

CLASSIFICAÇÃO DE *RATINGS* DE RISCO SOBERANO DE PAÍSES EMERGENTES A
PARTIR DE FUNDAMENTOS MACROECONÔMICOS UTILIZANDO REDES
NEURAS ARTIFICIAIS

Palavras Chave: *Rating* de risco soberano. Fundamentos macroeconômicos. Redes neurais artificiais.

Classificação JEL: C45, G14, E44

Bruno Ferreira Frascaroli

Bacharel em Economia pela UFV

Mestre em Economia pela UFPB

Doutorando em Economia pelo PIMES – UFPE

Luciano da Costa Silva

Bacharel em Física pela UFPB

Mestre em Matemática Aplicada pelo IME – USP

Doutor em Matemática Aplicada pelo IME – USP

Professor Doutor do Departamento de Estatística/ Mestrado em Economia – UFPB

Oswaldo Cândido da Silva Filho

Bacharel em Economia pela UFPB

Mestre em Economia pela UFPB

Doutorando em Economia pelo PPGE – UFRGS

CLASSIFICAÇÃO DE RATINGS DE RISCO SOBERANO DE PAÍSES EMERGENTES A PARTIR DE FUNDAMENTOS MACROECONÔMICOS UTILIZANDO REDES NEURAIIS ARTIFICIAIS

RESUMO

O mercado financeiro é caracterizado pela presença de assimetria de informação. Assim, diante do desenvolvimento e maior integração destes, instituições e dispositivos que têm como propósito minimizar os transtornos gerados pela assimetria de informação são de muita importância. Especialmente no caso de países como o Brasil, que têm ampla necessidade de captação de recursos no mercado externo. Um destes dispositivos é o *rating* de risco soberano, que constitui peça chave para determinar as condições dos mercados de crédito fundamentais para o desenvolvimento de países emergentes. O objeto de estudo do presente trabalho foi estudar a classificação dos *ratings* de risco soberano realizadas pelas agências de *rating* e seu propósito foi, a partir dos fundamentos macroeconômicos, encontrar uma classificação de risco dos diversos países emergentes utilizando o critério de risco estimado por Redes Neurais Artificiais. Tomando a classificação estimada, observamos o grau de homogeneidade entre as atribuições das agências e os fundamentos macroeconômicos dos países da amostra. Observamos que quatro destes fundamentos estão mais diretamente ligados a estas atribuições. Logo após, utilizamos redes neurais para fazer simulações de *cenários* das condições externas de crédito para a economia brasileira a partir de mudanças destes fundamentos macroeconômicos.

Palavras Chave: *Rating* de risco soberano, fundamentos macroeconômicos, redes neurais artificiais.

ABSTRACT

The financial market is characterized by the presence of information asymmetry. Therefore, due to the development and larger integration of these, institutions and devices that aim at minimizing the problems generated by information asymmetry are indeed very important. Especially in the case of developing countries, like Brazil, which need more resources in the external market. One of these devices is the sovereign risk rating, which constitutes a key piece in the determination of credit market conditions, essential to the growth of developing countries. The objective of the present work was to study the classification of sovereign risk ratings and its purpose was, based on macroeconomics foundations, to find a classification of risk of several emerging countries, by using the risk criterion estimated by the Artificial Neural Networks. According to the estimated classification, it is possible to observe the homogeneity degree among the attributions of agencies and macroeconomics foundations of the sampled countries. Four of these foundations are more directly connected with these attributions. After this, we used Neural Networks to promote simulations of sceneries of the credit external conditions for the Brazilian economy, starting with changes in the macroeconomics foundations.

Key-Words: Sovereign risk rating, macroeconomics foundations, artificial neural networks

Classificação JEL: C45, G14, E44

Introdução

Transações financeiras são inexoravelmente caracterizadas por assimetrias de informação entre fornecedores e tomadores de recursos. Os últimos têm necessariamente conhecimento mais amplo sobre sua própria capacidade de pagamento tanto a respeito da disposição de recursos e prazo de pagamento do que aqueles que lhes fornecem recursos. Portanto, do ponto de vista dos fornecedores de recursos, a presença de tal assimetria afetará os prêmios pelos riscos de crédito exigidos em qualquer operação de crédito e aquisição de títulos financeiros (CANUTO e SANTOS, 2003b).

Nos estudos sobre determinantes de crescimento e desenvolvimento econômico das nações é de suma importância estudar-se o mercado financeiro destas. O objeto de estudo do presente trabalho foi estudar a classificação dos *ratings* de risco soberano realizadas pelas agências de *rating* e seu propósito foi, a partir dos fundamentos macroeconômicos das diversas nações, encontrar uma classificação de risco dos diversos países emergentes utilizando o critério de risco estimado por Redes Neurais Artificiais. Tomando a classificação estimada, observamos a homogeneidade entre as atribuições das agências e os fundamentos macroeconômicos dos países da amostra. Esta classificação se baseou na localização de elementos constituintes e classificação *a posteriori* das mudanças de estado dos movimentos das séries temporais macroeconômicas determinantes das atribuições dos *ratings* de risco soberano desses países e das séries de risco soberano fornecidas pelas agências de *rating*. Logo após, utilizamos redes neurais para fazer simulações de *cenários* das condições externas de crédito para a economia brasileira a partir de mudanças em seus fundamentos macroeconômicos servindo, desta maneira, como uma ferramenta objetiva de apoio à decisão.

As redes neurais são aproximadores universais de funções. Elas são bastante similares às regressões lineares e não-lineares pelo método de mínimos quadrados ordinários (MQO), logo as primeiras podem ser vistas como uma abordagem estatística alternativa para resolver problemas que envolvem análise recursiva de informações. Ambos métodos envolvem minimização da soma dos quadrados dos erros de estimação (KAASTRA e BOYD, 1996).

Como a economia brasileira necessita de fluxos de capitais externos para equilibrar seu balanço de pagamentos, é possível compreendermos como os fundamentos macroeconômicos e as atribuições de *ratings* afetam a economia restringindo ou ampliando sua captação de recursos no mercado financeiro internacional. Vale ressaltar que mesmo após a estabilização de algumas variáveis macroeconômicas a partir de 1994, a dificuldade de captação de recursos no mercado financeiro internacional provocou uma mudança na política cambial em janeiro de 1999.

