Revista Brasileira de
Risco e Seguro

Insolvência Financeira de Operadoras de Planos de Saúde: uma Investigação Empírica

Sandro Leal Alves
Da Universidade Santa Úrsula e da Diretoria de Saúde da FENASEG
sandroleal@fenaseg.org.br

Resumo

Este estudo examina empiricamente a relação entre variáveis econômico-financeiras e outras características específicas de operadoras de planos de saúde, e o risco de insolvência financeira. Utiliza alguns dos principais Modelos de Previsão de Insolvência, recomendados pela literatura especializada: Regressão Logística, Análise Discriminante Multivariada e Redes Neurais. Testamos, adicionalmente, a viabilidade de utilização do Índice de Desempenho Econômico-Financeiro, utilizado pela Agência Nacional de Saúde Suplementar, como possível preditor de insolvência. A amostra é baseada nos demonstrativos financeiros anuais do período de 2001 até 2004 de operadoras solventes e insolventes. A evidência empírica sugere que o risco de insolvência está associado aos baixos níveis de capital e a ausência de reservas técnicas nos dois anos anteriores à ocorrência do evento.

Palavras-Chave

Modelos de Previsão de Insolvência; mercado de saúde suplementar; risco de insolvência.

Sumário

1. Introdução; 2. Importância da identificação de operadoras insolventes; 2.1. Regulares; 2.2. Consumidores; 2.3. Prestadores de serviços; 2.4. Corretores; 3. Modelos de previsão de insolvência; 3.1. Análise Discriminante Multivariada (ADM); 3.2. Regressão logística; 3.3. Redes neurais; 4. Estratégia empírica; 4.1. Desenho da amostra; 4.2. Seleção de indicadores econômico-financeiros e demais co-variáveis; 4.3. Modelos utilizados ; 4.4. Índice de Desempenho Econômico-Financeiro da ANS ; 5. Resultados; 6. Conclusões. 7. Referências bibliográficas; 8. Anexos.

Abstract

Financial insolvency of health plans organizations: an empirical investigation

Sandro Leal Alves
Santa Ursula University and Directory of Health at FENASEG (National Federation of Insurance and Capitalization Companies)
sandroleal@fenaseg.org.br

Summary

This study provides an empirical examination of the relationship between financial ratios and other firm-specific characteristics and the insolvency risk. The study uses some of the main Early Warning Models recommended by specialized literature: Logistic Regression, Multivariate Discriminant Analysis and Neural Network. We have tested, in addition, the viability of using the Financial Performance Index developed by the National Agency of Supplementary Health to predict insolvency problems. The sample is based on annual financial statements between 2001 through 2004 to both solvent and insolvent health plans companies. The empirical evidence suggests that the insolvency risk is associated with the low levels of capital and reserves two years priors to the occurrence of the event.

Keywords

Early warning models; supplementary health plans market; insolvency risk.

Table of Contents

Introduction; 2. The importance of identifying insolvent companies; 2.1. Regularly operating companies; 2.2. Consumers; 2.3. Outsourcers; 2.4. Brokers; 3. Insolvency prediction models; 3.1. Multivariable Discrimination Analysis (MDA); 3.2. Logistic regression; 3.3. Neural networks; 4. Empirical strategy; 4.1. Sample design; 4.2. Selection of financial and economic indicators and of other co-variables; 4.3. Employed models; 4.4. ANS's (National Supplementary Health Agency) Economic and Financial Performance Index; 5. Findings; 6. Conclusions. 7. References; 8. Appendices.

1. Introdução

A condição financeira das Operadoras de Planos de Saúde tem sido alvo de crescentes preocupações por parte de diversos agentes da sociedade, principalmente no período pós regulatório, onde a tarefa de zelar pela solvência das empresas passou a integrar o conjunto de atribuições do órgão regulador, a Agência Nacional de Saúde Suplementar (ANS). A insolvência recente de grandes operadoras, como a Unimed São Paulo, a Interclínicas e a Adress, chama atenção pelo número de beneficiários que passaram a não ter cobertura assistencial, tendo em vista a ausência de reservas técnicas por parte destas empresas, cabendo ao Estado conduzir o difícil processo de transferência compulsória de carteiras naturalmente acometidas pela anti-seleção. Insolvências dessa magnitude, aliadas ao elevado índice de descumprimento de requerimentos prudenciais[1] e ao alongamento da constituição das provisões técnicas condicionalmente à execução de programas de prevenção[2], sugerem a necessidade de um novo exame do perfil de risco das operadoras neste mercado.

Com exceção das seguradoras especializadas em saúde, as demais modalidades de operadoras[3] nunca estiveram sujeitas às regras de solvência, ainda que operassem em um setor cuja principal função está na diluição de riscos independentes pelo sistema de mutualismo e a administração de recursos de terceiros com o subseqüente pagamento das indenizações em caso de sinistro (utilização do seguro ou plano de saúde). Diante desse contexto, o estabelecimento e a fiscalização do cumprimento das regras prudenciais são condições necessárias à manutenção da estabilidade econômico-financeira do setor, mas não são suficientes. Outros desenhos institucionais têm auxiliado os reguladores no exercício da atividade de zelar pela solvência do mercado. Exemplos dessas atividades auxiliares são o acompanhamento econômico-financeiro das empresas, exigências de auditorias regulares e a avaliação das empresas por agências classificadoras de risco. Não obstante a importância desses mecanismos auxiliares, poucos trabalhos acadêmicos têm se dedicado à determinação de um arcabouço mais eficiente para o acompanhamento econômico-financeiro das operadoras de planos. Dentre os desenvolvimentos metodológicos nessa linha de pesquisa, destacam-se os Modelos de Previsão de Insolvência (MPI) que procuram identificar, *a priori*, empresas mais vulneráveis a partir de um conjunto de características, sejam elas econômico-financeiras ou institucionais.

A utilização desses tipos de modelos permite ao órgão regulador, ou mesmo aos demais interessados na solvência da empresa, antecipar-se aos efeitos econômicos adversos oriundos de um processo de

[1] Atualmente, 284 operadoras não cumprem os requerimentos de capital mínimo e provisões técnicas segundo a ANS. Isto representa cerca de 24% do setor, onde 1.200 empresas estão regularmente operando.

[2] A Resolução Normativa nº 94, de 24 de março de 2005, passou a incentivar a adoção de programas de promoção à saúde e prevenção de doenças, oferecendo o alargamento do prazo que as operadoras têm para providenciar suas coberturas das provisões de risco. Vale ressaltar que a literatura sobre solvência não registra uma redução no risco de *default* relacionado a investimentos preventivos.

[3] As operadoras das modalidades de Medicinas de Grupo, Cooperativas Médicas, Cooperativas Odontológicas, Autogestão, Odontologias de Grupo, Filantropias e Administradoras foram submetidas às regras de capital mínimo e provisão de risco pela RDC nº 77 de 2001, cujos requerimentos variam positivamente em relação ao nível de risco da operação, assumido menor quanto maior for a rede própria da operadora, e assumido maior quanto mais abrangente for a região de atuação da empresa.

insolvência, dando tempo hábil para a tomada de decisões. O objetivo do presente estudo é apresentar algumas alternativas ao acompanhamento regulatório atual, baseado em indicadores utilizados não apenas na literatura de finanças, mas, principalmente, na literatura de solvência de companhias seguradoras. Na segunda seção deste estudo apresentaremos a importância da identificação antecipada de *default* neste mercado. Na terceira parte, descreveremos a estratégia empírica utilizada e os principais modelos utilizados para trabalhos desta natureza, especificamente o modelo Logit, a análise discriminante multivariada e o modelo de redes neurais. A quarta parte apresenta os principais resultados e a última seção apresenta as conclusões mais relevantes obtidas neste estudo.

2. Importância da identificação de operadoras insolventes

A detecção antecipada de problemas de solvência de operadoras de planos de saúde é importante para diversos agentes deste mercado, incluindo reguladores, consumidores, prestadores de serviços e corretores. Vejamos resumidamente cada um desses casos:

2.1. Reguladores

A proteção dos consumidores de planos de saúde das potenciais perdas associadas à insolvência de uma operadora é tida como o objetivo básico da regulação deste mercado. A importância de se antecipar situações financeiras adversas tem a ver com o *timing* de se utilizar medidas saneadoras tais como a exigência de planos de recuperação econômico-financeira ou intervenções mais diretas como as direções fiscais e liquidações extrajudiciais. Baird and Morrison (1999) mostram, a partir de um modelo de opções reais, que existe elevado custo econômico em se postergar determinada intervenção, mas uma vez realizada, existem, por outro lado, alguns ativos específicos da firma, incluindo o capital humano, que são perdidos para sempre. O *timing* de atuação do órgão regulador é, por sua vez, uma função da quantidade e da qualidade das informações disponíveis e de sua respectiva capacidade de análise. Portanto, existe certamente uma quantidade ótima de informações, em que recursos escassos devem ser direcionados na sua aquisição, que minimize o custo total de uma intervenção. Nesse sentido, os reguladores deveriam sempre avaliar o *payoff* social entre uma intervenção imediata, em uma operadora, com um volume limitado de informações, ou uma intervenção defasada, porém com mais informações.

A literatura de previsão de insolvência procura preencher esta lacuna propiciando maior capacidade de avaliação de empresas a partir de um conjunto de indicadores estatisticamente significativos na determinação de seu sucesso ou fracasso. As demais variáveis deveriam ser analisadas concomitantemente a partir de um diagnóstico preciso e rápido. Diversos mercados regulados já se valem de análises geradas por essa família de modelos. Como atestam Jagtiani, Kolari, and Shin, H. (2003), para o mercado bancário americano:

> "Supervisors use the output from these monitoring or early warning system (EWS) models to determine which organizations need increased supervisory scrutiny, identify specific areas of concern, accelerate on-site examinations of institutions showing financial deterioration, and allocate more experienced or more specialized examiners to institutions with financial problems."

Fundamentalmente, a identificação prévia de problemas financeiros permitiria que a ANS utilizasse medidas saneadoras em tempo hábil para minimizar os custos de uma insolvência extrajudicial.

2.2. Consumidores

Existe elevada assimetria na informação entre o consumidor de plano de saúde e a sua operadora em relação à capacidade financeira desta última em honrar os compromissos assumidos. O custo de aquisição de informação relevante sobre a solvência da operadora é muito elevado tendo em vista a quantidade de operadoras e a pouca intimidade com a análise de balanços. Diante dessa situação, o consumidor se vale muitas vezes da reputação da empresa escolhida como forma de reduzir o seu esforço. A tarefa da regulação prudencial e do acompanhamento econômico-financeiro do mercado tem características de um bem público, e por isso é tradicionalmente delegada ao Estado. Daí a importância de se antecipar situações financeiras adversas que possam provocar perdas econômicas aos consumidores.

