na utilização de Monte Carlo ao longo dos anos, McCarthy (2000) constata que a simulação de Monte Carlo passou a estar amplamente presente no currículo das principais escolas de negócios.

A utilização de Monte Carlo em pesquisas relacionadas a finanças permite que variáveis de um sistema sejam modeladas através de determinados parâmetros, sendo que esta modelagem possibilita o estudo de um determinado sistema com base no comportamento das variáveis parametrizadas.

Entre as áreas de finanças que apresentam pesquisas utilizando Monte Carlo, a área de risco destaca-se por apresentar, em sua essência, a necessidade de se estimar comportamentos através de aferições quantitativas, o que muitas vezes demanda a utilização de Monte Carlo. Neste sentido, Philippatos (1973) afirma que a simulação de um sistema pode ser a resposta para um problema, bem como um instrumento para previsão do futuro.

De uma forma mais sintética, McNeil et al. (2005) descreve o método de Monte Carlo como uma denominação geral para qualquer abordagem de mensuração de risco que envolva a simulação de um modelo paramétrico explícito para mudanças em fatores de risco.

2.3.6.5. Aplicações do Método de Monte Carlo em Risco Operacional

Autores como Afambo (2006), Frachot et al. (2001), Baud et al. (2002), Tripp et al. (2004), Neil et al. (2009) prevêm em seus estudos sobre Risco Operacional a utilização das técnicas de simulação de Monte Carlo.

De forma sintética, a aplicação do método de Monte Carlo para risco operacional se dá através da definição dos parâmetros das distribuições de probabilidade para frequência e severidade de perdas, para posterior simulação de eventos de perdas e geração de uma nova distribuição de perdas através da agregação da frequência e da severidade simuladas.

Este item, por se tratar de um dos pontos centrais desta pesquisa, será mais amplamente explicitado durante os procedimentos metodológicos e análise dos resultados.

2.3.7. Geração de Variáveis Aleatórias

A simulação de eventos de perdas pode alicerçada na geração de variáveis aleatórias que obedeçam a certas características de distribuições históricas.

Robert e Casella (2004) destacam a importância da geração de variáveis aleatórias uniformes no intervalo $[0, 1]$, haja vista que a distribuição uniforme $U_{[0,1]}$ é base para todas as outras distribuições e seus respectivos algoritmos de geração de variáveis aleatórias.

Por exemplo, se imaginarmos que a média de uma série de perdas é \$ 10, e que estas perdas seguem uma distribuição Poisson, pode-se então criar um algoritmo que, a partir da média (considerada igual ao Valor Esperado) e de uma variável aleatória de distribuição uniforme $U_{[0,1]}$, seja capaz de gerar variáveis aleatórias que representem uma série de perdas de Valor Esperado próximo de \$ 10 e distribuição de probabilidade com características de distribuição de Poisson.

Algumas deduções matemáticas são necessárias para a criação dos algoritmos, haja vista que existe a necessidade de se compreender os conceitos de valor esperado e variância, bem como suas equivalências e propriedades, para que se busque um sistema de equações que aponte os parâmetros a serem inseridos em algoritmos de geração de variáveis aleatórias de cada tipo de distribuição de probabilidade. Algumas destas demonstrações são descritas nos apêndices deste trabalho.

3. PROCEDIMENTOS METODOLÓGICOS

3.1. Origem dos Dados

A primeira etapa no sentido de se realizar a simulação de perdas operacionais se dá na coleta de um banco de dados de perdas. Este item se alicerça na necessidade de se conhecer o comportamento estatístico das perdas operacionais, o que deverá propiciar a definição de parâmetros probabilísticos para geração de variáveis aleatórias que propiciarão a simulação de perdas.

3.2. Descrição e Ajustes dos Dados

O banco de dados bruto deverá apresentar uma série de características que podem levar a necessidade de ressalvas e ajustes.

É possível que existam dados incompletos ou incoerentes, bem como insuficiência de dados sobre determinada variável.

Na medida em que se obtém o banco de dados, deve-se conciliar o seu formato e vieses com a necessidade da pesquisa. Pode haver, desta forma, necessidade de exclusão de alguns itens, ou mesmo outros ajustes.

Nesta etapa deverá se realizar as adequações e analisar os resultados obtidos, haja vista que estes podem servir de base para comparação com os resultados da simulação. As medidas de adequação deverão ser acompanhadas de explanação de motivos e apresentação de eventuais vieses para a pesquisa.

3.3. Frequência das Perdas

A frequência das perdas consiste na mensuração da quantidade de eventos que ocorrem para um mesmo período. Nesta etapa deve-se analisar o banco de dados quanto aos resultados (média, variância, entre outros) para cada período definido.

Se as perdas ocorrem livremente durante o tempo, e o banco de dados reúne as perdas por ocorrência, deve-se utilizar o campo de “data da ocorrência” para agrupar as perdas em períodos iguais (dia, quinzena, mês, etc.). Desta forma, pode-se realizar a simulação para

todos os períodos possíveis, ou simplesmente escolher uma ou mais periodicidades específicas para serem utilizadas como padrão para a pesquisa.

3.4. Severidade das Perdas

A severidade das perdas consiste na mensuração do volume financeiro de cada evento de perda, individualmente. Também nesta etapa deve-se analisar o banco de dados quanto aos resultados (média, variância, entre outros), incluindo a análise da severidade geral e para cada período definido (dia, quinzena, mês, etc.).

3.5. Simulações

A análise das perdas históricas permite que sejam aferidos os dados estatísticos da frequência e severidade das perdas.

Conforme descrito anteriormente, para a frequência, pode-se então medir quantas perdas ocorreram a cada período (dia, quinzena, etc.) e qual a média, desvio-padrão, variância e outras medidas estatísticas da base de dados analisada. Para a severidade, pode-se saber qual o volume financeiro de cada perda e qual a média, desvio-padrão, variância e outras medidas estatísticas.

Desta forma, considerando-se os resultados obtidos através da análise da frequência e da severidade das perdas, passa-se então para a etapa da realização da simulação de perdas com base nos dados históricos analisados.

Esta etapa de simulação utiliza o comportamento estatístico da base analisada para medir um eventual comportamento futuro, probabilisticamente, com base nos valores esperados e suas distribuições de probabilidade.

3.5.1. Simulação de Monte Carlo

A simulação de Monte Carlo, para este caso, consiste na estimação de variáveis aleatórias que representem um valor para cada frequência de perda e outro valor para cada severidade de cada frequência estimada.

Para exemplificar, pode-se admitir que, com base no comportamento estatístico de uma base de dados de cinco anos de perdas relacionadas ao Risco Operacional de determinada empresa, a simulação da frequência de perdas para um dia gere 5 perdas, sendo que para cada

uma das cinco perdas é feita uma nova simulação independente que aponta R\$ 1.000 para a primeira, R\$ 2.500 para a segunda, R\$ 100.000 para a terceira, R\$ 500 para a quarta e R\$ 10.000 para a quinta.

Certamente que a simulação da frequência e severidade das perdas não é totalmente aleatória, e devem obedecer as características da distribuição de probabilidade com base no valor esperado, desvio-padrão, variância e outros indicadores obtidos no comportamento histórico de cada variável.

3.5.1.1. Parâmetros para Simulação de Monte Carlo

Para que seja realizada a simulação, devem-se determinar os parâmetros que são utilizados para a geração de variáveis aleatórias para a frequência e para a severidade. Estes parâmetros devem tomar como base os dados estatísticos da base de dados, conforme a análise feita da mesma nos itens anteriores.