Desta forma, torna-se claro a importância de estudos sobre as condições do mercado de crédito internacional haja vista que países emergentes como o Brasil, não são auto-suficientes em recursos financeiros tornando-se tomadores líquidos de recursos neste mercado. Reinhart (2001) salienta que, justamente para países emergentes tomadores líquidos de recursos, as condições de captação de recursos é mais crítica. Para estes países, as agências de *rating* possuem um comportamento mais severo, no sentido de, frequentemente, penalizar estes países com *downgrades*¹ mesmo que seus fundamentos macroeconômicos estejam estáveis.

Com base em verificações empíricas anteriores a este trabalho, como a destacada em Reinhart (Op. Cit.), direcionamos a análise para a relação entre as atribuições de *ratings* para os países emergentes e seus respectivos fundamentos macroeconômicos, no sentido de observarmos se realmente há uma relação próxima de causalidade entre flutuações nos

¹ Elevação de risco soberano na escala das agências de *ratings*.

fundamentos macroeconômicos, isto é, a capacidade dos países saldarem suas obrigações, e as atribuições de *ratings* realizadas pelas agências.

Um *rating* é uma estimativa da probabilidade de haver inadimplência futura. É importante entender que os *ratings* soberanos abordam o risco de crédito de governos nacionais (STANDARD & POOR'S, 2004). *Rating* é um ponto de vista sobre risco relativo baseado na capacidade e vontade do emissor para pagar completamente e no prazo acordado, principal e juros, durante o período de vigência do instrumento de dívida e severidade da perda, em caso de inadimplência (MOODY'S, 2003).

Quanto maior o risco que investidores assumem em adquirir algum título de um governo soberano, menor a capacidade deste governo em tornar atraente esta aquisição e, portanto, atrair capital estrangeiro. Em consequência, maior é o prêmio remunerado aos investidores para compensá-los por assumir esse risco. Cantor e Packer (1996) confirmam que existe uma correlação inversa entre as atribuições de *ratings* realizadas pelas agências e o *spread* de prêmios pagos entre títulos dos governos soberanos e os títulos do governo norte-americano, isto é, quanto menor o conceito atribuído pela agência (maior risco) maior a remuneração paga pelo título, embora a habilidade dos *ratings* para explicar *spreads* relativos não pode ser completamente atribuída à correlação mútua com indicadores de risco soberanos.

Stiglitz e Grenwald (2004), justificam que o mercado de capitais possui características especiais pelo fato de negociar crédito, isto é, o mercado de capitais possui particularidades que o torna diferente dos demais. Segundo eles, existe informação assimétrica neste mercado. Este fenômeno causa problemas de risco moral e seleção adversa². O risco moral surge pela incapacidade dos fornecedores de crédito, seja operacional ou por elevados custos, de monitorarem as ações dos tomadores de recursos após o contrato de concessão de crédito. A seleção adversa surge da informação assimétrica obtida pelos fornecedores de crédito a respeito dos projetos de investimentos dos tomadores de recursos que serão feitos com recursos emprestados.

Quando é possível diminuir o efeito maléfico das assimetrias de informação no sistema financeiro, as transações financeiras se desenvolvem. Assim, algumas medidas como coleta e processamento de informações antes das operações, firmação de contratos mais claros e monitoramento dos tomadores de recursos de modo a controlar o uso dos recursos após seu fornecimento agem no sentido de desenvolver o sistema financeiro. Entretanto, tais medidas operam com custos que, às vezes, oneram demasiadamente as partes que negociam recursos e nem sempre essas medidas têm eficácia suficiente para suprimir essa assimetria de informação.

Neste sentido, a presença de instrumentos de ordem legal, assim como instrumentos institucionais que sustentem o cumprimento de contratos e o exercício de garantias, a assimetria de informações e os prêmios cobrados como compensação pelos riscos de crédito diminuem.

Em conformidade com Canuto e Santos (2003b), um risco em particular é o risco soberano, isto é, o risco de crédito vinculado a operações de crédito concedidas a estados soberanos. Os colaterais e o cumprimento dos contratos são distintos daqueles presentes nos casos de crédito para agentes privados. Adicionalmente, a disponibilidade da capacidade de pagamento é diferente, pois entre seus determinantes estão as variáveis macroeconômicas que indicam as expectativas a cerca da capacidade futura de pagamento daquele país que toma recursos emprestados. Entre estas, podemos destacar as reservas de divisas estrangeiras, crescimento econômico, capacidade de arrecadação tributária, etc.

Em complemento, este trabalho faz uma breve análise acerca dos principais modelos de redes neurais que foram utilizados durante as estimações experimentais. Encontramos,

² Para uma discussão mais detalhada sobre risco moral e seleção adversa consulte Mas-Colell, Whinston e Green (1995).

treinamos através de aprendizagem supervisionada e testamos uma arquitetura de redes neurais para analisar as séries temporais macroeconômicas de um conjunto de países emergentes e, a partir delas, a rede neural pôde aprender como funciona a atribuição de *ratings* de risco soberano para estes países; e, a partir da arquitetura encontrada nos experimentos, fizemos simulações sobre as condições de crédito para a economia brasileira a partir de mudanças dos comportamentos dos determinantes macroeconômicos das atribuições de *rating*.

O presente trabalho está organizado da seguinte forma. Além desta introdução, na seção 2, discutimos a problemática envolvendo a questão dos *ratings*, das agências e dos possíveis impactos dos *ratings* no lado real da economia. Na terceira seção, abordamos os procedimentos metodológicos do trabalho, aspectos históricos das redes neurais, detalhando seus principais aspectos técnicos. Logo após, dedicamos a seção 4 para apresentarmos as variáveis que fazem parte da entrada da rede neural e como estas foram previamente trabalhadas para serem introduzidas no modelo. Na seção 5, discutimos resumidamente a implementação de uma rede neural. Após esta seção, segue-se a seção 6, na qual analisamos os resultados encontrados no trabalho. Finalizando, temos a seção 7 conclusiva em que discutimos a ligação da problemática econômica tratada com os resultados empíricos fornecidos pela rede neural.