2.3. Prestadores de serviços

Dada a elevada interdependência entre os agentes neste setor, a insolvência de uma operadora pode ter efeitos sobre os demais participantes do mercado, como hospitais, laboratórios, clínicas, médicos e dentistas. Portanto, é de interesse dos prestadores de serviço o conhecimento antecipado de problemas de solvência no futuro.

2.4. Corretores

Os corretores de planos de saúde são agentes dos consumidores na medida em que os orientam na aquisição, na manutenção ou na substituição de um plano de saúde. Conhecer a capacidade financeira das empresas reduz enormemente os riscos associados do processo e possibilita que o corretor seja um agente mais bem informado e, portanto, mais eficiente em sua atuação no mercado.

3. Modelos de previsão de insolvência

A preocupação acadêmica com a identificação de indícios ou sinais de insolvência é relativamente conhecida na literatura financeira. O trabalho de Altman (1968) é considerado o texto inicial sobre a utilização de análise discriminante multivariada na previsão de insolvência de empresas onde o vetor de variáveis explicativas era constituído de indicadores econômico-financeiros. Entretanto, a simples utilização de modelos de previsão de insolvência de empresas não seguradoras para o mercado segurador não parece ser uma tarefa tão simples quanto se imagina, tendo em vista as diferenças existentes entre essas atividades econômicas, principalmente na questão do risco. Especificamente, se uma empresa não seguradora vai à bancarrota, a perda econômica dos seus consumidores pode ser pouco significativa, sendo restrita no máximo ao valor do produto ou serviço comprado. Diferentemente, no caso de insolvência de uma seguradora, ou uma operadora de plano de saúde, os consumidores não sofrerão apenas a perda dos prêmios ou mensalidades já efetuados, mas poderão incorrer em perdas associadas à ocorrência dos eventos adversos cuja proteção foi viabilizada através do seguro, mas, entretanto, a garantia de indenização anteriormente paga não será honrada.

Diversas são as causas que podem levar uma operadora de planos de saúde à insolvência, por exemplo, uma inadequada política de aceitação de riscos ou de precificação, excessiva alavancagem financeira, baixa diversificação e qualidade de ativos garantidores ou problemas associados ao descasamento entre ativos e passivos. No caso brasileiro, especificamente, o ambiente regulatório tem sido bastante restritivo ao desenvolvimento do mercado devido à política de reajuste de preços dos planos individuais não acompanhar o crescimento das coberturas obrigatórias e da própria dinâmica de formação de preços neste setor. Entretanto, a utilização dos MPI's procura simplesmente identificar a situação financeira de uma empresa a partir de uma análise comparativa entre empresas que foram à insolvência e aquelas que permaneceram solventes ao longo do período analisado. Não se pretende determinar as causas da ocorrência do fenômeno. Essas estão relacionadas a outras variáveis de mercado como a concorrência, variáveis macroeconômicas e os efeitos da intervenção do Estado no ambiente de mercado. Não obstante, alguns autores como Browne, Carson and Hoyt (1999) procuram se valer dos modelos MPI para determinar o efeito destas demais variáveis, exógenas ao controle do empresário, sobre o risco de *default*.

No Brasil, os modelos do tipo MPI vêm sendo desenvolvidos para o mercado bancário[4] e, mais recentemente, alguns pesquisadores começaram a trabalhar nessa linha de pesquisa no mercado de saúde suplementar, como Alves (2004) e Serra (2005). A vantagem particular da utilização neste mercado específico é o grande número de operadoras reguladas, o que reduziria enormemente o custo da regulação. Atualmente, a forma de atuação econômico-financeira da ANS no mercado de saúde suplementar se dá tanto a partir de um conjunto de indicadores contábeis (liquidez, endividamento, sinistralidade, combinado, combinado ampliado e rentabilidade), onde as operadoras são classificadas a partir de intervalos pré-determinados e escolhidos de forma *ad-hoc*, bem como a partir de denúncias de irregularidades. A crítica a esse tipo de desenho é que ele não considera a interdependência entre os indicadores, a escolha dos intervalos é arbitrária e a metodologia não é capaz de sinalizar antecipadamente problemas de insolvência, como alerta Carson (1994).

Existem diversos modelos de previsão de insolvência. Para fins desta análise vamos nos concentrar nos modelos de análise discriminante multivariada, regressão logística e redes neurais.

3.1. Análise Discriminante Multivariada (ADM)

A ADM associa uma observação, mensurada por um vetor de variáveis, a um grupo particular de empresas previamente escolhidas (solventes ou insolventes), enquanto minimiza a taxa de erros de classificação. Sejam Π_1 e Π_2 dois grupos exclusivos entre si, de tal forma que se deseja determinar um mecanismo que melhor discrimine os dois grupos. Sendo n_1 o número de observações de um vetor de variáveis aleatórias $X^T = [x_1, x_2, ..., x_p]$ para Π_1 e n_2 o número de observações de X^T para Π_2, temos as seguintes matrizes de dados:

$$X_1 = [x_{11}, x_{12}, ..., x_{1n1}]_{(pxn1);} \text{ e}$$
$$X_2 = [x_{21}, x_{22}, ..., x_{2n2}]_{(pxn2);}$$

[4] Veja por exemplo Janot (2001).

Os vetores de médias amostrais e as matrizes de covariância amostrais são dados por:

$$\overline{X_1} = \frac{1}{n_1}\sum_{j=1}^{n_1} x_{1j} \ ;$$

$$\overline{X_2} = \frac{1}{n_2}\sum_{j=1}^{n_2} x_{2j} \ ;$$

$$S_1 = \frac{1}{n_1 - 1}\sum_{j=1}^{n_1}(x_{1j} - \overline{X_1})(x_{1j} - \overline{X_1})^T \ ;$$

$$S_2 = \frac{1}{n_2 - 1}\sum_{j=1}^{n_2}(x_{2j} - \overline{X_2})(x_{2j} - \overline{X_2})^T$$

Sendo as matrizes populacionais dos grupos desconhecidas e supostas iguais ($\Sigma 1 = \Sigma 2 = \Sigma$), então o estimador não viesado de Σ é uma combinação de S1 e S2 e é obtido da seguinte forma:

$$S_{pooled} = \left[\frac{n_1 - 1}{(n_1 - 1) + (n_2 - 1)}\right] S_1 + \left[\frac{n_2 - 1}{(n_1 - 1) + (n_2 - 1)}\right] S_2$$

A função discriminante linear de Fisher pode ser escrita da seguinte forma:

$$Z = (\overline{X_1} - \overline{X_2})^T S^{-1}{}_{pooled} X$$

E o ponto crítico é dado por:

$$\hat{m} = \frac{1}{2}(\overline{X_1} - \overline{X_2})^T S^{-1}_{pooled}(\overline{X_1} + \overline{X}_2)$$

A regra de classificação da função discriminante de Fisher deriva das seguintes condições:

Alocar X_0 em Π_1 se $Z_0 - \hat{m} \geq 0$ ou,

Alocar X_0 em Π_2 se $Z_0 - \hat{m} < 0$

Finalmente, o modelo de análise discriminante de Fisher pode ser descrito da forma linear como segue:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + ... + \beta_p X_p$$

Onde:
Y é a variável dependente dicotômica e assume os valores 0, quando a operadora é solvente e 1, quando é insolvente.

$\beta_0 = -\hat{m}$; é ponto crítico;
$\beta_{i's}$ são os coeficientes que indicam a importância relativa de cada indicador considerado;
$X_{i's}$ são as variáveis explicativas constituídas por índices financeiros e variáveis institucionais.

A regra de decisão onde são classificadas as operadoras solventes e as insolventes é definida pelo modelo da seguinte maneira: determinada operadora, com o vetor de características x_k, será alocada no grupo das operadoras insolventes se $Y_k \geq 0$; e no grupo das solventes, caso contrário. Uma particularidade dos modelos de ADM é a necessidade de normalidade multivariada dos vetores explicativos e da igualdade de matrizes de variância entre os grupos.

3.2. Regressão logística[5]

O modelo Logit é baseado na função de probabilidade cumulativa logística, especificada da seguinte forma:

$$P_i = F(Z_i) = F(\alpha + \beta X_i) = \frac{1}{1+e^{-Z_i}} = \frac{1}{1+e^{-(\alpha+\beta X_i)}}$$

onde:
e representa a base do logaritmo natural;
P_i é a probabilidade da operadora estar insolvente;
Xi são os vetores de variáveis explicativas (índices financeiros e variáveis institucionais);

Para mostrar como o modelo acima descrito poderá ser estimado, podemos multiplicar ambos os lados da equação por $1 + e^{-Zi}$, e obtermos:

$$(1 + e^{-Zi})\, P_i = 1$$

Dividindo por P_i e subtraindo de 1, temos:

$$e^{-Zi} = 1/P_i - 1 = (1 - P_i)/P_i$$

Como, por definição, $e^{-Zi} = 1/e^{Zi}$ então, temos que:

$$e^{Zi} = P_i / (1 - P_i)$$

[5] Esta seção está baseada em Pindyck and Rubinfeld (1998).

tomando os logaritmos naturais de ambos os lados, temos:

$$Z_i = \log \frac{P_i}{1 - Pi}$$

Ou então:

$$\log \frac{P_i}{1 - Pi} = Z_i = \alpha + \beta X_i$$

A variável dependente na equação de regressão é o logaritmo da chance de ocorrência de determinado evento (odds), solvência ou insolvência.

3.3. Redes neurais[6]

Inspiradas na estrutura neurológica do cérebro humano, uma família de modelos matemáticos conhecidos como redes neurais tem sido desenvolvida e aplicada em estudos de previsão de insolvência bancária e na indústria de seguros. Esta abordagem metodológica inclui alguns aspectos de inteligência artificial como o aprendizado a partir da experiência, a generalização a partir de exemplos e a utilização da essência de dados que possam conter informações não relevantes. Estruturalmente, o modelo de redes neurais pode ser representado como uma interconexão de várias unidades autônomas e possuem um comportamento similar, sob certos aspectos, ao funcionamento dos neurônios do cérebro humano.

Resumidamente, o algoritmo classificador das redes neurais implementa um método não paramétrico para classificar as observações em um de g grupos baseados nas p variáveis quantitativas observadas. Ao invés de estabelecer hipóteses sobre a distribuição de probabilidades das variáveis em cada grupo, o algoritmo constrói uma estimativa não paramétrica da função de densidade de cada grupo baseada em observações próximas ou na vizinhança de cada grupo. As estimativas são construídas usando uma janela de Parzen que pondera as observações de cada grupo de acordo com as suas distâncias da localização desejada. O diagrama abaixo, obtido de Statgraphics (2005), representa a forma básica das redes neurais. A rede contém quatro camadas (*layers*):

1.1 A primeira é referente aos *inputs* do modelo e formada por p neurônios (uma para cada variável explicativa);
1.2 A segunda camada refere-se a padrões, formada por n neurônios, um para cada padrão identificado, e que será usado no processo de aprendizagem da rede;
1.3 O terceiro é o de agregação, constituído por g neurônios, um para cada classe de *outputs*;
1.4 Por último, temos as camadas de *outputs* binários.