Os parâmetros também devem atender as necessidades dos algoritmos de geração de variáveis aleatórias, conforme as distribuições de probabilidade de perdas escolhidas. Conforme apontado no referencial teórico destas pesquisas, as deduções matemáticas que definem a forma de utilização dos parâmetros para geração de variáveis estão descritas nos apêndices.

Para exemplificar, a geração da variável aleatória de uma distribuição de Poisson utiliza o lambda como parâmetro. Para a obtenção de um lambda, sabe-se por dedução matemática que existe uma equivalência entre o lambda e o valor esperado de uma distribuição de Poisson. Desta forma, admite-se utilizar a média aritmética da base de dados históricos como o valor esperado e, conseqüentemente, como o lambda para a geração da variável de Poisson.

3.5.1.2. Simulação de Monte Carlo: Frequência

Com base nos algoritmos de geração de variável aleatória, bem como nos parâmetros da distribuição histórica de perdas contida na base de dados escolhida, são gerados para cada período uma quantidade variável e aleatória de perdas.

Certamente a distribuição da frequência simulada das perdas apresentará características de acordo com o algoritmo escolhido para geração das variáveis aleatórias. Por exemplo, se for utilizado um algoritmo de geração de variáveis aleatórias de Poisson, a

distribuição das frequências simuladas apresentará características condizentes a uma distribuição de Poisson.

3.5.1.3. Simulação de Monte Carlo: Severidade

Sobre a quantidade variável e aleatória de perdas gerada pela simulação da frequência, para cada evento é simulado um volume financeiro de perda, que se denomina severidade. Desta forma, se for gerada uma quantidade de 3 perdas para um dia (frequência), para cada perda será gerado um volume financeiro independente e aleatório, por exemplo \$ 10.000, \$ 2.000 e \$ 150.000.

A distribuição das severidades estimadas também se comportará de forma condizente com o tipo de algoritmo utilizado para a simulação do volume financeiro das perdas. Caso este algoritmo seja direcionada para a geração de variáveis aleatórias Gama, por exemplo, a distribuição do volume financeiro de perdas gerado também se aproximará de uma distribuição Gama.

3.5.1.4. Simulação de Monte Carlo: Perdas Agregadas e VaR

Uma vez simuladas as frequências e severidades das perdas, deve-se realizar a agregação dos resultados para a elaboração de uma distribuição de perdas agregadas, bem como obtenção do VaR da distribuição.

Esta ação se dá através da organização dos dados gerados seguindo os seguintes passos descritos no algoritmo abaixo:

- i. Obtenção das frequências individuais de perdas para cada simulação realizada;
- ii. Para cada frequência simulada, deve-se alocar a respectiva quantidade de severidade de perdas, gerados independentemente;
- iii. Para cada frequência simulada e respectivas severidades de perdas deve-se realizar a soma das perdas, considerando-as como o total para aquele período simulado. Por exemplo, se a primeira simulação de frequência gerar um resultado n , quer dizer que para um período T (diário, quinzenal, etc.) ocorreram n perdas e cada perda terá uma severidade s_x ($x = 1, 2, \dots$), sendo a

perda total do período igual a $\sum s_x$;

- iv. A reunião de todos os períodos simulados e suas respectivas perdas agregadas ($\sum s_{i,x}$) deverá ser classificada quanto ao volume financeiro das perdas agregadas;
- v. Deve então obter o VaR, com base no seu respectivo intervalo de confiança, através de ordenação dos valores de perdas agregadas e extração do valor correspondente a VaR desejado.

3.5.1.5. Simulação de Monte Carlo: Resultados

Os resultados obtidos através da simulação resumem-se em:

- a. Distribuição de frequência simulada;
- b. Distribuição de severidade simulada;
- c. Distribuição de perdas agregadas simuladas;
- d. VaR das perdas simuladas;

Estes resultados podem ser gerados a partir de distintas formas de distribuição de probabilidade (Poisson, Log-Normal, Binomial Negativa, etc.), bem como a partir de diferentes bases de dados e parâmetros.

Para comparar com os resultados obtidos nas distintas possibilidades de simulação, todos os testes podem ser refeitos seguindo as mesmas condições, adicionando-se um desmembramento da base de dados original e, conseqüentemente, uma alteração nos parâmetros de estimação das distribuições de probabilidade (média, desvio-padrão, etc.).

O desmembramento deve ser feito a partir da divisão da base de dados original em duas, realizada através do sorteio aleatório de cada dado para que passasse a compor uma ou outra nova base. Para cada dado foi sorteado um valor aleatório igual a 0 ou 1, sendo que todos os dados sorteados com o valor 0 passaram a compor a nova base de dados denominada “Base de Calibragem”, e os demais dados passaram a compor a base de dados denominada “*Hold Out Sample*”, que é simplesmente descartada.

Desta forma, serão apresentados abaixo os resultados da “Base de Calibragem”, conforme nos seguintes cenários de mensuração:

- a. Poisson (frequência) e LogNormal (severidade)
- b. Poisson (frequência) e Gama (severidade)
- c. Binomial Negativa (frequência) e LogNormal (severidade)

d. Binomial Negativa (frequência) e LogNormal (Gama)

Para cada cenário serão gerados 5.000 VaR, sendo que cada VaR será obtido através da simulação de 10.000 períodos de perdas agregadas (dias, quinzenas, ou qualquer outra periodicidade a ser determinada).

4. ANÁLISES DE RESULTADOS

4.1. Origem dos Dados

Os dados coletados para a composição da base de dados de eventos de perdas relacionadas a Risco Operacional são oriundos do site <http://datalossdb.org/>.

O DataLossDB é um projeto de pesquisa que tem por finalidade a documentação de dados de perdas ocorridos ao redor do mundo. Este projeto visa reunir informações sobre eventos que envolvam perda, roubo ou exposição de informações pessoalmente identificáveis. A base de dados disponível tem servido de base para pesquisas de diversas entidades educacionais, governamentais e comerciais.

Os dados disponíveis nesta fonte podem não seguir rigorosamente regras de quantificação para cada perda relacionada, mas apresentam uma opção disponível de estudo do tema que, segundo o próprio site citado acima, não tem uma fonte aberta de dados que facilitem a investigação da estrutura quantitativa dos eventos de perdas relacionados ao Risco Operacional. Desta forma, a base de dados fornecida pelo site supracitado permite que seja testado o arcabouço teórico desenvolvido por este estudo.

4.2. Descrição dos Dados

Existem algumas formas de filtrar os dados de perdas disponíveis no DataLossDB. Em primeiro lugar, existem quatro setores para os quais cada evento de perda pode ser atribuído, havendo ainda a possibilidade de um único evento estar ligado a mais de um setor, sendo eles:

- Negócios, Educação, Governo e Medicina.

Para os quatro setores existem 25 subtipos que os refinam, sendo eles:

- Negócios de Varejo, Financeiro, Tecnológico, Médico (não-hospitalar – fornecedor), Governo Federal, Serviços de Informações, Comunicação de Massa, Universidade, Indústria, Governo do Estado, Sem Fins Lucrativos, entre outros (relação original completa no apêndice).

Para os tipos de perdas existem 9 tipos:

- Número de Cartão de Crédito, Número da Seguridade Social, Nomes e Endereços, Endereços de Email, Miscelâneas, Médico, Informações Contábeis, Data de Nascimento, Informações Financeiras.

Existem ainda 24 subtipos de perdas, como:

- Exposição a vírus de computador, roubo de laptop, email exposto a terceiros não autorizados, entre outros (relação original completa no apêndice).