2 Literatura

O *rating* de risco soberano é um indicador que busca expressar o risco ao qual investidores estrangeiros estão submetidos ao adquirirem títulos de algum país. Os *ratings* de risco soberano são construídos com base em análises das conjunturas econômica, social e política dos países e, por este motivo, podem ser subjetivos porque envolvem julgamento não só das variáveis macroeconômicas internas e externas no presente, mas também das perspectivas das mesmas para o futuro.

As agências de *rating* são empresas independentes de qualquer interesse, quer por parte de governos ou de empresas privadas. Essa característica lhes permite ter como princípios: independência, objetividade, credibilidade e liberdade de divulgação de avaliações com relação à qualidade de crédito dos emitentes e emissões de dívida (*STANDARD & POOR'S*, 2002a). Dentre as principais agências de *rating* de risco temos, por exemplo, *Standard & Poor's*, *Moody's Investor Service* e *Fitch IBCA*³.

A presença de agências de *rating* como fornecedoras de mercadoria, neste caso, o processamento de informações, constitui peça-chave para que a oferta de recursos financeiros não fique restrita às instituições financeiras domésticas, permitindo ao governo central destas economias e às empresas domésticas, ampliarem suas possibilidades de tomarem recursos.

Os *ratings* normalmente tentam refletir os fatores específicos de risco de um país, os quais podem trazer conseqüências sobre a capacidade de uma entidade para saldar integral e pontualmente sua dívida. Fazem parte destes fatores de riscos o risco de intervenção soberana, como, por exemplo, o risco de um país impor políticas cambiais ou decretar moratória da dívida. Além disso, inclui os riscos econômico ou país, que se referem ao ambiente econômico, político e social, o qual influencia tanto os *ratings* do próprio país quanto aquelas entidades emissoras ali presentes (*STANDARD & POOR'S*, 2001a).

A Tabela 1 traz as escalas das classificações feitas pelas principais agências de *rating* do mundo, onde temos uma escala numérica crescente de risco que vai de 1 a 24. Países que se encontram na escala de 1 a 10 pertencem ao grupo de países de menor risco e, países que se encontram na escala acima de 10, fazem parte de países de maior risco, o que configura um

³ Segundo Bone (2005), as agências *Standard & Poor's* e *Moody's Investor Service* detém juntas cerca de 80% do mercado de classificação de *ratings*.

comportamento especulativo no mercado financeiro. Países que estão na ordem da escala de 22 a 24 são países que declararam moratória de suas dívidas. Logo, as classificações de obrigações nesta categoria são baseadas na possibilidade de recuperação parcial ou total do empréstimo.

Tabela 1 – Sistemas de classificação de *ratings*

Posição	Empresas			Escala
	Moody's	S & P	Fitch	Numérica
menor risco	Aaa	AAA	AAA	1
	Aa1	AA+	AA+	2
	Aa2	AA	AA	3
	Aa3	AA-	AA-	4
	A1	A+	A+	5
	A2	A	A	6
	A3	A-	A-	7
	Baa1	BBB+	BBB+	8
	Baa2	BBB	BBB	9
	Baa3	BBB-	BBB-	10
especulativa	Ba1	BB+	BB+	11
	Ba2	BB	BB	12
	Ba3	BB-	BB-	13
	B1	B+	B+	14
	B2	B	B	15
	B3	B-	B-	16
	Caa1	CCC+	CCC+	17
	Caa2	CCC	CCC	18
	Caa3	CCC-	CCC-	19
	-	CC	CC	20
	-	C	C	21
	Ca	SD	DDD	22
	C	D	DD	23
	-	-	D	24

Fonte: Standard & Poor's, Fitch Ratings e Moody's

2.1 O papel dos *ratings* no mercado

O *rating* de risco soberano exerce impacto direto ou indireto sobre a qualidade de crédito das entidades que operam em uma determinada localização de diversas maneiras. Cantor e Packer (1996), ressaltam que os *ratings* são importantes não apenas porque alguns dos maiores emissores de dívidas são governos soberanos, mas também porque de acordo com as atribuições de *ratings*, a captação de recursos por governos estaduais, municipais ou empresas privadas localizados nestes países é afetada.

Na presença de informações assimétricas nos mercados financeiros mundiais, as classificações realizadas pelas agências de *rating* do risco de crédito são sinalizações para os agentes participantes do mercado financeiro.

Bone (2004) resume os motivos pelos quais, o mercado sustenta a existência das agências de *rating*:

- O *rating* deve possuir idoneidade, isto é, ele vale apenas quando é confiável. Dado que uma agência de *rating* se financia cobrando o custo de elaboração do *rating* dos emitentes de dívidas, ela não possui qualquer incentivo de produzir *ratings* viesados ou não-confiáveis;
- Um outro argumento importante do mercado para o *rating* se deve aos custos de captar e interpretar informações sobre os emitentes de dívidas. Assim, as agências de *rating* possuem retorno de escala na captação e interpretação dessas informações;

- O *rating* tem a capacidade de sintetizar as informações sobre a futura qualidade de crédito do emitente de dívidas de uma forma clara e simples para o mercado.

2.2 Críticas sobre o papel dos *ratings*

Estudos mostram que há um atraso nas mudanças nas atribuições dos *ratings* frente às mudanças ocorridas nos mercados, e estes se antecipam às mudanças nas atribuições dos *ratings* (PARTNOY, 2002). Assim, a eficácia do objetivo do *rating* seria gravemente prejudicada, pois se as agências de *rating* se propõem a avaliar a condição futura de pagamento de um emitente de dívida, e esta é realizada após a mudança de percepção do mercado, os agentes não mais se apoiariam no *rating* como uma informação fidedigna de tal condição futura de pagamento de um emitente de dívida.

Além disso, Cantor e Packer (1996), observam que há uma forte convergência das atribuições dos *ratings* realizados pelas agências *Standard & Poor's* e *Moody's*, de modo que, quando estas agências atribuem *ratings* diferentes, esta diferença frequentemente é de apenas uma posição na escala de *ratings*, o que configura uma tendência conservadora destas atribuições.