[6] Esta seção baseia-se em Brockett et al. (1994).

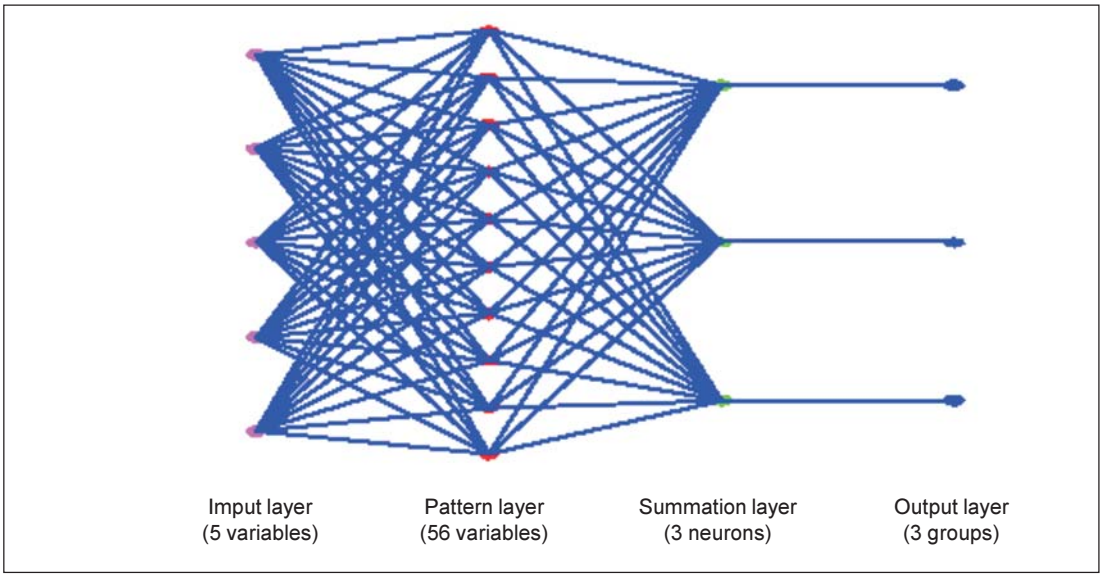

Conceitualmente, o *input layer* fornece a informação das p variáveis preditoras, alimentando o *layer* subseqüente que as padroniza. O *pattern layer* leva o valores obtidos para o *layer* agregativo através de uma função de ativação, que utiliza os valores de *inputs* para estimar a função densidade de probabilidade para cada grupo em determinada localização. Essas estimativas são então combinadas a partir de um processo de aprendizagem e geram um *score* para cada grupo. Finalmente, os *scores* são introduzidos no neurônio binário no *output layer*.

O processo se dá da seguinte forma: sejam p variáveis econômico-financeiras explicativas, denominadas neurônios, denotadas por X_1 até X_p. Esses valores são padronizados pela subtração da média e divisão pelo desvio-padrão e enviados para o *pattern layer*. Nesta fase, o algoritmo calcula a contribuição de cada Xi para estimar a função de densidade de probabilidade para o grupo pertinente através da função de ativação, dada por:

$$g_{ij} = W\left(\frac{X - X_i}{\sigma}\right)$$ Se a observação i pertence ao grupo j;

E g_{ij} = 0, caso contrário.

σ é o parâmetro de escala e controla a velocidade com que a influência de um ponto diminui em relação à sua distância de X. A função W é geralmente tomada como sendo uma gaussiana e definida por:

$$\exp\left(-\frac{\|X - X_1\|^2}{\sigma^2}\right)$$ e onde $\|X - X_1\|^2$ é a distância euclidiana entre X e Xi.

Sendo n_j o número de observações no conjunto de treinamento pertencentes ao grupo j, a função de densidade estimada para o grupo j na localização X é proporcional a:

$$g_j(X) = \frac{1}{n_j} \sum_{i=1} g_{ij}$$

Para alocar uma observação da localização X em um grupo, ainda resta conhecer a probabilidade *a priori* h*j* de uma observação pertencer ao grupo j, sem levar em consideração o vetor de *inputs*. Adicionalmente, o algoritmo considera o custo cj de classificar incorretamente uma observação pertencente ao grupo j. O *layer* de *outputs* calcula o *score* para cada grupo multiplicando a função de densidade de probabilidade pela probabilidade *a priori* e o custo de classificação: $score_j = h_j c_j g_j(X)$. A alocação se dá da seguinte forma:

$score_j > score_k$; aloca-se no neurônio de output j

$score_j < score_k$ aloca-se no neurônio de output k; $\forall$ $k \neq j$.

4. Estratégia empírica

O modelo de ADM demanda as seguintes hipóteses: 1) distribuição normal multivariada das variáveis independentes; 2) matrizes de covariâncias iguais entre os grupos. Diversos estudos empíricos atestam a dificuldade de cumprimento desses requisitos e, como resultado das violações, ocorrem vieses nas taxas de classificação e nos coeficientes estimados, como mostram BarNiv and McDonald (1992). A tendência dos trabalhos empíricos têm sido na direção de modelos mais eficientes e que dependam de menos hipóteses restritivas como o Logit, por exemplo. No entanto, utilizaremos a ADM como um *benckmark* para fins de comparação de modelos.

4.1. Desenho da amostra

Trabalhamos com duas amostras de operadoras, cada uma delas contendo um conjunto de empresas solventes e um conjunto de operadoras insolventes. A literatura reporta basicamente dois métodos de seleção do grupo de empresas insolventes, a baixa classificação nas agências especializadas de *rating* ou a partir de alguma intervenção estatal. Dada a inexistência de *rating* de planos de saúde por agências especializadas, optamos pela segunda alternativa, ou seja, definir como insolventes aquelas operadoras sob os chamados regimes especiais de intervenção, a direção fiscal, indicado em caso de anormalidades econômico-financeiras ou administrativas graves que coloquem em risco a assistência à saúde, ou a liquidação, um estágio de maior gravidade[7]. Entretanto, devido tanto à falta de dados destas operadoras quanto ao seu baixo índice de confiabilidade, não foi possível prosseguir nesta direção. Apenas para se ter uma idéia, de 58 regimes de direção fiscal decretados pela ANS no ano de 2005, 46 não dispunham de informação acessível no *site*. Diante dessa dificuldade, optamos por definir o conceito de insolvência da forma mais usual: operadoras com patrimônio líquido negativo. Para a finalidade do nosso estudo, não basta a seleção de empresas com PL negativo. Por isso, nossa amostra de operadoras insolventes foi dividida em composta pelas operadoras que tenham PL < 0 no período t, este sendo definido no intervalo de 2001-2004, mas que necessariamente tenham no período t-1, PL > 0, ou nos períodos t-1 e t-2, tenham PL > 0. A amostra inicial de operadoras que se enquadravam nesta regra consta no Anexo I.

[7] O arcabouço normativo subjacente a estes tipos de intervenções é dado pelo art. 23 e 24 da lei 9.656/98 e as RDC 24, RDC 25, RDC 82, RDC 84, RN 47 e RN 52.

O grupo das operadoras solventes foi escolhido a partir da própria experiência do autor com relação ao nível de solidez das empresas. Neste grupo foram incluídas todas as Sociedades Seguradoras Especializadas em Saúde, devido ao conhecido nível de comprometimento destas empresas com relação aos requerimentos prudenciais, e outras operadoras que apresentaram PL > 0 em todos os períodos analisados e não foram acometidas por intervenções por parte da ANS. Os dados foram obtidos através dos balanços patrimoniais das operadoras e seus respectivos demonstrativos de resultados, localizados no *site* da Agência Nacional de Saúde Suplementar[8].

4.2. Seleção de indicadores econômico-financeiros e demais co-variáveis

Os indicadores e demais co-variáveis explicativas foram inicialmente selecionados a partir de evidências empíricas de estudos prévios que suportaram suas inclusões, indicadores utilizados pela ANS em seu programa de qualificação e indicadores escolhidos a partir da própria experiência de análise deste mercado. O quadro abaixo resume o conjunto desses indicadores e apresenta seu sinal esperado. Um sinal positivo indica que um aumento no indicador aumenta a probabilidade de insolvência da operadora. Um sinal negativo, por sua vez, indica que uma elevação no indicador reduz a probabilidade de insolvência. O sinal de interrogação indica que o indicador não possui uma indicação clara, seja por aspectos conceituais ou falta de evidência empírica relevante. O Anexo II relaciona as siglas contábeis.

Resumo dos Indicadores Utilizados na Pesquisa

Siglas	Indicadores Econômico-Financeiros (Programa de Qualificação da ANS)	Sinal Esperado
END	Índice de Endividamento = (PC + PELP)/PL	+
IMO	Índice de Imobilização = AP/PL	+
ILC	Índice de Liquidez Corrente = AC/PC	-
ILA	Índice de Liquidez Geral Ajustada = (AC + APRL + API)/(PC + PELP)	?
ROE	Índice de Rentabilidade do Patrimônio Líquido = RL/PL	-
SIN	Índice de Sinistralidade = SR/PG ou EVE/CE	+
COM	Índice Combinado = (SR + DA + DC)/PG	+
COA	Índice Combinado Ampliado = (SR + DA + DC)/(PG + RF)	+
	Outros Indicadores de Solvência	
LOG PL	Logarítimo do Patrimônio Líquido	-
LOG AT	Logarítimo do Ativo Total	-
RES	Reservas sobre o PL	-
ALA	Alavancagem de Prêmios sobre o PL	+
VPL	Módulo da Variação do PL	+
PLP	PL sobre o Passivo Total	-
RO	Resultado Operacional = CE - EVE - DA - DC	-
ROPL	Resultado Operacional sobre o PL	-
MO	Resultado Operacional sobre o Prêmio Ganho	-
IDA	Índice de Despesas Administrativas = DA/PG	+
RFP	Resultado Financeiro sobre o Prêmio Ganho	?
VPG	Módulo da Variação do Prêmio Ganho	+
VR	Módulo da Variação nas Reservas	?
PAC	Passivo Total sobre o Ativo Circulante	+
IDC	Índice de Despesas de Comercialização = DC/PG	+
ST	Solvência Total = AT / (PC + PELP)	
	Institucionais	
ORG	Forma Organizacional = 0 = sem fins lucrativos; 1 = com fins lucrativos	-
RP	Rede Própria = 0 sem rede própria; =1 com rede própria	?
GF	Presença de Garantias Financeiras; com reservas = 1; sem reservas = 0	-
TAM	Proxy para o tamanho da operadora medida pelo número de bebeficiários	?
	Variável Endógena	
Solv	Solvência = 0 (Operadora solvente); Solv =2 (Operadora Insolvente)	

OBS - O índice 1 que aparece logo após a sigla do indicador significa que este é calculado para o ano anterior à insolvência, ou seja, refere-se a t -1. Da mesma forma, o índice 2 refere-se ao período t -2.