Tantas subdivisões dos eventos de perdas podem permitir diversas análises, mas para esta pesquisa as simulações serão realizadas a partir dos dados gerais, haja vista que somente a partir de um banco de dados muito extenso é que seria razoável a utilização tantas divisões. Ressalta-se ainda que o banco de dados de perda do DataLossDB ainda disponibiliza somente pouco menos de 3 mil eventos de perdas, bem como diversos ajustes são necessários para que tais eventos se adéquem as condições ideais para definição de parâmetros e início do processo de simulação.

4.3. Base de Dados Original: Primeiros Ajustes

A obtenção dos dados em maio de 2010 gerou 2605 dados originais de perdas, divididos entre os anos conforme a tabela abaixo:

Tabela 2: Dados Originais de Perdas

Dados	Quantidade	%
<2000	25	1,0%
2000	9	0,3%
2001	17	0,7%
2002	5	0,2%
2003	14	0,5%
2004	24	0,9%
2005	141	5,4%

2006	533	20,5%
2007	491	18,8%
2008	732	28,1%
2009	480	18,4%
2010	134	5,1%
Total	2.605	100,0%

4.3.1. Ajuste 1: Redução do Período Analisado

Pela baixa frequência, todas as ocorrências anteriores a 2006 foram desconsideradas, totalizando a exclusão de 235 dados ou 9,0% da base total.

Deve-se observar, adicionalmente, que as ocorrências do ano de 2010 compreendem somente o período dos cinco primeiros meses do ano.

A base de dados passa então a compreender um período aproximado de 4,5 anos, de 2006 a 2010, com um total de 2.370 perdas, distribuídas conforme a tabela abaixo:

Tabela 3: Dados de Perdas após Ajuste 1

Dados	Quantidade	%
2006	533	22,5%
2007	491	20,7%
2008	732	30,9%
2009	480	20,3%
2010	134	5,7%
Total	2.370	100,0%

4.3.2. Ajuste 2: Exclusão de outras Perdas

O primeiro ajuste realizado pela análise da frequência das perdas reduziu a base de 2.605 para 2.370 eventos.

Para a severidade, faz-se necessário um novo ajuste, que leve em conta a razoabilidade dos volumes financeiros das perdas.

Entre os 2.370 dados restantes, destacam-se 683 que apresentam severidade das perdas iguais a zero. Entende-se que estes dados estejam disponíveis na base por representarem um tipo de perda não quantificada, seja por impossibilidade técnica ou por não ter havido tempo para medir o tamanho da referida perda (caso de perdas atribuídas a este ano de 2010). Independente do motivo pelo qual estes dados apresentam severidade igual a zero, toma-se como precaução a exclusão dos mesmos sobre a base, para que as medidas estatísticas que irão mensurar as distribuições de probabilidade não sofram deste viés.

Desta forma, a base de dados resultante deste segundo ajuste passa a se configurar da seguinte forma:

Tabela 4: Dados de Perdas após Ajuste 2

Dados	Quantidade	%
2006	359	21,3%
2007	366	21,7%
2008	542	32,1%
2009	320	19,0%
2010	100	5,9%
Total	1.687	100,0%

Seguindo a segmentação por setor, a base passa a apresentar a seguinte configuração:

Tabela 5: Segmentação dos Dados de Perdas por Setor

Segmento	Quantidade	%
Negócios	661	39,2%
Educação	396	23,5%
Governo	342	20,3%
Medicina	258	15,3%
Outros	30	1,8%
Total	1.687	100,0%

4.4. Freqüência das Perdas

A análise da freqüência das perdas pode ser realizada por dia, quinzena, mês ou qualquer outro período determinado. Para a base de dados final, com 1.687 dados, os testes sobre a freqüência de perdas foram realizados para os períodos diário, quinzenal e mensal, conforme segue:

Tabela 6: Análise da Freqüência de Perdas

Medidas	Diário	Quinzenal	Mensal
Média	1,8277	15,8704	31,7407
Desvio-Padrão	1,0960	7,2086	12,7874
Variância	1,2013	51,9643	163,5164
Maior	9,0000	40,0000	61,0000
Moda	1,0000	15,0000	23,0000

Estes dados servirão como parâmetros para a realização das simulações, ou seja, para a execução dos algoritmos de geração de variáveis aleatórias, os dados de média e variância serão os fatores determinantes dos resultados das simulações das distribuições de Poisson e Binomial Negativa, conforme demonstrado no apêndice referente aos respectivos algoritmos de geração de variáveis aleatórias.

4.5. Severidade das Perdas

A análise da severidade das perdas foi também realizada por dia, quinzena e mês. Para a base de dados final, com 1.687 dados, os testes sobre a severidade de perdas foram realizados para os períodos diário, quinzenal e mensal, conforme segue:

Tabela 7: Análise da Severidade de Perdas

Medidas	Diário	Quinzenal	Mensal
Média	325.253	4.953.243	9.906.488
Desvio-Padrão	4.528.404	17.370.167	23.853.498
Variância	20.506.444.066.647	301.722.715.033.488	568.989.366.329.639
Maior	130.017.718	130.062.229	130.216.942

Para a série de dados diária, a maior severidade durante o período de 2006-2010 foi de \$ 130.017.718,00. Para a série quinzenal, o valor de maior expressão foi de \$ 130.062.229,00. Na série mensal, a maior perda foi de \$ 130.216.942,00. Estes valores de maior expressão, tão distantes das médias para cada respectiva periodicidade, são influenciados pela perda de \$ 130.000.000,00 ocorrida em 20/01/2009, na empresa Heartland Payment Systems.

A tabela abaixo relaciona em ordem decrescente as 10 maiores perdas registradas na base de dados, conforme segue:

Tabela 8: As 10 Maiores Perdas da Base de Dados

Data	Empresa	Valor
20/01/09	Heartland Payment Systems	130.000.000
17/01/07	TJX Companies Inc.	94.000.000
05/10/09	National Archives and Records Administration	76.000.000
22/05/06	U.S. Department of Veterans Affairs	26.500.000
20/11/07	HM Revenue and Customs	25.000.000
06/10/08	T-Mobile	17.000.000
26/03/08	BNY Mellon Shareowner Services	12.500.000
06/09/08	GS Caltex	11.000.000
12/03/07	Dai Nippon Printing Company	8.637.405
03/07/07	Fidelity National Information Services	8.500.000

Para a base de dados então final, com 1.687 dados, foram extraídos três VaR, com intervalos de confiança de 99,0%, 95,0% e 90,0%, conforme descrito na tabela abaixo:

Tabela 9: VaR da Base de Dados

Data	Valor
VaR (99,0%)	3.300.000
VaR (95,0%)	300.000
VaR (90,0%)	100.000

Pode-se então obter o histograma das perdas, conforme representado na figura abaixo:

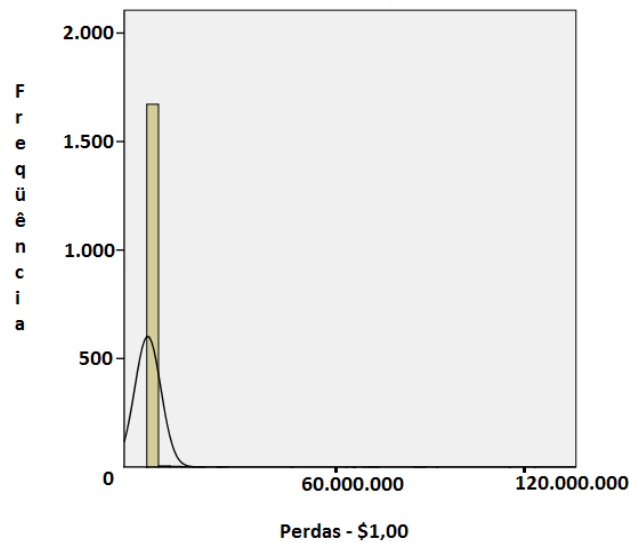


Figura 2 – Histograma das Perdas da Base de Dados Ajustada (1.687 eventos)

É importante notar que a escala das perdas varia de \$ 0 a \$ 130.000.000, sendo que a maior ocorrência constitui um valor muito distante da área de maior frequência, o que faz com que o histograma das perdas apresente o formato acima, onde a barra de perdas baixas apresenta um tamanho maior, o que ratifica os altos índices de dispersão da média encontrados (desvio-padrão e variância).