Segundo Partnoy (2002), existe um paradoxo no mercado financeiro envolvendo os *ratings* atribuídos pelas agências. Embora haja cada vez menos informações contidas nos *ratings* atribuídos pelas agências, estas parecem estar em contínua prosperidade. O autor aponta para a existência de ineficiências de ordem legal existentes nos mercados financeiros que explicam este paradoxo. Numerosas regras legais e regulamentações dependem substancialmente dos *ratings* e, particularmente, daqueles atribuídos por uma pequena parte das agências de *rating* que fazem parte da *Nationally Recognized Statistical Ratings Organizations (NRSROs)*. Contudo, as barreiras para entrar no mercado de *NRSRO* são proibitivas.

Logo, os *ratings* atribuídos pelas agências de *rating* que fazem parte da *NRSRO* são valiosos para os participantes do mercado financeiro mesmo que o conteúdo informacional deles não seja maior que a informação pública neste contida. Agentes que administram recursos de investidores institucionais, por exemplo, estão submetidos às regulamentações internas da administração dos fundos que atribuem o risco existente na construção das carteiras com base nos *ratings*. Assim, mesmo que os *ratings* não forneçam uma informação adequada sobre os riscos de determinados emitentes, os administradores desses fundos são obrigados a utilizá-los. O trabalho de Partnoy (Op. Cit.) demonstra que o aumento da utilização dos *ratings* como instrumento de regulamentação, após 1973, mudou a natureza do produto vendido pelas agências de *rating*, pois os *ratings* ao invés de fornecerem informação, determinam a conduta dos agentes no mercado financeiro.

As agências de *rating* fracassaram em antecipar o declínio rápido nos preços de centenas de papéis financeiros na crise de 1929 e, em consequência deste fato, numerosos *ratings* foram abruptamente baixados, o que pela primeira vez, demonstra uma mudança generalizada na atribuição de *ratings* pelas agências, tornando-se mais conservadoras (PARTNOY, Op. Cit.).

Mais recentemente, de acordo com Ferri, Liu e Stiglitz (1999), diversos observadores e instituições do mercado financeiro como, por exemplo, *World Bank* e *IMF*, apontaram para a falha das agências de *rating* em alertar antecipadamente o mercado sobre a crise asiática de 1997. Parecido com o que houve na crise de 1929, as agências de *rating* baixaram os *ratings* de risco soberano de alguns países envolvidos na crise configurando novamente um comportamento excessivamente conservador em vista do que os fundamentos macroeconômicos justificariam.

Segundo Ferri, Liu e Stiglitz (Op. Cit.) em reconhecimento a esta falha, uma destas agências, a *Fitch IBCA*, em comentário público em janeiro de 1998, reconhece não ter dado a

devida atenção às dívidas de curto prazo em moeda estrangeira destes países. Após a crise asiática, a *Moody's*, em declaração, também enfatiza a importância das dívidas de curto prazo em moeda estrangeira.

Bone (2002) afirma que antes da crise na Ásia em 1997 as mudanças nos *ratings* soberanos não eram significativas e se mostravam historicamente estáveis. Após a crise asiática, mais precisamente de julho de 1997 a novembro de 1998, foram observados *downgrades* abruptos não comparáveis aos que ocorriam anteriormente.

O trabalho de Ferri, Liu e Stiglitz (1999), postula a existência de uma regra procíclica das agências de *rating* o que prolongaria os efeitos de crises sobre as economias através de comportamentos excessivamente conservadores dessas agências na medida em que elas baixam excessivamente os *ratings* de risco soberano de economias que já possuem baixos *ratings* de risco soberano na escala. Ao passo que, segundo os autores, em economias com *rating* de risco soberanos mais elevados isso não acontece, pelo contrário, essas economias experimentam atribuições crescentes de *rating*.

Ferri, Liu e Stiglitz (Op. Cit.), argumentam que após as crises, as agências de *rating* se tornam mais conservadoras porque são pegadas de surpresa e têm mais dificuldade de reconstruir suas reputações. Assim, como a reputação dessas agências é prejudicada também o retorno de seus serviços também é prejudicado. Logo, elas são incentivadas a se tornarem mais conservadoras para não falharem novamente.

Contudo, os *ratings* atribuídos pelas agências não devem ser atribuídos como um remédio às crises financeiras.

2.3 Determinantes das atribuições de *ratings*

Os *ratings* de risco soberano atribuídos pelas agências de *rating* para as diversas nações do mundo usam critérios que nem sempre são claros, ou seja, não há um padrão de quais são os determinantes para as atribuições destes *ratings* e nem das ponderações utilizadas para cada determinante, pois estes *ratings* são compostos de uma combinação de determinantes qualitativos e quantitativos.

The agencies never describe their terms or analysis precisely or say, for example, that a particular rating has a particular probability of default, and they stress that the ratings are qualitative and judgmental. This secretive, qualitative process is not the type of process one would expect if the agencies had survived based on their ability to accumulate reputational capital. On the other hand, such processes make it more likely that an agency would be able to survive in a non-competitive market; if the rating process had been public or quantitative (rather than qualitative), other market entrants easily could have duplicated the rating agencies technology and methodology (PARTNOY, 2002).

Dentre os determinantes qualitativos de atribuição dos *ratings* temos determinantes de riscos políticos, como, por exemplo, a probidade das lideranças, estabilidade e transparência das instituições, que fazem parte do julgamento dos analistas sobre o comportamento destes governos frente às decisões em momentos de crises econômicas. Haque, Mark e Mathieson (1998), confirmaram empiricamente que variáveis políticas não têm nenhum ou quase nenhum impacto sobre a decisão de atribuição de *ratings* por parte das agências. Uma possível explicação apontada por eles é a de que as variáveis econômicas absorvem instantaneamente flutuações originadas no âmbito político. Diante disso, no presente trabalho utilizamos fundamentos macroeconômicos para buscarmos explicar a decisão de atribuição de *ratings* pelas agências.

Os determinantes quantitativos incluem diversas medidas de desempenho econômico e financeiro, bem como as obrigações contingenciais, embora o julgamento sobre a integridade da amostra desses dados seja uma questão mais qualitativa. Não há uma fórmula exata para se combinar os escores ao se determinar os *ratings*. As variáveis analíticas são inter-relacionadas e os pesos não são fixos, nem entre os diversos governos soberanos nem ao longo do tempo (STANDARD & POOR'S, 2004).