[8] http://www.ans.gov.br.

Utilizamos os indicadores da ANS como uma forma de poder avaliar sua capacidade de antecipar insolvências ainda que estes não possuam evidência empírica neste sentido. Os outros indicadores de solvência são suportados por uma variedade de modelos e contam com ampla evidência empírica de suas importâncias para antecipar movimentos de insolvência[9].

Estudos para o caso brasileiro[10] utilizando modelos de ADM sugerem evidência negativa à utilização da sinistralidade e da rentabilidade como bons preditores. A solvência ou insolvência de uma operadora de plano de saúde depende muito mais da qualidade dos ativos garantidores, do comprometimento das reservas e de um baixo grau de alavancagem do que fatores de curto-prazo, como sinistralidade e a própria rentabilidade, como tem revelado a literatura especializada. Incluímos, baseados nessa premissa, diversos indicadores de solvência. Outros indicadores igualmente relevantes não foram possíveis de serem obtidos por falta de desdobramentos nos balanços e demonstrativos divulgados[11].

Como variáveis institucionais, escolhemos incluir o índice de reclamações da ANS, suportada por alguns autores, a forma organizacional, se lucrativa ou não lucrativa, a presença ou ausência de reservas técnicas, e o tamanho da operadora, tendo em vista que, pelo menos em tese, quanto maior a massa segurada melhor a diluição dos riscos.

Não basta, entretanto, escolher as variáveis que teoricamente explicam a solvência de uma operadora. É preciso que algumas condições estatísticas se verifiquem para justificar a utilização dessas variáveis no modelo de forma a eliminar redundâncias e tornar os modelos mais eficientes. Nesse sentido, como critério de seleção de indicadores[12], implementamos três procedimentos subseqüentes para validar a entrada de variáveis explicativas econômico-financeiras nos modelos: 1) teste de igualdade de médias; 2) matriz de correlação parcial e; 3) análise de componentes principais. Satisfeitas essas premissas, teremos indicadores capazes de discriminar empresas solventes das insolventes, evitar problemas de multicolinearidade entre indicadores e utilizar os indicadores que melhor explicam a variabilidade dos dados.

Os resultados dos testes de igualdade de médias[13], reproduzidos no Anexo III, geraram resultados favoráveis, ou seja, bons discriminantes para as variáveis ILC, LN PL, LN AT, PLP, IDA, SIN e RFP, para a amostra com indicadores antecedentes em t-1. Para a amostra contendo dados antecedentes para os dois períodos, foram aceitos os indicadores: END_2, IMO_2, SIN_1, SIN_2, ALA_2, $LN\ PL_1$, $LN\ PL_2$, $LN\ AT_1$, $LN\ AT_2$, RFP_1.

---

[9] Vejam, por exemplo, os trabalhos de Carson and Hoyt (1995), Ambrose and Carroll (1994), Brockett et al (1994), Carson (1994), Browne, Carson and Hoyt (1999) dentre outros.

[10] Alves (2005).

[11] Convém ressaltar a impossibilidade de utilizarmos o ILA também por falta de informações nos balanços. Esse indicador, apesar de constar no programa de qualificação da ANS, carece de literatura que o referencie, dado que a imobilização não significa liquidez, ao contrário do que sugere o programa.

[12] Inicialmente contamos com 20 indicadores para a amostra t-1 e 42 indicadores para a amostra t-2.

[13] Ho: $\mu_1 - \mu_2=0$; H_1:$\mu_1 - \mu_2 \neq 0$, ao nível de significância de 95%. Um p-valor inferior a 0,1 indica a rejeição de Ho. Assumimos variâncias iguais no teste.

A matriz de correlações para a amostra t-1, reproduzida no anexo IV, mostrou elevada correlação entre os indicadores LN PL e LN AT. Já para a amostra t-2, foram identificadas elevadas correlações entre os indicadores END_2, IMO_2, e ALA_2, entre SIN_1, SIN_2, e entre LN PL_1, LN PL_2, LN AT_1 e LN AT_2. Todas superiores a 70%. Até o presente momento temos as seguintes variáveis selecionadas:

Amostra t-1: ILC, (LN PL ou LN AT), PLP, IDA, SIN e RFP;
Amostra t-2: (END_2, IMO_2, ou ALA_2), (SIN_1ou SIN_2), (LN PL_1, LN PL_2, LN AT_1, LN AT_2) e RFP_1.

Somente nos dois primeiros passos foi possível reduzir o número de variáveis econômico-financeiras de 20 para 6, na amostra t-1, e de 42 para 4, na amostra t-2. Tendo em vista a redução significativa do número de co-variáveis, a última etapa do procedimento perde sua importância. De qualquer maneira, realizamos o procedimento a fim de verificar os principais componentes dentre as variáveis utilizadas.

O objetivo da análise de componentes principais é obter o menor número de combinações de variáveis explicativas responsáveis pela maior parte da variabilidade dos dados. No caso da amostra t-1, dois componentes foram extraídos, ILC e LN PL, por possuírem autovalores superiores à unidade, e respondem por cerca de 64% da variabilidade dos dados originais. Já na amostra t-2, 3 componentes principais foram obtidos: END2, IMO1, SIN1.

4.3. Modelos utilizados

Os modelos estimados foram:

Modelo t-1:

$$Y = \beta_0 + \beta_1\, ILC + \beta_2\, LNPL + \beta_3\, PLP + \beta_4\, IDA + \beta_5\, SIN + \beta\, RFP + \beta_7\, TAM + \beta_8\, GF + \beta_9\, RP + \beta_{10}\, RECL + \beta_{11}\, ORG$$

Modelo t-2:

$$Y = \beta_0 + \beta_1\, ALA_2 + \beta_2\, SIN_2 + \beta_3\, LNPL_2 + \beta_4\, RFP_1 + \beta_5\, TAN + \beta_6 GF_1 + \beta_7\, GF_2 + \beta_8\, RP + \beta_9\, RECL + \beta_{10}\, ORG$$

Onde:
Y = 0 para operadoras solventes e Y = 1 para operadoras insolventes;
ILC é o índice de liquidez corrente;
LNPL é o logaritmo do Patrimônio Líquido;
PLP é a razão do PL sobre o passivo total;
IDA é o índice de despesas administrativas;
SIN é o índice de sinistralidade;
RFP é a razão do resultado financeiro sobre o prêmio ganho;
ALA_2 é o índice de alavancagem mensurado dois anos antes da insolvência;
SIN_2 é o índice de sinistralidade mensurado dois anos antes da insolvência;
$LNPL_1$ é o logaritmo do Patrimônio Líquido, mensurado no ano anterior;
RFP_1 é a razão do resultado financeiro sobre o prêmio ganho.

Vale recordar que todos os indicadores do modelo t-1 são referentes ao período anterior à ocorrência do evento, solvência ou insolvência, razão pelo qual não estão acrescidos de índices indicativos ao período de referência. Ao contrário, no modelo t-2 os índices que acompanham a variável descrevem o período antecedente ao qual se referem: 1 para o período t-1 e 2 para o período t-2.

Para cada um dos dois modelos utilizamos as metodologias de regressão logística, análise discriminante multivariada e redes neurais.

4.4. Índice de Desempenho Econômico-Financeiro da ANS

A Agência Nacional de Saúde Suplementar, no âmbito de sua política de qualificação das operadoras do mercado, desenvolveu um ranking das operadoras reguladas, baseado nas dimensões econômico-financeira, atenção à saúde, estrutura e operação e satisfação do consumidor, cuja estrutura de pesos é 30%, 50%, 10% e 10%, respectivamente. O Índice de Desempenho na Dimensão Econômico-Financeira (IDEF) é definido por uma função que associa valores (pontos) diferenciados em relação à posição relativa de cada operadora em relação ao conjunto de operadoras semelhantes (mesma modalidade) e ao conjunto total de operadoras. As operadoras são avaliadas por uma família de índices econômico-financeiros: END, IMO, ILC, ILA, SIN, ROE, COM e COA. A nota da operadora é resultante das pontuações obtidas nos índices divididos pelo total de pontos estabelecidos como meta. Adicionalmente, os índices possuem pesos diferenciados, sendo 5% para END e ILC e 15% para os demais.

As pontuações de cada indicador são obtidas mediante sua posição relativa aos quartis das distribuições dos indicadores da mesma modalidade e no âmbito do mercado total. Para os indicadores do tipo quanto maior, melhor, como ILC e ILA, quanto mais próximo ao limite superior, maior a pontuação recebida. Para alguns índices do tipo quanto menor, melhor, como END e IMO, o inverso é verdadeiro. Entretanto, os índices SIN, COM e COA, que são do tipo quanto menor melhor, receberam um sistema de pontuação diferenciado, onde quanto mais próximos da mediana, melhor é a nota e, conseqüentemente, quanto mais distantes da mediana (mesmo que seja para baixo), menor é a nota. Calculamos o IDEF para uma amostra de operadoras solventes e insolventes em t-1 e implementamos um teste-t de igualdade de médias para verificar a capacidade discriminante deste indicador. De acordo com o teste, as médias dos índices de desempenho econômico-financeiro da ANS para o grupo de operadoras solventes não difere estatisticamente da média do grupo de operadoras insolventes. Não utilizamos, portanto, esse indicador como preditor de insolvência.

Group Statistics

	SOLV	N	Mean	Std. Deviation	Std. Error Mean
IDSS-Dimensão	1	26	,593	,183	3,589E-02
Econômico-Financeira	0	39	,677	,140	2,245E-02

Independent Samples Test

		Levene's Test for Equality of Variances		t-test for Equality of Means						
									95% Confidence Interval of the Difference	
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	Lower	Upper
IDSS-Dimensão Econômico-Financeira	Equal variances assumed	1,647	,204	-2,098	63	,040	-8,424E-02	4,015E-02	-,164	-4,02E-03
	Equal variances not assumed			-1,990	43,954	,053	-8,424E-02	4,233E-02	-,170	1,073E-03

5. Resultados

Com relação aos modelos de previsão de insolvência, os resultados mostram uma dominância acentuada dos modelos de regressão logística sobre seus concorrentes. Tal evidência é suportada pelo reduzido erro do tipo 1 (4,9% e 12,2%) que é o de classificar uma empresa insolvente no grupo solvente. O custo do erro tipo 1 é dado pelo risco de não se atuar preventivamente em uma operadora com problemas financeiros graves. Já o custo do erro do tipo 2 é dado pelo custo processual de se acentuar os esforços de fiscalização e acompanhamento financeiro em uma empresa solvente, além de um eventual custo de imagem ocasionado por uma intervenção regulatória. Nesse sentido, os modelos logísticos foram os que apresentaram a melhor performance, pois produziram erros do tipo 1 de 4,9% e 12,2% para um ano e dois anos antes da insolvência, respectivamente. Os modelos de redes neurais foram superiores aos de análise discriminante na previsão de insolvência um ano antes da ocorrência. Para o período de dois anos antecedentes, o inverso é verdadeiro.