4.6. Simulações

A análise das perdas históricas permite que sejam aferidos os dados estatísticos da frequência e severidade das perdas.

Para a frequência, pode-se então medir quantas perdas ocorreram a cada período (dia, quinzena, etc.) e qual a média, desvio-padrão, variância e outras medidas estatísticas da base de dados analisada.

Para a severidade, pode-se saber qual o volume financeiro de cada perda e qual a média, desvio-padrão, variância e outras medidas estatísticas.

Desta forma, considerando-se os resultados obtidos através da análise da frequência e da severidade das perdas, passa-se então para a etapa da realização da simulação de perdas com base nos dados históricos analisados.

Esta etapa de simulação utiliza o comportamento estatístico da base analisada para medir um eventual comportamento futuro, probabilisticamente, com base nos valores esperados e suas distribuições de probabilidade.

4.6.1. Simulação de Monte Carlo

A simulação de Monte Carlo, para este caso, consiste na estimação de variáveis aleatórias que representem um valor para cada frequência de perda e outro valor para cada severidade de cada frequência estimada.

Para exemplificar, pode-se admitir que, com base no comportamento estatístico de uma base de dados de cinco anos de perdas relacionadas ao Risco Operacional de determinada empresa, a simulação da frequência de perdas para um dia gere 5 perdas, sendo que para cada uma das cinco perdas é feita uma nova simulação independente que aponta R\$ 1.000 para a primeira, R\$ 2.500 para a segunda, R\$ 100.000 para a terceira, R\$ 500 para a quarta e R\$ 10.000 para a quinta.

Certamente que a simulação da frequência e severidade das perdas não é totalmente aleatória, e devem obedecer as características da distribuição de probabilidade com base no valor esperado, desvio-padrão, variância e outros indicadores obtidos no comportamento histórico de cada variável.

4.6.2. Programa de Simulação

Para a realização das simulações, foi criado um programa em Microsoft Excel, estruturado sobre programações de macros em linguagem VBA. Este programa se constitui em uma interface amigável dos conceitos até então expostos, o que facilita a realização das simulações.

A figura abaixo apresenta a interface de definição dos parâmetros, ou seja, após a análise da base de dados histórica, a simples obtenção de dados estatísticos como média e desvio-padrão da frequência e severidade das perdas é suficiente para que o programa esteja apto a simular diversos cenários, haja vista que é necessário somente preencher os itens contidos em “Dados da Distribuição”, conforme segue o exemplo:

Distribuição de Freqüência		Distribuição de Severidade	
<u>Dados da Distribuição:</u>			
E [X] = Média =	7.86	E [X] = Média =	53,745.29
Var (X) =	18.94	Desvio-Padrão =	193,591.13
		Var (X) =	37,477,527,429.39
<hr/>			
<u>Quando Poisson:</u>			
Lambda = (Média)	7.86		
<hr/>			
<u>Quando Binomial Negativa:</u>			
E [X] =	r / p	E [X] =	$\alpha * \beta$
Var (X) =	$r * (1 - p) / p^2$	Var (X) =	$\alpha * \beta^2$
Solução do Sistema			
$r = p * E [X]$		$\alpha = E [X] / \beta$	
$p = 1 / [(Var (X) / E [X]) + 1]$		$\beta = Var (X) / E [X]$	
(r) =	2.31	alpha =	0.08
(p) =	0.29	beta =	697,317.41

Figura 3 – Interface de Definição dos Parâmetros

Após a definição dos parâmetros, as macros que realizam todas as simulações precisam receber ainda, agora na interface de simulações, as “Características Gerais”, que devem conter o número de simulações desejadas e o intervalo de confiança dos VaR a serem obtidos. Por fim, para realizar a simulação, basta “clique” em um dos botões correspondentes aos quatro cenários de simulações disponíveis, conforme apresentado na figura abaixo:

DADOS DE ENTRADA		
<u>Características Gerais</u>		
Números de Simulações	100	
Intervalo de Confiança (VaR)	99.00%	
<u>Opções de Simulação</u>		
(1) Poisson + LogNormal	(1)	
(2) Poisson + Gama	(2)	
(3) Bin.Negativa + LogNormal	(3)	
(4) Bin.Negativa + Gama	(4)	
<u>Distribuição de Freqüência</u>		
Quando Poisson:		
(Lâmbda) =	7.86	
Quando Binomial Negativa:		
(r) =	2.31	
(p) =	0.29	
<u>Distribuição de Severidade</u>		
Quando LogNormal:		
(Mu) =	7.82	
(Sigma) =	2.81	
Quando Gama:		
(alpha) =	0.08	
(beta) =	697,317.41	

Figura 4 – Interface de Simulação dos Cenários

4.6.3. Parâmetros para Simulação de Monte Carlo

Para que seja realizada a simulação, devem-se determinar os parâmetros que são utilizados para a geração de variáveis aleatórias para a frequência e para a severidade. Estes parâmetros devem tomar como base os dados estatísticos da base de dados, conforme a análise feita da mesma nos itens anteriores.

Tanto para a frequência quanto para a severidade, foi decidido que o período utilizado para análise seria de 15 dias, ou seja, os dados foram agrupados quinzenalmente. Foram realizados testes para outros períodos (diário e mensal), mas por questões de conveniência para programação computacional e posteriores análises, ficou decidido que o período quinzenal seria mais apropriado para o processo de simulação.

Para a frequência das perdas, periodicidade quinzenal, os principais parâmetros estimados apresentaram os seguintes valores:

Tabela 10: Parâmetros da Frequência (Quinzenal)

Data	Valor
Média Aritmética	15,87
Variância	51,96

Para a severidade das perdas, analisada caso a caso (perda a perda), os parâmetros foram:

Tabela 11: Parâmetros da Severidade

Data	Valor
Média Aritmética	4.953.244
Desvio-Padrão	17.370.167
Variância	301.722.715.033.488
Média Aritmética do Ln(perda)	13.21
Desvio-Padrão do Ln(perda)	2,81

Todos estes valores apresentados acima servirão de referência para que sejam montados algoritmos de geração de variáveis aleatórias para frequência e severidade das perdas, com base nas seguintes distribuições de probabilidade:

- a. Para frequência: Poisson e Binomial Negativa

- b. Para severidade: Log-Normal e Gama

4.6.4. Simulação de Monte Carlo: Frequência

Para a simulação da frequência, que agrupa a quantidade de perdas relacionadas ao Risco Operacional para cada período quinzenal, foi necessário realizar a programação computacional de geração de variável aleatória com base em uma distribuição de probabilidade.

As duas distribuições de probabilidades escolhidas, amparadas pelo referencial teórico como distribuições mais comuns em frequência de perdas operacionais, foram Poisson e Binomial Negativa.

Para uma distribuição de Poisson, o fator determinante na geração de variável é o λ , que segundo a própria distribuição deve ser representado pelo valor esperado. Para este caso, utilizou-se como valor esperado a média aritmética da base de dados histórica de perdas, que apresenta o valor de 15.87 para o período quinzenal, ou seja, aproximadamente 15.87 perdas por período.