Cantor e Packer (1996), confirmam que, mesmo para os determinantes quantitativos, é difícil encontrar uma relação entre os pesos atribuídos aos determinantes pela *Moody's* e pela *Standard & Poor's*, por causa do grande número de critérios adotados por estas agências.

A *Standard & Poor's* divide a estrutura dos determinantes dos *ratings* soberanos em categorias. Para atribuir *ratings* de crédito, cada governo soberano é classificado dentro de uma escala – cujas notas vão de um (a mais alta) até seis – aplicadas a cada uma das categorias analíticas (STANDARD & POOR'S, 2004).

Dentre os determinantes, podemos enumerar alguns, na mesma linha de trabalhos como, por exemplo, Cantor e Packer (1996), Canuto, Santos e Porto (2004), Rowland (2004), que serão utilizados como entradas no processo de aprendizagem supervisionada para criação de um critério de risco soberano. Podemos dividir estes determinantes em variáveis utilizando o mesmo critério de divisão adotado por Rowland (2004), apenas adicionando mais uma categoria de variáveis determinantes do desenvolvimento e estabilidade econômica.

Variáveis de Solvência: Taxa de crescimento das exportações de bens e serviços; taxa de crescimento das importações de bens e serviços; e dívida de longo prazo como percentual do produto.

Variáveis de Liquidez: Nível de reservas totais como percentual do produto; dívida externa total como percentual das exportações de bens e serviços; serviço da dívida total como percentual das exportações de bens e serviços; e balança externa de bens e serviços como percentual do produto.

Variáveis de desenvolvimento e estabilidade econômica: Taxa de crescimento do produto *per capita*; evolução do nível de preços ao consumidor; e grau de abertura econômica medidas pela soma do volume das exportações mais importações como percentual do produto.

O modelo econométrico de Cantor e Packer (1996) é seminal, no sentido de ajustar um bom modelo de previsão para as atribuições de *ratings* através de séries temporais de amostra de dados macroeconômicos. Porém, após a crise asiática ocorrida em 1997, o modelo econométrico destes autores não mais consegue uma boa capacidade preditiva das atribuições de *ratings*. Adicionalmente, eles chamam a atenção para a limitação de modelos quantitativos na incapacidade de explicar todos os movimentos das atribuições dos *ratings*, haja vista que estes tipos de modelos têm dificuldade de inserir entre suas variáveis explicativas, variáveis qualitativas.

O trabalho de Ferri, Liu e Stiglitz (2002), chama a atenção para o que seria o modelo utilizado pelas agências na atribuição de *ratings* após a crise asiática de 1997. Este modelo principal é dividido em dois modelos. Um modelo quantitativo em função dos determinantes de ordem macroeconômica. E um modelo de informações *ad hoc* de cada país, refletindo o julgamento das agências. O modelo pode ser expresso da seguinte maneira:

$$Ratings = w_q Ratings_q + w_j Ratings_j$$

$$w_q + w_j = 1$$

Onde

w_q é o peso do julgamento feito pelas agências dos determinantes quantitativos;

w_j é o peso do julgamento feito pelas agências dos determinantes qualitativos;

Temos inúmeras abordagens feitas através de modelos quantitativos ao problema de atribuição de *ratings*. Dentre os trabalhos poderíamos citar o trabalho de Rowland (2004) que

utiliza a técnica de análise coletiva de dados (*pooled data*). Canuto e Santos (2004), utilizam um modelo econométrico de análise coletiva de dados em *cross-section*. Na linha do modelo econométrico de Cantor e Packer (1996), Ferri, Liu e Stiglitz (2002) estimam um modelo MQO com dois tipos de cardinalização para os *ratings*. Leichsenring (2004) estima um modelo de vetores autoregressivos (VAR) para avaliar a relação entre os *ratings* e a taxa de juros doméstica. Bone (2004) utiliza testes de estabilidade de *Chow* para medir a estabilidade das séries temporais de *ratings* soberanos emitidos pelas diversas agências.

Entre os modelos econométricos, podemos citar o problema da cardinalização. Este problema surge da tentativa de cardinalizar os *ratings* para torná-los estimáveis, pois modelos econométricos são incapazes de lidar com conceitos, assim não há como introduzirmos como variável num modelo econométrico um conceito de *rating*. Contudo, ao cardinalizar um conceito de *rating*, podemos incorrer em erros, pois cardinalizações, sejam elas lineares ou não-lineares, estabelecem uma relação quantificável entre os conceitos de *ratings*. Assim, uma atribuição de *rating* igual a 2 (dois), por exemplo, não quer dizer necessariamente que possua o dobro de risco de uma atribuição de *rating* igual a 1 (um).

3 Procedimentos Metodológicos

3.1 Introdução

O processo de estimação utilizado no presente trabalho foi o processo chamado de Redes Neurais Artificiais. Esta metodologia é inspirada nos princípios do funcionamento do cérebro humano para resolução de determinados tipos de problemas, criando a chamada inteligência artificial. Este processo de estimação é muito útil diante de problemas de reconhecimento de padrões e, portanto, de acordo com os objetivos estabelecidos, ele se torna o estimador mais apropriado para nossa análise.

A utilização de redes neurais, assim como a utilização de outros métodos de estimação, possui vantagens e desvantagens. Entre as vantagens, podemos apontar:

- Flexibilidade na modelagem: A hipótese de linearidade não é necessária;
- Flexibilidade estatística: Nenhuma hipótese *a priori* é feita sobre as distribuições de probabilidade envolvidas;
- Categorização: As variáveis dependentes podem ser categorias qualitativas, em vez de apenas numéricas.

Entre suas desvantagens podemos destacar:

- A rede neural pode apresentar dificuldade de configuração em relação à sua estrutura inicial e também no que se refere aos parâmetros dos algoritmos de aprendizado;
- Pode haver dificuldade em apresentar os resultados obtidos na forma da análise estatística tradicional, como intervalos de confiança, estímulo-resposta e relações de causalidade;
- Podem existir dificuldades de convergência e instabilidade inerentes aos algoritmos de otimização empregados.