As variáveis significativas foram LNPL, GF, ORG e RECL, para um ano antes da insolvência e LNPL2 e GF2 para dois anos antes. Nenhum índice econômico-financeiro utilizado pela Agência Nacional de Saúde Suplementar mostrou-se um bom preditor de insolvência financeira, segundo os resultados obtidos.

Os resultados obtidos acompanham os desenvolvimentos recentes da literatura internacional que incorpora, aos modelos de previsão de seguradoras, variáveis relacionadas ao capital da empresa e o dimensionamento de suas reservas.

Performance Relativa dos Modelos

Amostras	Modelos	Variáveis Significativas	% de Acertos Operadoras Solventes	% de Acertos Operadoras Insolventes	Erro Tipo 1	Erro Tipo 2	% de Acerto Global do Modelo
t-1	ADM	LNPL, GF, ORG	100,0%	64,3%	35,7%	0,0%	85,50%
t-1	Logit	RECL, LNPL, GF	85,71%	95,12%	4,9%	14,3%	91,30%
t-1	Redes Neurais	nd	92,7%	71,43%	28,6%	7,3%	84,05%
t-2	ADM	LNPL2, GF2	95,12%	76,92%	23,1%	4,9%	90,74%
t-2	Logit	LNPL2	100%	87,80%	12,2%	0,0%	90,74%
t-2	Redes Neurais	nd	97,56%	53,85%	46,2%	2,4%	87,04%

Erro Tipo 1: Classificar operadoras insolventes como solventes
Erro Tipo 2: Classificar operadoras solventes como insolventes

Com relação aos parâmetros estimados, vale observar que:

- A ausência de garantias financeiras eleva em 8,16% a chance de uma operadora se tornar insolvente no ano seguinte;
- Cada 1% de aumento de capital da operadora reduz em 0,34% a chance dela se tornar insolvente no ano seguinte e 0,23% no ano posterior;
- O aumento nas reclamações dos consumidores mostrou-se uma importante variável na antecipação de problemas financeiros.

6. Conclusões

A questão da solvência de operadoras de planos de saúde, embora seja de grande relevância para diversos participantes desse setor, vem sendo debatida principalmente no âmbito da elevação das taxas de sinistralidade do setor, ocasionada, dentre outros fatores, pelo descasamento entre a taxa de crescimento dos reajustes de planos individuais, regulados, e o crescimento dos custos do setor, não regulados. Entretanto, em que medida um aumento na sinistralidade eleva os riscos de insolvência? Ou, de forma mais abrangente, qual a relação dos indicadores econômico-financeiros tradicionais e a insolvência de operadoras de planos? Para responder a essa pergunta, elaboramos alguns modelos de previsão de insolvência a fim de identificar as variáveis que realmente impactam o risco de insolvência. A partir da comparação de operadoras solventes e operadoras insolventes para o período 2001-2004, foi possível chegar a algumas destas respostas.

Como primeiro resultado, foi comprovado que a solvência das operadoras está diretamente relacionada ao volume de capital e à presença de reservas técnicas. A ausência de garantias financeiras eleva em 8,16% a chance de uma operadora se tornar insolvente no ano seguinte e para cada 1% de aumento de capital da operadora reduz em 0,34% a chance dela se tornar insolvente no ano seguinte e 0,23% dois anos à frente. Nesse sentido, uma nova agenda de pesquisa faz-se necessária a fim de verificar, de forma mais precisa, a relação entre o risco de insolvência e outras variáveis como a qualidade dos ativos garantidores das reservas, a estrutura do passivo e o risco da operação, de forma a proporcionar uma regulação prudencial baseada em risco.

Este resultado sugere um foco mais específico no dimensionamento do capital e das garantias financeiras no âmbito do acompanhamento deste mercado. A utilização do índice de desempenho econômico-financeiro da ANS, utilizado em seu programa de qualificação de operadoras, não se mostrou um bom preditor de solvência, dado que carece de robustez estatística, varia conforme a amostra analisada, e não se mostrou um bom discriminante entre operadoras solventes e insolventes. Em razão dessas propriedades, ou ausência delas, sua utilização com o objetivo de estabelecer um *rating* de operadoras fica prejudicado.

7. Referências bibliográficas

ALTMAN, E. Financial Ratios, Discriminant Analysis and the Prediction of Business Failure. **Journal of Finance,** 1968.

ALVES, SL. Modelos de Previsão de Insolvência de Operadoras de Planos de Saúde. In: CONGRESSO DE ECONOMIA DA SAÚDE DA AMÉRICA LATINA E CARIBE, 1, 2004. **Anais**... Rio de Janeiro, 2004.

AMBROSE, MILLS, SEWARD. Best's Rating, Financial Ratios and Prior Probabilities in Solvency Prediction, **Journal of Risk and Insurance**, n. 55, p. 229-244, 1988.

BAIRD; MORRISON. Optimal Timing and Legal Decision Making: The Case of Liquidation Decision in Bankruptcy. **Working Papers in Law and Economics,** Chicago, n.86, 1999.

BARNIV; MCDONALD. Identifying Financial Distress in the insurance industry: A Synthesis of Methodological and Empirical Issues. **Journal of Risk and Insurance**, n. 59, p. 543-573, 1992.

BRASIL Ministério da Saúde. Agência Nacional de Saúde Suplementar. **Programa de Qualificação da Saúde Suplementar.** Rio de Janeiro. Disponível em www.ans.gov.br. Acesso em 27 de maio de 2005.

BROCKETT /et al/. A Neural Network Method for Obtaining an Early Warning of Insurer Insolvency. **Journal of Risk and Insurance**, n. 61, p. 402-424, 1994.

BROWNE, CARSON, HOYT. Economic and Market Predictors of Insolvencies in the Life-Health Insurance Industry. **Journal of Risk and Insurance**, n. 66, p. 643-659, 1999.

CARSON, J. Financial Distress in the Life Insurance Industry: An Empirical Examination", Proceedings of the 4th Actuarial Approach for Financial Risks (AFIR). **International Colloquium**, April, n Orlando, FL, v. 3, p. 1211-1240, 1994.

FINSIGER; PAULY. Reserve levels and Reserve Requirements for Profit-Maximizing Insurance Firms". In: BAMBERG, G. ; SPREMANN, K. (eds). **Risk and Capital**, Springer-Verlag, p. 160-180, 1984.

HAMMOND; SHILLING. Some Relationship of Portfolio Theory to the Regulation of Insurer Solidity. **Journal of Risk and Insurance**, n. 45, p. 377-400, 1978.

HARRINGTON; DANZON. **An Evaluation of Solvency Surveillance in the Property Liability Insurance Industry.** Schaumburg, Il Alliance of American Insurers, 1986.

HARRINGTON ; NELSON. A Regression-Based Methodology for Solvency Surveillance in the Property-Liability Insurance Industry. **Journal of Risk and Insurance**, n. 53, p. 583-605, 1986.

IPPOLITO, R. The Effects of Price Regulation in the Automobile Insurance Industry. **Journal of Law and Economics**, p. 22, p. 55-89, 1979.

JAGTIANI, J., KOLARI, J., SHIN, H. Early warning models for bank supervision: Simpler could be better. **Economic Perspectives**, Federal Reserve Bank of Chicago, p. 49-60, 2003.

KASTELIJN; REMMERSWAAL. **Solvency, Surveys of Actuarial Studies nº 3**. NATIONAL NEDERLANDEN, 1986.

MCDONALD. **Predicting Insurance Insolvency Using Generalized Qualitatives Response Models.** Mimeo, Brigham Young University, 1988.

MUNCH ; SMALLWOOD. Solvency Regulation in the Property-Liability Insurance Industry: Empirical Evidence, Bell **Journal of Economics**, n. 11, p. 261-282, 1980.

PINCHES; TIESCHMANN. A Multivariate Model for Predicting Financially Distressed Property-Liability Insurers, **Journal of Risk and Insurance**, n. 40, p. 327-338, 1973.

PINDYCK AND RUBINFELD. **Econometric Models and Economic Forecast.** 4th ed. McGraw-Hill International Editions, 1998.

RAMANATHAN, R (1989) **Introductory Econometrics with Applications**. Harcourt Brace Inc, 1989.

STATGRAPHICS. **Neural Network Classifier,** 2005**.**

SERRA, C. **Indicadores contábeis, análise discriminante e previsão de insolvência no mercado de saúde suplementar**. Rio de Janeiro, UNESA, 2005. [Trabalho de conclusão do curso de ciências atuariais].