Como se trata de uma variável discreta a ser representada por número inteiro, o algoritmo que determina a variável aleatória contempla o λ de 15.87, mas gera um valor positivo inteiro para a quantidade simulada de perdas para cada período.

Para a distribuição Binomial Negativa, os fatores determinantes são as variáveis denominadas “ r ” e “ p ”, obtidas através de cálculos sobre o valor esperado e a variância. Conforme o caso da distribuição de Poisson, o valor esperado foi estimado através da média aritmética da frequência de perdas quinzenais da base de dados utilizada, bem como a variância foi representada pela aferição da mesma sobre a mesma base.

O algoritmo da geração de variável aleatória Binomial Negativa também gera um número inteiro e positivo para a quantidade de perdas, calculados sobre o valor esperado de 15.87 e variância de 51.96, que geram “ $r = 3.71$ ” e “ $p = 0.23$ ”.

4.6.5. Simulação de Monte Carlo: Severidade

Para a simulação da severidade, que determina o tamanho de cada perda relacionada ao risco operacional, também foi necessário realizar a programação computacional de geração de variável aleatória com base em uma distribuição de probabilidade.

As duas distribuições de probabilidades escolhidas, amparadas pelo referencial teórico como distribuições mais comuns em frequência de perdas operacionais, foram Log-Normal e Gama.

Para uma distribuição Log-Normal, os fatores determinantes na geração de variável são o “Mu” e “Sigma”, representado pela média e desvio-padrão do $\ln(x)$, ou seja, do log das perdas operacionais. Para este caso, utilizou-se a média aritmética da base de dados histórica de perdas, que apresenta o valor de 13.21 para o período quinzenal, e o desvio-padrão de 2.81.

Para uma distribuição Gama, os fatores determinantes na geração da variável aleatória são “alpha” e “beta”, representados respectivamente por equações que envolvem o valor esperado e a variância das perdas operacionais. Neste caso o valor esperado foi considerado igual a média da base de dados histórica, assumindo um valor de 4.953.243.93, e a variância no valor de 301.722.715.033.488,00, que passam a gerar “alpha = 0.08” e “beta = 60.914.164.44”.

4.6.6. Simulação de Monte Carlo: Perdas Agregadas e VaR

A análise das perdas agregadas se dá pela repetição das simulações de frequência e severidade das perdas operacionais. Ou seja, para cada período quinzenal estimado, estima-se uma quantidade de perdas e o tamanho de cada perda (frequência e severidade). Estas gerações são aleatórias e independentes.

Existem então quatro possibilidades de utilização dos algoritmos de geração de variáveis aleatórias, com base nas distribuições de probabilidade assumidas para este estudo:

- a. Poisson (frequência) e LogNormal (severidade)
- b. Poisson (frequência) e Gama (severidade)
- c. Binomial Negativa (frequência) e LogNormal (severidade)
- d. Binomial Negativa (frequência) e LogNormal (Gama)

Para esta pesquisa, foi desenvolvido um software capaz de simular milhares de vezes as perdas operacionais para determinado período e com base nos algoritmos de geração de variáveis aleatórias baseados em cada uma das distribuições de probabilidades citadas.

Como importante parâmetro de comparação dos resultados obtidos pela simulação, o value-at-risk (VaR) representa intervalo de confiança dos resultados gerados na simulação. A base de dados gerada através das simulações pode ser então analisada através do valor máximo obtido de uma fração da base total, onde se excluem os valores extremos numa

proporção percentual determinada pelo VaR. Em resumo, se forem simulados 100 dados, e o VaR for igual a 99%, o resultado do VaR 99% será igual ao penúltimo maior valor simulado, ou seja, não será considerado os maiores valores que representem 1% dos dados da base.

4.6.7. Simulação de Monte Carlo: Resultados

A primeira simulação de resultados foi realizada com base nos parâmetros descritos anteriormente, a partir da base de dados de 1.687 perdas, com base na frequência quinzenal, para as quatro seguintes possibilidades de composição de distribuições de probabilidade:

- i. (A) Poisson (frequência) e LogNormal (severidade);
- ii. (B) Poisson (frequência) e Gama (severidade);
- iii. (C) Binomial Negativa (frequência) e LogNormal (severidade), e;
- iv. (D) Binomial Negativa (frequência) e LogNormal (Gama).

A simulação foi feita com base no cálculo de 1.000 VaR gerados a partir da simulação de 1.000 quinzenas, sendo que para cada quinzena foi simulada uma frequência e as respectivas severidades.

Com isto, a média dos 1.000 VaR para cada cenário gerou os seguintes resultados, conforme a tabela abaixo:

Tabela 12: Simulações de VaR a partir da Base de Dados Ajustada de 1.687 eventos

Distribuições / VaR	Original	(A)	(B)	(C)	(D)
VaR (99,0%)	3.300.000	25.793.542	45.207.298	15.805.192	35.254.622

O fato de haver um valor extremo de \$ 130.000.000 na série de dados original, mesmo dia de uma média de perdas de \$ 316.577 e uma distribuição que aponta a grande maior frequência de perdas de severidade inferiores a \$ 100.000, promoveu a possibilidade de realizar mais um ajuste na base de dados.

Ratificando esta necessidade, deve-se considerar que a base de dados está até então composta de 1.687 dados, o que não representa uma série tão extensa a ponto de mitigar os efeitos de algumas perdas tão díspares em relação à tendência central da série.

Desta forma, antes de serem tomadas maiores conclusões sobre a simulação, foram realizados novos ajustes na base de dados.

Em primeiro lugar foi criada uma variável aleatória uniforme para cada evento de perda, com valor igual a um ou zero. Desta forma, todos os dados que apresentavam variável zero formaram uma nova base de dados, enquanto que os demais, com valor um, formaram outra base de dados.

Adicionalmente, a base de dados foi reduzida para 97,5% dos dados, ou seja, 2,5% das informações foram excluídas, sendo 1,25% das maiores perdas e 1,25% das menores severidades.

Desta forma, a base de dados que formou a primeira série, com variáveis iguais a zero, gerou novos parâmetros para uma nova simulação, conforme as tabelas abaixo:

Tabela 13: Parâmetros da Frequência (Quinzenal)

Data	Valor
Média Aritmética	7,86
Variância	18,94

Tabela 14: Parâmetros da Severidade

Data	Valor
Média Aritmética	425.848
Desvio-Padrão	585.152
Variância	342.403.043.799
Média Aritmética do Ln(perda)	11,47
Desvio-Padrão do Ln(perda)	3,02

Para a geração dos resultados, cada simulação gerou 1.000 dados quinzenais, entre frequência e severidade de perdas. Ou seja, foram simulados 1.000 períodos quinzenais, sendo que para cada quinzena foi simulada uma quantidade de perdas, cada qual com uma severidade distinta.

Com base então nas quatro possibilidades de simulação admitidas no item anterior, foram obtidos os seguintes resultados:

Tabela 15: Simulações de VaR

Distribuições / VaR	Original	(A)	(B)	(C)	(D)
VaR (99,0%)	1.000.000	12.417.971	1.108.533	8.163.019	1.013.981
VaR (95,0%)	277.000	3.065.896	788.570	1.871.756	647.716
VaR (90,0%)	97.011	1.536.324	630.418	885.755	495.430

Os resultados acima denotam a baixa precisão das distribuições Log-normal para mensuração do VaR de perdas operacionais para a base de dados considerada. Desta forma, os dois cenários que consideravam a distribuição Log-normal para severidade, Poisson e Binomial Negativa, deixam de ser considerados para a análise seguinte, que buscará perceber para a distribuição Gama qual a melhor distribuição de frequência para mensuração do VaR.