3.2 Descrição das Redes Neurais

Redes neurais são aproximadores universais de funções, como os estimadores de regressão linear e as séries de Fourier. Seu princípio é inspirado nas redes de conexões de neurônios existentes no cérebro dos animais vertebrados. Sua unidade fundamental é o *neurônio*, onde verificamos 3 elementos básicos:

1) Um conjunto de sinapses, caracterizadas por pesos w_{kj} , sendo k o índice utilizado para designar o neurônio e j o índice da sinapse. Um sinal x_j na entrada da sinapse j é multiplicado pelo peso sináptico w_{kj} .

- 2) Um somador, chamado de *junção aditiva*, que soma os sinais de entrada, ponderados pelos respectivos w_{kj} .
- 3) Uma função de transferência para restringir a amplitude da saída do neurônio.

O *bias* b_k , é introduzido para melhorar o ajuste da função aproximada. Normalmente, o *bias*, tem um valor positivo e seu propósito é análogo ao intercepto nas regressões dos modelos econométricos.

Assim, podemos descrever um neurônio matematicamente da seguinte forma:

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (1)$$

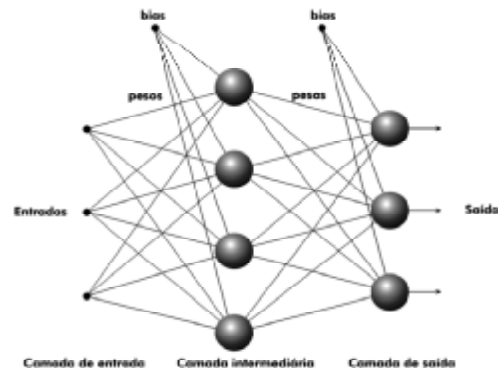
$$y_k = j(v_k) \quad (2)$$

Onde:

v_k é a saída do combinador linear (somador).

Posteriormente, os neurônios são organizados em uma *rede*, com a saída de um servindo como entrada para outros. A Figura 1 mostra a arquitetura mais comum de rede neural, na qual os neurônios são dispostos em *camadas*. Na figura, os círculos simbolizam os neurônios e as setas representam as ligações sinápticas entre os neurônios.

Figura 1 – Rede neural com 3 camadas



Fonte: Piazzini (2001)

A função de transferência ou de ativação dá o caráter não linear ao neurônio. Se $j(v_k) = v_k$, então o modelo de neurônio é linear e rede neural funciona de modo análogo a um modelo de regressão linear. A função de transferência a ser escolhida pelo pesquisador é de suma importância para o bom desempenho do modelo a ser utilizado. Algumas formas de função são: função de limiar, função linear por partes, função sigmóide e função tangente hiperbólica⁴.

3.3 Algoritmos de aprendizado

Refere-se ao aprendizado por meio de regras bem definidas para solução de problemas de aprendizado. Existem muitos algoritmos específicos para aprendizagem de redes neurais, diferenciando entre si pela maneira como os pesos sinápticos são modificados. Os algoritmos de aprendizado podem se dividir em:

1) Aprendizado supervisionado

Este método de aprendizagem consiste na adoção de uma função de *custo* na rede neural, onde cada vez que a rede erra a resposta desejada para o padrão de entrada, um fator externo (*professor*) indica quais devem ser os ajustes realizados nos pesos sinápticos de acordo com o erro a fim de diminuir esta resposta incorreta da rede. Logo, o objetivo deste

⁴ Para uma discussão mais detalhada sobre Funções Transferência consulte Fausett (1994).

tipo de aprendizado é, a cada seqüência de aprendizado, fazer com que a rede atinja uma solução estável, isto é, correções cada vez menores nos pesos sinápticos.

2) Aprendizado não-supervisionado

Como o próprio nome diz, é um método de aprendizado onde as redes neurais não utilizam um *professor*, ou seja, não há um algoritmo de correção das falhas das respostas da rede neural. Neste caso, a rede neural recebe a entrada de dados, e os organiza de maneira arbitrária em categorias. Na próxima entrada de dados, esta faz uma verificação se os dados correspondem a alguma categoria já existente e, em caso de não existir, ela cria uma ou mais categorias para classificar estes novos dados.

3.4 O *Perceptron*

Uma rede neural com neurônios utilizando funções de ativação do tipo limiar é chamada *Perceptron*. Estes são utilizados para reconhecimento de padrões, como o reconhecimento de escrita ou de voz. Os dados de entrada consistem de um vetor (x_1, x_2, \dots, x_m) e a saída consiste em uma de N categorias previamente determinadas (por exemplo, as letras *A, B, C*, etc).

Minsky e Papert (1969) analisaram matematicamente o *perceptron* e demonstraram que redes de uma camada não são capazes de solucionar problemas que não sejam linearmente separáveis. Como não acreditavam na possibilidade de se construir um método de treinamento para redes com mais de uma camada, eles concluíram que as redes neurais seriam sempre suscetíveis a essa limitação.

Contudo, o desenvolvimento do algoritmo de treinamento *backpropagation*, por Rumelhart, Hinton e Williams (1986), precedido por propostas semelhantes ocorridas a partir dos 1970's, mostrou que é possível treinar eficientemente redes com camadas escondidas, resultando no modelo de redes neurais artificiais mais utilizados atualmente, as redes *perceptron* multi-camadas (*Multi-Layer Perceptron*), treinadas com o algoritmo *backpropagation* (KUMAR, RAO e SONI, 1995).

3.5 *Multi-Layer Perceptron*

A regra de aprendizado utilizada para treinar uma rede *multilayer perceptron* é chamada Regra Delta Generalizada ou *backpropagation*. Quando um padrão de entrada é apresentado à rede pela primeira vez, esta produz uma saída aleatória. A diferença entre esta saída e a saída desejada constitui o erro. O *backpropagation* se baseia num custo ou uma função de erro baseada nesta diferença para ajustar os pesos sinápticos. A função de erro ou de performance, indicada pelo nome *Least Mean Square (LMS)*, é a soma dos erros quadrados. A intenção do treinamento é buscar cada vez mais diminuir o valor deste erro. O método minimiza o erro e realiza iterativamente ajustes nos pesos sinápticos, passando por todos os padrões de entradas do conjunto de treinamento. Esse método é conhecido como descida de gradiente (*gradient descent*). O processo de aprendizagem prossegue, até que algum critério seja estabelecido como, um mínimo de erro global, ou uma diferença sucessiva mínima entre erros calculados para cada iteração. O *backpropagation* é, na verdade, um método para implementar o processo de gradiente de descida no espaço dos pesos sinápticos para o treinamento de uma rede *feedforward*.