8. Anexos

Anexo I – Amostra inicial

Amostra de Operadoras Insolventes com dados em t-1

OPERADORA	MODALIDADE
APUB-SSIND-ASSOCIACAO DOS PROFESSORES UNIVERSITARIOS DA BAH	Autogestão Não Patrocinada
UNIMED CAMPINA GRANDE - COOPERATIVA DE TRABALHO MEDICO LTDA	Cooperativa Médica
UNIMED DE PENAPOLIS - COOPERATIVA DE TRABALHO MEDICO	Cooperativa Médica
UNIMED DE SAO JOSE DOS CAMPOS	Cooperativa Médica
UNIMED DO ALTO OESTE POTIGUAR - COOPERATIVA DE TRABALHOS MÉD	Cooperativa Médica
UNIMED DO OESTE GOIANO COOPERATIVA DE TRABALHO MEDICO	Cooperativa Médica
UNIMED FLORIANÓPOLIS COOP. DE TRABALHO MÉDICO	Cooperativa Médica
UNIMED VALE DO SÃO FRANCISCO COOPERATIVA DE TRABALHO MÉDICO	Cooperativa Médica
UNIDENTAL- COOPERATIVA UNIÃO DOS DENTISTAS DO EST. DO CEARÁ	Cooperativa odontológica
UNIODONTO DE FOZ DO IGUACU COOPERATIVA ODONTOLOGICA	Cooperativa odontológica
UNIODONTO DE RECIFE COOP.DE TRABALHO ODONTOLOGICO	Cooperativa odontológica
UNIODONTO DE SÃO ROQUE- COOPERATIVA ODONTOLÓGICA	Cooperativa odontológica
UNIODONTO DE SC COOPERATIVA ADMINISTRADORAS DE CONTRATOS	Cooperativa odontológica
UNIODONTO ITAPERUNA-COOP DE TRABALHO ODONTOLOGICO	Cooperativa odontológica
UNIODONTO LEOPOLDINA - COOP. DE TRABALHO ODONTOLOGICO LTDA.	Cooperativa odontológica
UNIODONTO PETRÓPOLIS - COOP.TRAB.ODONTOLÓGICOS LTDA	Cooperativa odontológica
UNIODONTO SUL CAPIXABA COOPERATIVA ODONTOLOGICA	Cooperativa odontológica
SANTA CASA DE MISERICÓRDIA DE ITAPEVA	Filantropia
ASSOCIAÇÃO AUXILIADORA DAS CLASSES LABORIOSAS	Medicina de Grupo
CONFIANCA ASSISTENCIA MEDICO HOSP. LTDA	Medicina de Grupo
MED LINE ASSISTENCIA MEDICA E ODONTOLOGICA LTDA	Medicina de Grupo
PROTEÇÃO E ASSISTÊNCIA MÉDICA À SAÚDE S/S LTDA -	Medicina de Grupo
SAMP ESPIRITO SANTO ASSISTÊNCIA MÉDICA LTDA	Medicina de Grupo
SANTA MARINA SAÚDE S/C LTDA	Medicina de Grupo
TERRAMAR ADMINISTRADORA DE PLANO DE SAUDE LTD A	Medicina de Grupo
TRANSCLINICA LTDA	Medicina de Grupo
UNIHOSP-ASSISTÊNCIA MÉDICO-HOSPITALAR LTDA.	Medicina de Grupo
VECTRA ASSISTENCIA ODONTOLÓGICA S/C LTDA.	Medicina de Grupo
SOIP - PLANOS ODONTOLOGICOS S/S LTDA.	Odontologia de Grupo
UNISAUDE LTDA	Odontologia de Grupo

Amostra de Operadoras Insolventes com dados em t-2

OPERADORA	MODALIDADE
APUB-SSIND- ASSOCIACAO DOS PROFESSORES UNIVERSITÁRIOS DA BAH	Autogestão Não Patrocinada
UNIMED DE PENAPOLIS - COOPERATIVA DE TRABALHO MEDICO	Cooperativa Médica
UNIMED DO ALTO OESTE POTIGUAR - COOPERATIVA DE TRABALHOS MÉD	Cooperativa Médica
UNIMED VALE DO SÃO FRANCISCO COOPERATIVA DE TRABALHO MÉDICO	Cooperativa Médica
UNIDENTAL- COOPERATIVA UNIÃO DOS DENTISTAS DO EST. DO CEARÁ	Cooperativa odontológica
UNIODONTO DE SÃO ROQUE- COOPERATIVA ODONTOLÓGICA	Cooperativa odontológica
UNIODONTO DE SC COOPERATIVA ADMINISTRADORAS DE CONTRATOS	Cooperativa odontológica
UNIODONTO ITAPERUNA-COOP DE TRABALHO ODONTOLOGICO	Cooperativa odontológica
UNIODONTO SUL CAPIXABA COOPERATIVA ODONTOLOGICA	Cooperativa odontológica
PROTEÇÃO E ASSISTÊNCIA MÉDICA À SAÚDE S/S LTDA-	Medicina de Grupo
SANTA MARINA SAÚDE S/C LTDA	Medicina de Grupo
UNIHOSP-ASSISTÊNCIA MÉDICO-HOSPITALAR LTDA.	Medicina de Grupo
VECTRA ASSISTENCIA ODONTOLÓGICA S/C LTDA.	Medicina de Grupo
SOIP - PLANOS ODONTOLOGICOS S/S LTDA.	Odontologia de Grupo
UNISAUDE LTDA	Odontologia de Grupo

Amostra de Operadoras Solventes com dados em t-2 e t-1

OPERADORA	MODALIDADE
AMESP ADMINISTRADORA DE PLANOS DE SAUDE E ODONTOLOGICOS S/C LTDA	Medicina de Grupo
AMIL ASSISTÊNCIA MÉDICA INTERNACIONAL LTDA	Medicina de Grupo
DENTALCORP ASSISTÊNCIA ODONTOLÓGICA INTERNACIONAL LTDA	Odontologia de Grupo
GOLDEN CROSS ASSISTENCIA INTERNACIONAL DE SAUDE LTDA	Medicina de Grupo
INTERMEDICA SISTEMA DE SAÚDE S.A.	Medicina de Grupo
INTERODONTO - SISTEMA DE SAÚDE ODONTOLÓGICA LTDA.	Odontologia de Grupo
MEDIAL SAÚDE S/A.	Medicina de Grupo
ODONTOPREV S/A	Odontologia de Grupo
ASSOCIL ASSESSORIA DE SAÚDE EM ODONTOLOGIA AO COM.E IND.LTDA	Odontologia de Grupo
OMINT SERVIÇOS DE SAÚDE LTDA	Medicina de Grupo
UNIMED DE SANTOS COOP DE TRAB MEDICO	Cooperativa Médica
UNIMED BETIM COOPERATIVA DE TRABALHO MEDICO	Cooperativa Médica
UNIMED BH COOPERATIVA DE TRABALHO MÉDICO LTDA	Cooperativa Médica
UNIMED CAMPINAS - COOPERATIVA DE TRABALHO MÉDICO	Cooperativa Médica
UNIMED CUIABA COOPERATIVA DE TRABALHO MÉDICO	Cooperativa Médica
UNIMED DE BRUSQUE COOPERATIVA DE TRABALHO MÉDICO	Cooperativa Médica
UNIMED DE CAMPOS COOPERATIVA DE TRABALHO MÉDICO	Cooperativa Médica
UNIMED DE MARINGÁ COOPERATIVA DE TRABALHO MÉDICO	Cooperativa Médica
UNIMED DIVINOPOLIS - COOPERATIVA DE TRABALHO MEDICO LTDA	Cooperativa Médica
UNIMED-RIO COOPERATIVA DE TRABALHO MEDICO DO RIO DE JANEIRO	Cooperativa Médica
UNIODONTO DE CAMPINAS COOPERATIVA ODONTOLOGICA	Cooperativa odontológica
UNIODONTO DE FORTALEZA COOPERATIVA DE TRABALHO ODONTOLOGICO	Cooperativa odontológica
UNIODONTO DO BRASIL CENTRAL NACIONAL DAS COOPERATIVAS ODONT.	Cooperativa odontológica
UNIODONTO DE SAO PAULO COOPERATIVA ODONTOLOGICA	Cooperativa odontológica
UNIODONTO PORTO ALEGRE COOPERATIVA ODONTOLOGICA LTDA	Cooperativa odontológica
UNIODONTO DE PRESIDENTE PRUDENTE COOPERATIVA ODONTOLOGICA	Cooperativa odontológica
BENEFICENCIA CAMILIANA DO SUL	Filantropia
CASA DE SAÚDE SÃO BERNARDO LTDA.	Medicina de Grupo
AGF SAÚDE S/A	Seguradora Especializada
BRADESCO SAÚDE S.A	Seguradora Especializada
BRASILSAÚDE COMPANHIA DE SEGUROS	Seguradora Especializada
GRALHA AZUL SAÚDE S/A	Seguradora Especializada
HSBC SEGURO SAUDE S/A	Seguradora Especializada
ITAUSEG SAÚDE S/A	Seguradora Especializada
MARÍTIMA SAÚDE SEGUROS S/A	Seguradora Especializada
NOTRE DAME SEGURADORA S.A	Seguradora Especializada
PORTO SEGURO - SEGURO SAUDE S/A	Seguradora Especializada
SALUTAR SAUDE SEGURADORA S/A	Seguradora Especializada
SUL AMÉRICA COMPANHIA DE SEGURO SAÚDE S/A	Seguradora Especializada
SUL AMÉRICA SEGURO SAÚDE S/A	Seguradora Especializada
UNIBANCO AIG SAÚDE SEGURADORA S/A	Seguradora Especializada
UNIMED SEGUROS SAUDE S/A	Seguradora Especializada

Anexo II

Siglas	Legenda
AC	Ativo Circulante
ARLP	Ativo Realizável de Longo Prazo
AP	Ativo Permanente
API	Ativo Permanente Imobilizado
AT	Ativo Total
PT	Provisões Técnicas. Nas SES = Provisões Comprometidas + Prov. Não Comprometidas
PC	Passivo Circulante
PELP	Passivo Exigível de Longo Prazo
REF	Resultado de Exercícios Futuros
PL	Patrimônio Líquido
PAT	Passivo Total
CE	Contraprestações Efetivas. Nas SES = Prêmio Ganho
EV	Eventos Indenizáveis. Nas SES = Sinistro Retido
DC	Despesas de Comercialização
ODO	Outras Receitas e Despesas Operacionais
RO	Resultado Operacional
RF	Resultado Financeiro
DA	Despesas Administrativas
RNO	Resultado Não Operacional
IMP	Impostos e Participações sobre o Lucro
RL	Resultado Líquido