Desta forma foi elaborado o histograma do VaR (99,0%) das perdas para os dois cenários restantes, conforme segue:

i. Poisson (frequência) e Gama (severidade)

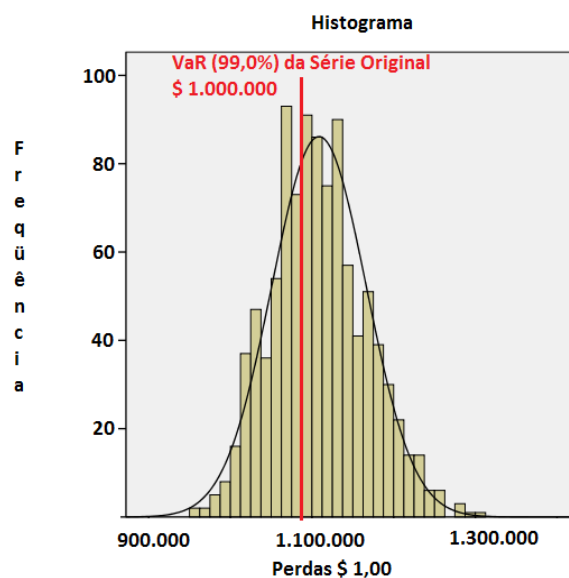


Figura 5 – Histograma das Perdas para Poisson e Gama

ii. Binomial Negativa (frequência) e LogNormal (Gama)

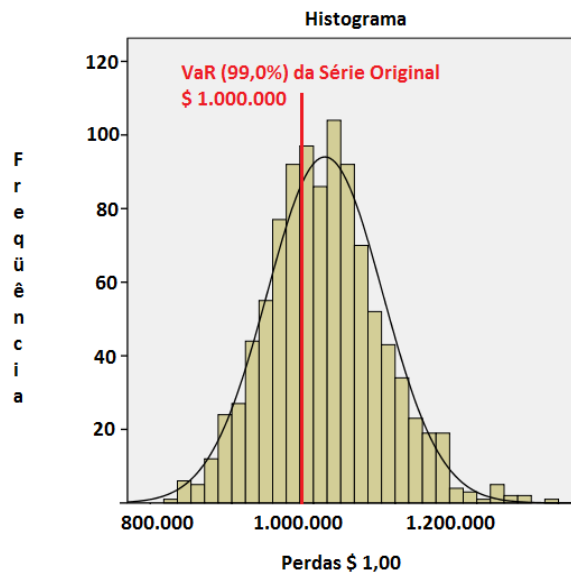


Figura 6 – Histograma das Perdas para Binomial Negativa e Gama

Os histogramas acima dão a noção de que o VaR 99,0% para as distribuições testadas (que apresentem Gama para severidade) aproximam-se do VaR da própria série de dados histórica que gerou os parâmetros.

Porém, para que se tenha um parâmetro mais preciso que indique qual dos dois cenários restantes apresenta mais precisão na estimação dos VaR de perdas operacionais, foi realizado um teste adicional que mensurou uma medida de dispersão média para todos os 1.000 VaR simulados para cada cenário.

O procedimento constituiu-se em calcular para cada VaR simulado a diferença entre este e o VaR histórico da série de dados que gerou os parâmetros, calculando-se por fim a média das dispersões para cada distribuição, o que gerou os resultados descritos na tabela abaixo, conforme segue:

Tabela 16: Dispersão média (VaR simulado (n) – VaR histórico)

Distribuições / VaR	Poisson e Gama	Bin. Neg. e Gama
VaR (99,0%)	108.533	13.981
VaR (95,0%)	511.571	370.716
VaR (90,0%)	533.407	398.420

Percebe-se, por fim, que a simulação para a série de dados estudada, a partir da distribuição Binomial Negativa para frequência e Gama para severidade apresentou menor

dispersão do que a combinação de Poisson e Gama, apresentando a mais alta precisão para o VaR com intervalo de confiança de 99,0% do que nos dois outros cenários de VaR (95,0% e 90,0%).

5. CONSIDERAÇÕES FINAIS

Este trabalho se iniciou na definição dos conceitos de risco operacional e dos modelos de mensuração de previsões de perdas atribuídas ao risco operacional, em especial o modelo avançado denominado LDA.

Posteriormente foi realizada a descrição do modelo LDA, bem como a definição dos conceitos utilizados por este modelo, como o método de simulação de Monte Carlo e o VaR.

Foram criados então algoritmos de geração de variáveis aleatórias, com base em distribuições teóricas de probabilidade (Poisson, Binomial Negativa, Log-Normal e Gama) para que pudesse ser realizada a simulação de perdas atribuídas ao risco operacional.

Com base em uma base de dados disponível, foi realizada a estimação dos parâmetros da distribuição de perdas da referida base de dados, para que se pudesse ser realizada a simulação de Monte Carlo que gerasse diversos VaR para distintos cenários de simulação, com o intuito de testar um programa desenvolvido com base nos conceitos da abordagem LDA.

Os resultados apontaram que as distribuições Binomial Negativa (para frequência de perdas) e Gama (para severidade) foram as mais precisas na determinação de VaR de perdas operacionais, com base na comparação dos resultados obtidos na simulação em relação aos VaR aferidos na base de dados utilizada para estimação dos parâmetros da simulação.

Porém, além de simplesmente provar que uma distribuição de probabilidade é mais oportuna que outra para determinadas condições, os resultados apontaram que se pode implementar um modelo LDA que possa compor uma ferramenta gerencial para desenvolvimento de estratégias relacionadas ao risco operacional de empresas. Um exemplo, dentre vários, seria a modelagem dos dados para determinada empresa e a execução de análises de sensibilidade que gerassem indicativos de quais áreas de uma empresa seriam mais relevantes para reduzir a exposição a riscos operacionais, de forma a impactar positivamente na redução da perda esperada a eventos relacionados a este risco operacional.

Deve-se considerar como limitações desta pesquisa a não utilização de modelos que analisassem as perdas de valores extremos, responsáveis pela redução da precisão do modelo, bem como as eventuais correlações existentes entre as perdas. Outra importante limitação desta pesquisa é a indisponibilidade de uma base de dados mais extensa e refinada, o que permitiria que o nível das análises pudessem ser incrementado através, por exemplo, da

simulação de valores para cada segmento da economia, cada tipo de empresa, cada tipo e subtipo de evento de perda ou qualquer outra forma de análise pretendida.

Deixo então como sugestão para incremento desta pesquisa em estudos futuros a elaboração de estudos que utilizem técnicas de mensuração da correlação entre eventos de perdas, bem como a utilização de Teoria de Valores Extremos ou outras teorias que possam analisar o impacto de perdas de valor elevado na alteração das distribuições de perdas para modelos LDA.

Adicionalmente, na medida em que haja disponibilidade de dados confiáveis e de maior nível de detalhamento, cabe também a sugestão para estudos futuros que comparem o comportamento da perda atribuída ao risco operacional nos diversos níveis de detalhamento possíveis. Por exemplo, pode-se vir a testar a hipótese de que o volume de perdas operacionais esteja relacionado também a aspectos organizacionais entre distintas empresas de um mesmo segmento, ou mesmo outra hipótese de que uma empresa financeira tenha perdas esperadas atribuídas ao risco operacional em maior intensidade do que empresas não-financeiras.