O algoritmo de *backpropagation* pode apresentar alguns problemas em relação à dificuldade de aprendizado. Ao se deparar com padrões de entradas muito complexos, o treinamento é muito lento e existe o risco da rede neural cair num mínimo local.

Paralelamente, também há desvantagem em utilizar camadas escondidas, pois o aprendizado se torna muito mais difícil. A característica principal da camada escondida é que seus elementos se organizam de tal forma que cada elemento aprenda a reconhecer

características diferentes do espaço de entrada, assim, o algoritmo de treinamento deve decidir que características devem ser extraídas do conjunto de treinamento.

3.5.1 Regra de aprendizado do *Multi-Layer Perceptron*

Em conformidade com Kröse e Smagt (1996), considerando que estamos utilizando unidades com função de transferência não-linear, temos que generalizar a regra delta para este tipo de função de transferência.

A função de transferência é uma função diferenciável da entrada total, dada por:

$$y_k^p = F(s_k^p) \quad (3)$$

Onde:

y_k^p é a saída produzida pela rede neural num certo momento do processo de aprendizado para um dado padrão de entrada p ;

s_k^p é o número de neurônios utilizados pela rede neural num certo momento do processo de aprendizado para um dado padrão de entrada p , isto é:

$$s_k^p = \sum_j w_{jk} y_j^p + b_k \quad (4)$$

Para obter a generalização correta da regra delta, é necessário definir:

$$\Delta_p w_{jk} = -g \frac{\partial E^p}{\partial w_{jk}} \quad (5)$$

Onde:

Δ_p é uma constante que indica o quanto deve o peso sináptico alterar num certo momento do processo de aprendizado para um dado padrão de entrada p ;

g é uma constante de proporcionalidade;

E^p é a soma dos erros quadrados num certo momento do processo de aprendizado para um dado padrão de entrada p .

Logo, podemos definir E^p como:

$$E^p = \frac{1}{2} \sum_{o=1}^{N_o} (d_o^p - y_o^p)^2 \quad (6)$$

Onde:

d_o^p é a saída desejada para unidade o quando o padrão de entrada p é mantido.

Continuamos definindo $E = \sum_p E^p$ como a soma dos erros quadrados. Podemos

escrever:

$$\frac{\partial E^p}{\partial w_{jk}} = \frac{\partial E^p}{\partial s_k^p} \frac{\partial s_k^p}{\partial w_{jk}} \quad (7)$$

Pela equação (5) podemos observar que o segundo fator do lado direito da equação (7) é:

$$\frac{\partial s_k^p}{\partial w_{jk}} = y_j^p \quad (8)$$

Podemos definir:

$$d_k^p = -\frac{\partial E^p}{\partial s_k^p} \quad (9)$$

Alterando a regra de atualização, que é equivalente à regra delta, temos que o resultado é uma descida de gradiente na superfície de erro. Assim, as alterações nas mudanças dos pesos sinápticos são feitas de acordo com:

$$\Delta_p w_{jk} = \mathbf{g} d_k^p y_j^p \quad (10)$$

Desta forma, o objetivo é definir qual deveria ser d_k^p para cada unidade k da rede neural. O resultado derivado agora, é que há uma computação recursiva simples destes d^p 's que podem ser implementados propagando sinais de erro para trás pela rede neural.

Para computar d_k^p , aplica-se a regra da cadeia para escrever esta derivada parcial como produto de dois fatores, um que reflete a mudança do erro como uma função da saída da unidade k e outro que reflete a mudança da saída como uma função de mudanças na entrada. Podemos escrever:

$$d_k^p = -\frac{\partial E^p}{\partial s_k^p} = -\frac{\partial E^p}{\partial y_k^p} \frac{\partial y_k^p}{\partial s_k^p} \quad (11)$$

Substituindo a equação (3) no segundo fator do lado direito da equação (11), temos:

$$\frac{\partial y_k^p}{\partial s_k^p} = F'(s_k^p) \quad (12)$$

A equação (12) é a derivada da função F para a k -ésima unidade, avaliada na entrada s_k^p para a unidade k . Para substituir a equação (12) no primeiro fator do lado direito da equação (11), em primeiro lugar, tomamos que a unidade k é uma unidade de saída $k = o$ da rede neural. Neste caso, segue-se que da definição de E^p definida pela equação (6) que:

$$\frac{\partial E^p}{\partial y_o^p} = -(d_o^p - y_o^p) \quad (13)$$

Substituindo a equação (13) na equação (11), chegamos a:

$$d_o^p = (d_o^p - y_o^p) F'(s_o^p), \quad \forall o \quad (14)$$

Em segundo lugar, se k não é uma unidade de saída, mas uma unidade escondida $k = h$, não é conhecida a contribuição da unidade ao erro da saída da rede neural. Porém, a medida de erro pode ser escrita como uma função dos pesos da entrada da camada escondida para a camada de saída; $E^p = E^p(s_1^p, s_2^p, s_3^p, \dots, s_j^p)$ e utilizando novamente a regra da cadeia podemos escrever:

$$\frac{\partial E^p}{\partial y_h^p} = \sum_{o=1}^{N_o} \frac{\partial E^p}{\partial s_o^p} \frac{\partial s_o^p}{\partial y_h^p} = \sum_{o=1}^{N_o} \frac{\partial E^p}{\partial s_o^p} \frac{\partial}{\partial y_h^p} \sum_{j=1}^{N_h} w_{ko} y_j^p = \sum_{o=1}^{N_o} \frac{\partial E^p}{\partial s_o^p} w_{ko} = -\sum_{o=1}^{N_o} d_o^p w_{ho} \quad (15)$$

Substituindo a equação (16) na equação (12):

$$d_h^p = F'(s_h^p) \sum_{o=1}^{N_o} d_o^p w_{ho} \quad (16)$$

As equações (15) e (16) têm um procedimento recursivo para computar os d^p 's para todas as k unidades da rede neural que é usada para ajustar as mudanças dos pesos sinápticos de acordo com equação (16). Este procedimento constitui a regra de delta generalizada para uma rede *feed-forward* de unidades não-lineares.