Anexo III

Teste de Igualdade de Médias

		Levene's Test for Equality of Variances		t-test for Equality of Means						
									90% Confidence Interval of the Difference	
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	Lower	Upper
END	Equal variances assumed	3,945	,051	-1,393	67	,168	-21,34	15,31	-46,87	4,20
	Equal variances not assumed			-1,184	30,214	,245	-21,34	18,01	-51,90	9,23
IMO	Equal variances assumed	,000	,987	-,451	67	,653	-1,24	2,74	-5,81	3,34
	Equal variances not assumed			-,509	61,283	,613	-1,24	2,43	-5,30	2,82
ILC	Equal variances assumed	6,969	,010	1,957	67	,054	4,59	2,35	,68	8,50
	Equal variances not assumed			2,316	47,539	,025	4,59	1,98	1,27	7,92
ROE	Equal variances assumed	,241	,625	-,826	67	,412	-1,85	2,24	-5,60	1,89
	Equal variances not assumed			-,941	58,669	,350	-1,85	1,97	-5,15	1,44
SIN	Equal variances assumed	4,337	,041	1,901	67	,062	,11	5,97E-02	1,39E-02	,21
	Equal variances not assumed			1,790	45,755	,080	,11	6,34E-02	7,03E-03	,22
COM	Equal variances assumed	3,659	,060	-1,207	67	,232	-,17	,14	-,42	6,67E-02
	Equal variances not assumed			-1,038	31,572	,307	-,17	,17	-,46	,11
COA	Equal variances assumed	4,839	,031	-1,672	67	,099	-,23	,14	-,47	-6,22E-04
	Equal variances not assumed			-1,434	31,188	,162	-,23	,16	-,51	4,26E-02
LN_PL	Equal variances assumed	,070	,792	8,585	67	,000	4,88	,57	3,93	5,83
	Equal variances not assumed			8,494	55,976	,000	4,88	,57	3,92	5,84
LN_AT	Equal variances assumed	2,186	,144	7,999	67	,000	3,97	,50	3,14	4,79
	Equal variances not assumed			7,810	53,177	,000	3,97	,51	3,12	4,82
RES	Equal variances assumed	5,972	,017	-1,173	67	,245	-11,96	10,20	-28,98	5,05
	Equal variances not assumed			-,966	27,043	,342	-11,96	12,38	-33,05	9,12
ALA	Equal variances assumed	1,707	,196	-1,037	67	,303	-58,17	56,08	-151,72	35,37
	Equal variances not assumed			-,928	36,893	,360	-58,17	62,69	-163,95	47,61
PLP	Equal variances assumed	,711	,402	3,013	67	,004	,18	5,85E-02	7,87E-02	,27
	Equal variances not assumed			2,899	50,079	,006	,18	6,08E-02	7,44E-02	,28
RO	Equal variances assumed	7,919	,006	,395	67	,694	1802015,5	4565920,0	-5813556	9417587
	Equal variances not assumed			,477	41,336	,636	1802015,5	3781199,2	-4560087	8164118
ROPL	Equal variances assumed	,635	,428	-1,420	67	,160	-8,27	5,82	-17,98	1,44
	Equal variances not assumed			-1,335	45,391	,189	-8,27	6,20	-18,68	2,13
MO	Equal variances assumed	3,659	,060	1,207	67	,232	,17	,14	-6,67E-02	,42
	Equal variances not assumed			1,038	31,572	,307	,17	,17	-,11	,46
IDA	Equal variances assumed	5,694	,020	-1,859	67	,067	-,29	,16	-,55	-3,00E-02
	Equal variances not assumed			-1,636	34,525	,111	-,29	,18	-,59	9,63E-03
RFP	Equal variances assumed	2,938	,091	3,614	67	,001	6,17E-02	1,71E-02	3,32E-02	9,02E-02
	Equal variances not assumed			4,046	62,715	,000	6,17E-02	1,52E-02	3,62E-02	8,71E-02
PAC	Equal variances assumed	,017	,898	-,062	67	,951	-1,75E-02	,28	-,49	********
	Equal variances not assumed			-,061	55,960	,951	-1,75E-02	,29	-,50	********
IDC	Equal variances assumed	,704	,404	,438	67	,663	3,46E-03	7,89E-03	-9,71E-03	********
	Equal variances not assumed			,417	48,145	,678	3,46E-03	8,28E-03	-1,04E-02	********

Estatísticas Descritivas da Amostra t-1

	SOLV	N	Mean	Std. Deviation	Std. Error Mean
END	0	41	5,96	27,24	4,25
	1	28	27,30	92,62	17,50
IMO	0	41	2,76	13,46	2,10
	1	28	4,00	6,47	1,22
ILC	0	41	6,46	12,11	1,89
	1	28	1,87	3,13	,59
ROE	0	41	-1,11	11,15	1,74
	1	28	,75	4,87	,92
SIN	0	41	,75	,21	3,25E-02
	1	28	,64	,29	5,44E-02
COM	0	41	1,03	,30	4,68E-02
	1	28	1,21	,86	,16
COA	0	41	,98	,28	4,35E-02
	1	28	1,22	,83	,16
LN_PL	0	41	16,09	2,27	,35
	1	28	11,21	2,40	,45
LN_AT	0	41	17,12	1,92	,30
	1	28	13,16	2,17	,41
RES	0	41	,67	2,23	,35
	1	28	12,63	65,48	12,37
ALA	0	41	41,73	157,49	24,60
	1	28	99,90	305,15	57,67
PLP	0	41	,44	,22	3,40E-02
	1	28	,26	,27	5,05E-02
RO	0	41	1992587,34	24010968,62	3749883
	1	28	190571,82	2569744,07	485635,98
ROPL	0	41	-2,96	20,18	3,15
	1	28	5,31	28,23	5,34
MO	0	41	-3,08E-02	,30	4,68E-02
	1	28	-,21	,86	,16
IDA	0	41	,24	,40	6,21E-02
	1	28	,54	,88	,17
RFP	0	41	4,80E-02	8,31E-02	1,30E-02
	1	28	-1,37E-02	4,23E-02	7,99E-03
PAC	0	41	2,02	1,13	,18
	1	28	2,04	1,19	,23
IDC	0	41	3,38E-02	2,86E-02	4,46E-03
	1	28	3,04E-02	3,69E-02	6,98E-03

Estatisticas Descritivas da Amostra t-2

	SOLV	N	Mean	Std. Deviation	Std. Error Mean
END1	0	41	5,96	27,24	4,25
	1	13	4,24	5,18	1,44
END2	0	41	1,72	2,38	,37
	1	13	23,09	65,84	18,26
IMO1	0	41	2,76	13,46	2,10
	1	13	1,21	1,16	,32
IMO2	0	41	,58	,69	,11
	1	13	11,43	37,54	10,41
ILC1	0	41	6,46	12,11	1,89
	1	13	1,72	1,63	,45
ILC2	0	41	6,74	13,26	2,07
	1	13	3,11	6,64	1,84
ROE1	0	41	-1,11	11,15	1,74
	1	13	-,39	1,51	,42
ROE2	0	41	,21	,58	9,00E-02
	1	13	-1,72	9,72	2,70
SIN1	0	41	,75	,21	3,25E-02
	1	13	,59	,34	9,54E-02
SIN2	0	41	,74	,18	2,84E-02
	1	13	,50	,38	,10
COM1	0	41	1,03	,30	4,68E-02
	1	13	1,01	,14	3,81E-02
COM2	0	41	,99	,25	3,90E-02
	1	13	,90	,24	6,70E-02
COA1	0	41	,98	,28	4,35E-02
	1	13	1,04	,19	5,30E-02
COA2	0	41	,97	,24	3,74E-02
	1	13	,89	,24	6,54E-02
LN_PL1	0	41	16,09	2,27	,35
	1	13	11,66	1,64	,45
LN_PL2	0	41	16,06	2,12	,33
	1	13	11,17	1,80	,50
LN_AT1	0	41	17,12	1,92	,30
	1	13	12,93	1,87	,52
LN_AT2	0	41	16,98	2,00	,31
	1	13	12,79	1,51	,42
RES1	0	41	,67	2,23	,35
	1	13	,25	,39	,11
RES2	0	41	,36	,46	7,23E-02
	1	13	,28	,99	,28
ALA1	0	41	41,73	157,49	24,60
	1	13	22,75	35,73	9,91
ALA2	0	41	9,23	10,06	1,57
	1	13	47,51	73,92	20,50
VPL1	0	41	384,96	1857,01	290,02
	1	13	85,30	122,83	34,07
PLP1	0	41	,44	,22	3,40E-02
	1	13	,35	,26	7,26E-02
PLP2	0	41	,46	,22	3,41E-02
	1	13	,35	,29	8,17E-02
RO1	0	41	1992587	24010968,62	3749883
	1	13	142630,86	326608,48	90584,89
RO2	0	41	7479250	20481855,49	3198728
	1	13	428822,08	1405055,49	389692,28
ROPL1	0	41	-2,96	20,18	3,15
	1	13	,54	2,28	,63
ROPL2	0	41	,32	1,55	,24
	1	13	5,28	31,42	8,72
MO1	0	41	-3,08E-02	,30	4,68E-02
	1	13	-7,78E-03	,14	3,81E-02
MO2	0	41	,32	1,55	,24
	1	13	5,28	31,42	8,72
IDA1	0	41	,24	,40	6,21E-02
	1	13	,38	,40	,11
IDA2	0	41	,22	,36	5,59E-02
	1	13	,36	,35	9,67E-02
RFP1	0	41	4,80E-02	8,31E-02	1,30E-02
	1	13	-2,01E-02	5,82E-02	1,61E-02
RFP2	0	41	2,40E-02	6,07E-02	9,48E-03
	1	13	1,00E-02	9,79E-02	2,71E-02
VPG	0	41	44,41	158,68	24,78
	1	13	122,44	227,01	62,96
PAC1	0	41	2,02	1,13	,18
	1	13	2,11	1,45	,40
PAC2	0	41	1,92	1,28	,20
	1	13	2,40	2,30	,64
IDC1	0	41	3,38E-02	2,86E-02	4,46E-03
	1	13	3,94E-02	4,86E-02	1,35E-02
IDC2	0	41	3,12E-02	2,65E-02	4,15E-03
	1	13	3,09E-02	3,94E-02	1,09E-02
ST1	0	41	5,43	8,71	1,36
	1	13	2,57	3,29	,91
ST2	0	41	6,18	12,49	1,95
	1	13	3,73	7,12	1,98

Anexo IV

Matriz de Correlações (amostra t-2)

	END2	IMO2	SIN1	SIN2	ALA2	LN PL1	LN PL2	LN AT1	LN AT2	RFP1
END2		0,9940	-0,0527	-0,3431	0,8473	-0,2330	-0,4404	-0,1756	-0,2330	-0,0790
		(54)	(54)	(54)	(54)	(54)	(54)	(54)	(54)	(54)
		0,0000	0,7049	0,0111	0,0000	0,0899	0,0009	0,2040	0,0900	0,5701
IMO2	0,9940		-0,0664	-0,3418	0,7960	-0,2053	-0,4087	-0,1625	-0,2191	-0,0700
	(54)		(54)	(54)	(54)	(54)	(54)	(54)	(54)	(54)
	0,0000		0,6331	0,0114	0,0000	0,1364	0,0022	0,2403	0,1114	0,6150
SIN1	-0,0527	-0,0664		0,8017	0,0260	0,4904	0,4596	0,5691	0,5506	0,4470
	(54)	(54)		(54)	(54)	(54)	(54)	(54)	(54)	(54)
	0,7049	0,6331		0,0000	0,8520	0,0002	0,0005	0,0000	0,0000	0,0007
SIN2	-0,3431	-0,3418	0,8017		-0,3338	0,5431	0,5914	0,5773	0,5892	0,3534
	(54)	(54)	(54)		(54)	(54)	(54)	(54)	(54)	(54)
	0,0111	0,0114	0,0000		0,0136	0,0000	0,0000	0,0000	0,0000	0,0088
ALA2	0,8473	0,7960	0,0260	-0,3338		-0,3204	-0,5081	-0,1996	-0,2524	-0,1452
	(54)	(54)	(54)	(54)		(54)	(54)	(54)	(54)	(54)
	0,0000	0,0000	0,8520	0,0136		0,0182	0,0001	0,1479	0,0655	0,2947
LN PL1	-0,2330	-0,2053	0,4904	0,5431	-0,3204		0,8985	0,9510	0,8838	0,4957
	(54)	(54)	(54)	(54)	(54)		(54)	(54)	(54)	(54)
	0,0899	0,1364	0,0002	0,0000	0,0182		0,0000	0,0000	0,0000	0,0001
LN PL2	-0,4404	-0,4087	0,4596	0,5914	-0,5081	0,8985		0,8653	0,9489	0,3067
	(54)	(54)	(54)	(54)	(54)	(54)		(54)	(54)	(54)
	0,0009	0,0022	0,0005	0,0000	0,0001	0,0000		0,0000	0,0000	0,0241
LN AT1	-0,1756	-0,1625	0,5691	0,5773	-0,1996	0,9510	0,8653		0,9131	0,4682
	(54)	(54)	(54)	(54)	(54)	(54)	(54)		(54)	(54)
	0,2040	0,2403	0,0000	0,0000	0,1479	0,0000	0,0000		0,0000	0,0004
LN AT2	-0,2330	-0,2191	0,5506	0,5892	-0,2524	0,8838	0,9489	0,9131		0,2671
	(54)	(54)	(54)	(54)	(54)	(54)	(54)	(54)		(54)
	0,0900	0,1114	0,0000	0,0000	0,0655	0,0000	0,0000	0,0000		0,0509
RFP1	-0,0790	-0,0700	0,4470	0,3534	-0,1452	0,4957	0,3067	0,4682	0,2671	
	(54)	(54)	(54)	(54)	(54)	(54)	(54)	(54)	(54)	
	0,5701	0,6150	0,0007	0,0088	0,2947	0,0001	0,0241	0,0004	0,0509	