6. REFERÊNCIAS

- AFAMBO, E. F. **Operational risk capital provisions for banks and insurance companies**, 2006, 165 p., Ph.D., Georgia State University. Georgia
- AYADI, R. Solvency II: A Revolution for Regulating European Insurance and Re-insurance Companies. **Journal of Insurance Regulation**. v. 26, n. 1, p. 11, 2007
- BAUD, N.; FRACHOT, A.; RONCALLI, T. Internal data, external data and consortium data for operational risk measurement: How to pool data properly? **Crédit Lyonnais**, Paris, 2002
- BCBS – Basel Committee on Banking Supervision (2003). **Sound practices for the management and supervision of operational risk**, Disponível em: <<http://www.Bis.Org/publ/bcbs96.Htm>>. Acesso em 10 dez.2009, 16:00:00
- BREDNIKHIN, S., MEDVEDEV, I., e MIKHAILOV, G. Estimation of the criticality parameters of branching processes by the Monte Carlo method. **Computational Mathematics and Mathematical Physics**, p. 345-356, 2010
- CHAVEZ-DEMOULIN, V.; EMBRECHTS, P. Advanced extremal models for operational risk. **Department of mathematics ETH-Zentrum**. Zurich, 2004
- CROUHY, M.; GALAI, D.; MARK, R. **Gerenciamento de Risco: Abordagem Conceitual e Prática: Uma Visão Integrada dos Riscos de Crédito, Operacional e de Mercado**. Rio de Janeiro: Qualitymark, São Paulo: SERASA, 2004.
- CRUZ, M. G. **Modeling, Measuring and Hedging Operational Risk**. West Sussex: Wiley Finance, 2002
- DOFF, R. A Critical Analysis of the Solvency II Proposals. **Geneva Papers on Risk & Insurance**. Basingstoke: v. 33, n. 2, p. 193, 2008
- DUTTA, K. e PERRY, J., A Tale of Tails: An Empirical Analysis of Loss Distribution Models for Estimating Operational Risk Capital. **FRB of Boston Working Paper No. 06-13**. Disponível em SSRN: <http://ssrn.com/abstract=918880>
- EHRENTREICH, N. **Agent-Based Modeling**. New York: Springer-Verlag, 2007
- ELING, M.; SCHMEISER, H.; SCHMIT, T. J. The Solvency II Process: Overview and Critical Analysis. **Risk Management and Insurance Review**. Mount Vernon: v. 10, n. 1, p. 69, 2007
- EMBRECHTS, P., FURRER, H., KAUFMANN, R. Quantifying regulatory capital for operational risk. **Derivatives Use, Trading & Regulation**, London, v. 9. n. 3, p. 217, 2003

- EMBRECHTS, P.; KAUFMANN, R.; SAMORODNITSKY, G. Ruin theory revisited: Stochastic models for operational risk. **Risk Management for Central Bank Foreign Reserves**: 243-26, 2004
- FITCH RISK MANAGEMENT. **Fitch sees hitch in Basel operational risk rules**. Londres, abr.2004. <<http://www.financialexpress.com/news/fitch-sees-hitch-in-basel-operational-risk-rules/103362/>>. Acesso em: 10 dez.2009
- FONTNOUVELLE, P.; DEJESUS-RUEFF, V.; JORDAN, J.; ROSENGREN, E. Capital and risk: New evidence on implications of large operational losses. **Federal Reserve Bank of Boston**, 2003
- FRACHOT, A.; GEORGES, P.; RONCALLI, T. Loss Distribution Approach for operational risk. **Crédit Lyonnais**, France, 2001
- FRACHOT, A.; RONCALLY, T. Mixing internal and external data for managing operational risk. **Crédit Lyonnais**, France, 2002
- FRACHOT, A.; MOUDOULAUD, O.; RONCALLI, T. Loss Distribution Approach in Practice. **Handbook: A Guide for Financial Practitioners**, editado por Micheal Ong, Risk Books, 2003
- FRACHOT, A.; RONCALLI, T.; SALOMON, E. The Correlation Problem in Operational Risk. **Risk's Newsletter**, 2004. Disponível em: <<http://ssrn.com/abstract=1032594>>. Acesso em 8 dez.2009, 18:00:00
- GIACOMETTI, R., RACHEV, S. T., CHERNOBAI, A. e BERTOCCHI, M. Aggregation Issues in Operational Risk. **Journal of Operational Risk**, 3(3), pp. 3-23, 2008.
- GLASSERMAN, P. (2003). **Monte Carlo methods in financial engineering**. Springer-Verlag. ISBN 0-387-00451-3.
- GOURIER, E.; FARKAS, W.; ABBATE, D. Operational risk quantification using extreme value theory and copulas: from theory to practice. **The Journal of Operational Risk**, London, v. 4, n. 3, p. 3, 2009
- HOFFMAN, D. G. **Managing Operational Risk**. New York: Wiley Finance, 2002
- HOLSBOER, J. H. The Impact of Low Interest Rates on Insurers. **Geneva Papers on Risk and Insurance**, 2000
- JOBST, A. A. It's all in the data – consistent operational risk measurement and regulation. **International Monetary Fund, Monetary and Capital Markets Department (MCM)**, Washington, 2007

- KOJADINOVIC, I., & YAN, J. Comparison of three semiparametric methods for estimating dependence parameters in copula models. **Insurance, Mathematics & Economics**, p. 52, 2010.
- KHINDANOVA, I., RACHEV, S. **Value at Risk: Recent Advances**. Em: G. Anastassiou (ed) Handbook of Analytic-Computational Methods in Applied Mathematics, 801-858. Boca Raton, FL: CRC Press. 2000
- KLUGMAN, S., PANJER, H. e WILLMOT, G. (2004). **“Loss Models: from Data to Decisions”**. 2nd ed. John Wiley & Sons.
- KUHN, R.; NEU, P. Functional correlation approach to operational risk in banking organizations. **Physica A**. v. 322, p. 650-666, 2003
- LAI, Y., **The Monte Carlo and Quasi-Monte Carlo Methods and Their Applications**, Ph. D Dissertation, Claremont Graduate University, California, USA, 2000
- LUAN, D.. **Computational modeling and simulation of thrombus formation**. Ph.D. dissertation, Cornell University, United States -- New York. Retrieved June 17, 2010, from Dissertations & Theses: Full Text.(Publication No. AAT 3376617).
- MANNING, S.; GURNEY, A. Operational risk within an insurance market. **Journal of Financial Regulation and Compliance**, v. 13, n. 4, p. 293, 2005
- MENDES, J. M. **Modelo de Previsão de Perdas por Risco Operacional Utilizando Séries Temporais**, 2006. 117 p. Dissertação (Mestrado em Economia do Setor Público). Departamento de Economia da Universidade de Brasília. Brasília.
- MCCARTHY, **“Monte Carlo Simulation: Still Stuck in Low Gear,”** Journal of Financial Planning, January 2000, Vol. 13, No. 1 pp. 54–60.
- MCNEIL, A. J.; FREY, R.; EMBRECHTS, P. **Quantitative Risk Management**. New Jersey: Princeton University Press, 2005
- MOOSA, I. A. **Operational Risk Management**. New York: Palgrave Macmillan, 2007
- NAYLOR, T. H., BALINTFY, J. L., BURDICK, D. S., AND CHU, K. **Computer Simulation Techniques**. John Wiley & Sons, New York, 1966.
- NAWROCKI, D. The problems with Monte Carlo simulation. **Financial Planning Association Journal**. 26(11), p. 183-193, 2001
- NEIL, M.; HÄGER, D.; ANDERSEN, L. B. Modeling operational risk in financial institutions using hybrid dynamic Bayesian networks. **The Journal of Operational Risk**. London, v. 4, n. 1, p. 3, 2009
- NESLEHOVA, J.; EMBRECHTS, P.; CHAVEZ-DEMOULIN, V. Infinite Mean Models and the LDA for Operational Risk. **Department of mathematics ETH-Zentrum**. Zurich, 2006