Correlação de Person
(Tamanho da Amostra)
P-Valor

Matriz de Correlações (amostra t-1)

	ILC	LN PL	LN AT	PLP	IDA	SIN	RFP
ILC		0,2851	0,2170	0,3925	-0,1184	0,2423	0,3421
		(69)	(69)	(69)	(69)	(69)	(69)
		0,0176	0,0732	0,0009	0,3327	0,0449	0,0040
LN PL	0,2851		0,9333	0,4698	-0,2290	0,4546	0,4909
	(69)		(69)	(69)	(69)	(69)	(69)
	0,0176		0,0000	0,0000	0,0584	0,0001	0,0000
LN AT	0,2170	0,9333		0,2012	-0,3092	0,5254	0,4740
	(69)	(69)		(69)	(69)	(69)	(69)
	0,0732	0,0000		0,0974	0,0097	0,0000	0,0000
PLP	0,3925	0,4698	0,2012		0,0642	0,0663	0,3372
	(69)	(69)	(69)		(69)	(69)	(69)
	0,0009	0,0000	0,0974		0,6002	0,5884	0,0046
IDA	-0,1184	-0,2290	-0,3092	0,0642		-0,4129	-0,1096
	(69)	(69)	(69)	(69)		(69)	(69)
	0,3327	0,0584	0,0097	0,6002		0,0004	0,3700
SIN	0,2423	0,4546	0,5254	0,0663	-0,4129		0,4237
	(69)	(69)	(69)	(69)	(69)		(69)
	0,0449	0,0001	0,0000	0,5884	0,0004		0,0003
RFP	0,3421	0,4909	0,4740	0,3372	-0,1096	0,4237	
	(69)	(69)	(69)	(69)	(69)	(69)	
	0,0040	0,0000	0,0000	0,0046	0,3700	0,0003	

Correlação de Person
(Tamanho da Amostra)
P-Valor

Anexo V

ANÁLISE DOS COMPONENTES PRINCIPAIS DE T-1
Variáveis: ILC, LN PL, LN AT, PLP, IDA, SIN, RFP

Data input: observations
Number of complete cases: 69
Missing value treatment: listwise
Standardized: yes

Number of components extracted: 2

Principal Components Analysis

Component Number	*Eigenvalue*	*Percent of Variance*	*Cumulative Percentage*
1	3,15527	45,075	45,075
2	1,30999	18,714	63,789
3	0,888968	12,700	76,489
4	0,673515	9,622	86,111
5	0,515396	7,363	93,473
6	0,433987	6,200	99,673
7	0,0228752	0,327	100,000

ANÁLISE DOS COMPONENTES PRINCIPAIS DE T-1
Variáveis: END2, IMO1, SIN1, SIN2, ALA2, LN PL1, LN PL2, LN AT1, LN AT2, RFP1

Data input: observations
Number of complete cases: 54
Missing value treatment: listwise
Standardized: yes

Number of components extracted: 3

Principal Components Analysis

Component Number	*Eigenvalue*	*Percent of Variance*	*Cumulative Percentage*
1	5,09444	50,944	50,944
2	1,74103	17,410	68,355
3	1,1563	11,563	79,918
4	0,936896	9,369	89,287
5	0,681396	6,814	96,101
6	0,179409	1,794	97,895
7	0,113725	1,137	99,032
8	0,0733204	0,733	99,765
9	0,0197917	0,198	99,963
10	0,00369601	0,037	100,000

Anexo VI

Análise Discriminante para amostra t-1

Prior Probabilities for Groups

SOLV	Prior	Cases Used in Analysis Unweighted	Cases Used in Analysis Weighted
0	,741	40	40,000
1	,259	14	14,000
Total	1,000	54	54,000

Classification Results[a]

		SOLV	Predicted Group Membership 0	Predicted Group Membership 1	Total
Original	Count	0	41	0	41
		1	10	18	28
	%	0	100,0	,0	100,0
		1	35,7	64,3	100,0

a. 85,5% of original grouped cases correctly classified.

Variables Entered/Removed[a,b,c,d]

Step	Entered	Wilks' Lambda Statistic	df1	df2	df3	Exact F Statistic	df1	df2	Sig.
1	GF	,574	1	1	52,000	38,519	1	52,000	,000
2	LN_PL	,383	2	1	52,000	41,003	2	51,000	,000
3	ORG	,346	3	1	52,000	31,495	3	50,000	,000

At each step, the variable that minimizes the overall Wilks' Lambda is entered.

a. Maximum number of steps is 22.

b. Minimum partial F to enter is 3.84.

c. Maximum partial F to remove is 2.71.

d. F level, tolerance, or VIN insufficient for further computation.

Logit para amostra t-1

Estimated Regression Model (Maximum Likelihood)

Parameter	*Estimate*	*Standard Error*	*Estimated Odds Ratio*
CONSTANT	13,1412	3,98715	
Recl	1,71434	1,31103	5,55302
LN PL	-1,07773	0,313323	0,340369
GF = 0	18,2195	927,76	8,17764E7

Likelihood Ratio Tests

Factor	*Chi-Squared*	*Df*	*P-Value*
Recl	5,36953	1	0,0205
LN PL	37,0854	1	0,0000
GF	15,0681	1	0,0001

Prediction Performance – Percent Correct

Cutoff	*TRUE*	*FALSE*	*Total*
0,0 0,05	100,00 100,00	0,00 68,29	40,58 81,16
0,1	100,00	80,49	88,41
0,15	100,00	80,49	88,41
0,2	100,00	82,93	89,86
0,25	92,86	82,93	86,96
0,3	92,86	87,80	89,86
0,35	92,86	87,80	89,86
0,4	89,29	92,68	91,30
0,45	85,71	92,68	89,86
0,5	85,71	95,12	91,30
0,55	82,14	95,12	89,86
0,6	82,14	95,12	89,86
0,65	82,14	95,12	89,86
0,7	82,14	97,56	91,30
0,75	78,57	97,56	89,86
0,8	78,57	97,56	89,86
0,85	71,43	97,56	86,96
0,9	64,29	97,56	84,06
0,95	64,29	100,00	85,51
1,0	0,00	100,00	59,42

Redes Neurais para amostra t-1

Neural Network Bayesian Classifier – Solv

Classification factor: Solv
Input factors: Recl, ILC, SIN,LN PL, PLP, IDA, RFP, TAM, GF, RP ORG

Prior probabilities: proportional to occurrence in training set
Error costs: equal for all classes

Number of cases in training set: 69
Number of cases in validation set: 0

Spacing parameter used: 0,0984375 (optimized by jackknifing during training)

Training Set

Solv	*Members*	*Percent Correctly Classified*
0	41	92,6829
1	28	71,4286
Total	69	84,058

Classification Table

Actual	*Group*	*Predicted*	
Solv	*Size*	*0*	*1*
0	41	38	3
		(92,68%)	(7,32%)
1	28	8	20
		(28,57%)	(71,43%)

Percent of training cases correctly classified: 84,06%

Modelo de ADM para amostra t-2

Classification Table

Actual	*Group*	*Predicted*	
Solv	*Size*	*0*	*1*
0	41	39	2
		(95,12%)	(4,88%)
1	13	3	10
		(23,08%)	(76,92%)

Percent of cases correctly classified: 90,74%

Discriminant	*Eigenvalue*	*Relative*	*Canonical*
Function		*Percentage*	*Correlation*
1	1,46917	100,00	0,77137

Functions	*Wilks*			
Derived	*Lambda*	*Chi-Squared*	*DF*	*P-Value*
1	0,404994	46,0981	2	0,0000

Classification Function Coefficients for Solv

	0	*1*
LN PL2	3,63406	2,70775
GF2	4,1039	-1,33456
CONSTANT	-31,8741	-15,5629

Logit para a amostra t-2

Estimated Regression Model (Maximum Likelihood)

		Standard	*Estimated*
Parameter	*Estimate*	*Error*	*Odds Ratio*
CONSTANT	17,9435	5,72532	
LN PL2	-1,43684	0,451697	0,237678

Likelihood Ratio Tests

Factor	*Chi-Squared*	*Df*	*P-Value*
LN PL2	38,3964	1	0,0000

Prediction Performance – Percent Correct

Cutoff	*TRUE*	*FALSE*	*Total*
0,0	100,00	0,00	24,07
0,16	100,00	87,80	90,74
0,32	84,62	92,68	90,74
0,48	76,92	92,68	88,89
0,64	76,92	92,68	88,89
0,8	61,54	100,00	90,74
0,96	15,38	100,00	79,63

Redes Neurais para amostra t-1

Neural Network Bayesian Classifier - Solv
Classification factor: Solv
Input factors: ALA2 SIN2 LN PL2 RFP1 TAM GF1 GF2 RP Recl

Prior probabilities: non-informative
Error costs: equal for all classes

Number of cases in training set: 54
Number of cases in validation set: 0

Spacing parameter used: 0,298438 (optimized by jackknifing during training)

Training Set

		Percent Correctly
Solv	*Members*	*Classified*
0	41	97,561
1	13	53,8462
Total	54	87,037