- O'BRIEN, C. Modernizing Insurance Solvency Regulation: **Evidence from the UK. Journal of Insurance Regulation**. v. 26, n. 1, p. 41, 2006
- OKTEN, G., **Contributions to the theory of Monte Carlo and Quasi-Monte Carlo Methods**, Ph.D. Dissertation, Claremont Graduate School, California, 1997.
- PHILIPPATOS, G. C. **Financial Management: Theory and Techniques** (San Francisco: Holden Day, 1973).
- ROBERT, C. P., CASELLA, G. **Monte Carlo Statistical Methods**. 2nd ed. 2004. Corr. 2nd printing, 2004, XXX, 645 p. 132 illus., Hardcover ISBN: 978-0-387-21239-5
- ROSENBLAD, A. **Randomization, bootstrap and Monte Carlo methods in biology**, third edition :Chapman & Hall/CRC, Boca Raton, FL, 2009
- RUBINSTEIN, R.Y.: **"Simulation and the Monte Carlo Method"**. John Wiley & Sons, Inc., 1981, 278 pp.
- SANABRIA, L., & CECHET, R. Severe Wind Hazard Assessment using Monte Carlo Simulation. **Environmental Modeling & Assessment**, p. 147-154, 2010
- SILVA, J. V. M. **Modelagem Estocástica em Risco Operacional Aplicando a Teoria dos Valores Extremos**, 2006. 73 p. Dissertação (Mestrado em Economia do Setor Público). Departamento de Economia da Universidade de Brasília. Brasília.
- SUNDMACHER, Maïke and FORD, Guy, **When Statistics Fail: Extreme Events in Financial Institutions (2004)**. Available at SSRN: <http://ssrn.com/abstract=963240>
- TRIPP, M. H.; BRADLEY, H. L.; DEVITT, R.; ORROS, G. C.; OVERTON, G. L.; PRYOR, L. M.; SHAW, R. A. **Quantifying operational risk in general insurance companies**. In: Institute of Actuaries, 2004
- WANG, L.. **Computational studies of quantum spin systems. Ph.D. dissertation**, Boston University, United States – Massachusetts, 2010

APÊNDICE

Soluções de Sistemas para Distribuições de Frequência e Severidade.

Para as afirmações abaixo, considera-se que o valor esperado $E[X]$ seja igual à média de cada distribuição, bem como $Var(X)$ e $\sigma(X)$ iguais a variância e desvio-padrão, respectivamente.

1.1. Distribuição de Frequência - Poisson:

Parâmetros: λ .

$$E[X] = \lambda$$

1.2. Distribuição de Frequência - Binomial Negativa:

Parâmetros: r e p .

$$E[X] = \frac{r}{p}$$

$$Var(X) = \frac{r * (1 - p)}{p^2}$$

Deduções:

$$r = E[X] * p$$

(...)

$$Var(X) = E[X] * p * \frac{1 - p}{p^2}$$

$$\frac{Var(X)}{E[X]} = p * \frac{1 - p}{p^2}$$

$$\frac{Var(X)}{E[X]} = \frac{1 - p}{p}$$

$$p * \frac{Var(X)}{E[X]} = 1 - p$$

$$p + \left(p * \frac{Var(X)}{E[X]} \right) = 1$$

$$p * \left(1 + \frac{Var(X)}{E[X]} \right) = 1$$

$$p = \frac{1}{\left(1 + \frac{Var(X)}{E[X]} \right)}$$

Solução Binomial Negativa:

$$r = E[X] * p$$

$$p = \frac{1}{\left(1 + \frac{Var(X)}{E[X]} \right)}$$

1.3. Distribuição de Severidade - LogNormal:

Parâmetros: $E[X]$ e $\sigma(X)$.

Observação: Admitindo cada variável de perda X , a média e o desvio padrão devem ser calculados sobre os logaritmos $\ln(X)$.

$$E[X] = \text{média}$$

$$\sigma(X) = \text{desvio - padrão}$$

1.4. Distribuição de Severidade - Gama:

Parâmetros: α e β .

$$E[X] = \frac{\alpha}{\beta}$$

$$\text{Var}(X) = \frac{\alpha}{\beta^2}$$

Deduções:

$$\alpha = \beta * E[X]$$

(...)

$$\text{Var}(X) = \frac{\beta * E[X]}{\beta^2}$$

$$\beta^2 = \frac{\beta * E[X]}{\text{Var}(X)}$$

$$\frac{\beta^2}{\beta} = \frac{E[X]}{\text{Var}(X)}$$

$$\beta = \frac{E[X]}{\text{Var}(X)}$$

Descrições dos dados disponibilizados pelo endereço eletrônico <http://datalossdb.org/>

Perdas

Short Name	Description
CCN	Credit Card Numbers
SSN	Social Security Numbers (or Non-US Equivalent)
NAA	Names and/or Addresses
EMA	Email Addresses
MISC	Miscellaneous
MED	Medical
ACC	Account Information (Financial)
DOB	Date of Birth
FIN	Financial Information

Subtipo das Perdas

Short Name	Description
Disposal Computer	Discovery of computers not disposed of properly
Disposal Document	Discovery of documents not disposed of properly
Disposal Tape	Discovery of backup tapes not disposed of properly
Disposal Drive	Discovery of disk drives not disposed of properly
Email	Email communication exposed to unintended third party
Fraud Se	Fraud or scam (usually insider-related), social engineering
Hack	Computer-based intrusion, data not generally publically exposed
Lost Computer	Lost computer (unspecified type in media reports)
Lost Document	Discovery of documents not disposed of properly through loss (not theft)
Lost Drive	Lost data drive, unspecified if IDE, SCSI, thumb drive, etc)
Lost Laptop	Lost laptop (generally specified as a laptop in media reports)
Lost Media	Media (i.e. disks) reported to have been lost by a third party
Lost Tape	Lost backup tapes
Missing Laptop	Missing laptop, unknown or disputed whether lost or stolen
Snail Mail	Personal information in "snail mail" exposed to unintended third party
Stolen Computer	Stolen desktop (or unspecified computer type in media reports)
Stolen Document	Documents either reported or known to have been stolen by a third party
Stolen Drive	Stolen data drive, unspecified if IDE, SCSI, thumb drive, etc)
Stolen Laptop	Stolen Laptop (generally specified as a laptop in media reports)
Stolen Media	Media (disks or other) generally reported or known to have been stolen by a third party
Stolen Tape	Stolen backup tapes
Unknown	Unknown or unreported breach type
Virus	Exposure to personal information via virus or trojan (i.e. keystroke logger, possibly classified as hack)
Web	Computer/web-based intrusion, data typically available to the general public via search engines, public pages, etc.

Setores

Short Name	Description
Biz	Business
Edu	Educational
Gov	Government
Med	Medical

Subtipo dos Setores

Short Name	Description
Retail	Retail Businesses
Fin	Financial
Tech	Technology
Med	Medical (Non-Hospital / Provider)
Fed	Federal Government
Data	Data Services / Brokerage
Media	Mass Media
Uni	University
Ind	Industry
State	State Government
NFP	Non-Profit / Not-For-Profit
County	County Government
Org	Organization
Hos	Hospital
HS	High School
Ins	Insurance
City	City (Government or Citizens)
Hotel	Hotel
Law	Legal Firm
Elem	Elementary School
Edu	Educational
Biz	Business
Gov	Government
Pro	Medical Provider
Agr	Agricultural