Para detalhar melhor as propriedades dos algoritmos de aprendizagem, consulte alguns teoremas descritos em Veelenturf (1995), Kröse e Smagt (1996), Block (1962) e Novikoff (1962).

3.5.3 Treinamento *Resilient-Propagation* (RPROP)

Ao contrário o algoritmo de *backpropagation* tradicional, o algoritmo *Resilient-Propagation* também chamado de RPROP, desenvolvido inicialmente por Riedmiller e Braun (1993), utiliza apenas sinais de derivadas parciais para ajustar os coeficientes dos pesos

sinápticos. Este algoritmo utiliza o método de iterações e reajusta os pesos sinápticos após todos os padrões da sub-amostra de treinamento serem apresentados à rede.

O algoritmo RPROP ajusta os pesos sinápticos da rede neural seguindo a regra:

$$\Delta_{ij}^{(t)} = \begin{cases} h^+ \Delta_{ij}^{(t)}, & \frac{\partial E^{(t)}}{\partial w_{ij}} \frac{\partial E^{(t-1)}}{\partial w_{ij}} > 0 \\ h^- \Delta_{ij}^{(t)}, & \frac{\partial E^{(t)}}{\partial w_{ij}} \frac{\partial E^{(t-1)}}{\partial w_{ij}} < 0 \end{cases} \quad (17)$$

$$0 < h^- < 1 < h^+$$

Segundo Akobir [2005?], se em determinado momento o peso sináptico correspondente da derivada parcial w_{ij} inverter seu sinal, é por que sua última modificação foi elevada e o algoritmo perdeu o mínimo local. Então, o tamanho da modificação deveria diminuir determinado pelo fator h^- e o valor prévio do coeficiente do peso sináptico restabelecido. Em outras palavras, esta modificação deveria ser desfeita.

$$\Delta w_{ij}(t) = \Delta w_{ij}(t) - \Delta_{ij}^{(t-1)} \quad (18)$$

Se o sinal da derivada parcial não mudou, então o ajuste deveria ser aumentado por h^+ para alcançar mais rapidamente a convergência. Fixados os fatores de diminuição h^- e de aumento h^+ podemos manter as configurações globais da rede de neural inalteradas. Logo, este fato poderia ser uma vantagem do algoritmo *Resilient-Propagation* em relação ao algoritmo de *backpropagation* tradicional (AKOBIR, Op. Cit.).

Para evitar valores de pesos sinápticos muito altos ou muito baixos, o valor de ajuste é determinado acima por Δ_{\max} e abaixo por Δ_{\min} .

A regra demonstrada pela equação (19) é utilizada para encontrar o valor de ajuste dos pesos sinápticos:

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_{ij}^{(t)}, & \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ +\Delta_{ij}^{(t)}, & \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ 0, & \frac{\partial E^{(t)}}{\partial w_{ij}} = 0 \end{cases} \quad (19)$$

Se a derivada é positiva, isto é, o erro aumenta, o coeficiente do peso sináptico é diminuído pelo valor de ajuste, caso contrário é aumentado. Logo, a equação ilustra a forma como os pesos são ajustados:

$$w_{ij}(t+1) = w_{ij}(t) - \Delta w_{ij}(t) \quad (19)$$

3.5.5 Regularização

Além da função de performance da rede neural *LMS*, definida anteriormente para o caso do *Multi-Layer Perceptron* pela equação (16), temos modificações destas funções de performance. O objetivo destas modificações é melhorar a performance de generalização da rede neural, a qual é chamada de regularização.

Função de Performance modificada

Uma definição alternativa para a função tradicional de performance utilizada para treinar uma rede neural do tipo *feedforward* é a *LMS* descrita em Demuth e Beale (1998).

$$F = mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (21)$$

É possível melhorar o poder de generalização da rede neural modificando a função de performance somando um termo que consiste na média da soma dos quadrados dos pesos e *bias* da rede neural:

$$msereg = gmse + (1 - g)mw \quad (22)$$

Onde g é a razão de performance e,

$$msw = \frac{1}{n} \sum_{j=1}^n w_j^2 \quad (23)$$

Ao usar esta função de performance a rede irá diminuir seus pesos sinápticos e *bias*, e isto forçará a resposta de rede a ser mais suave e menos sujeita a problemas de *overfitting*.

O problema com a regularização é que é difícil determinar um valor ótimo para o parâmetro da razão de performance. Se escolhermos um valor para este parâmetro elevado, podemos incorrer em *overfitting*. Se esta razão for muito pequena, a rede não vai generalizar adequadamente a amostra de treinamento.

Segundo Kaastra e Boyd (1996), o problema de *overfitting* ocorre quando um modelo de predição, como o de redes neurais, possui muito poucos graus de liberdade. Este problema causa perda de poder de generalização das redes neurais fazendo com que esta ganhe em memorização de idiosincrasias de observações individuais e perda do poder predição. Logo, um modelo de redes neurais robusto deve analogamente aos modelos econométricos, seguir o critério da parcimônia, o que, além de diminuir o custo computacional da rede neural, aumenta sua capacidade de generalização.

4 Seleção e Tratamento da Amostra de Dados

A amostra de *ratings* utilizada compreende os *ratings* de longo prazo em moeda estrangeira atribuídos a países emergentes pela agência *Standard & Poor's*, a partir de 1975, fornecidos pelo relatório de 2 de novembro de 2005. Das 23 escalas de *ratings* atribuídas por esta agência apresentadas na Tabela 1, esta amostra de *ratings* possui 18 escalas diferentes⁵.

É importante ressaltar que o início da amostra temporal de *ratings* se dá a partir em 1975, porém isso não quer dizer que todos os países tenham atribuições de *ratings* se iniciando em 1975. Cada país da amostra foi incluso de acordo com a sua primeira atribuição de *rating*.

As variáveis utilizadas no trabalho como determinantes macroeconômicos das atribuições de *ratings* foram coletadas nas estatísticas de indicadores de desenvolvimento dos países emergentes publicadas pelo Banco Mundial.

A publicação *Indicadores de Desenvolvimento do Mundo* realizada pelo Banco Mundial, possui observações com frequência anual e término em 2003. Como estas observações fizeram referência às estatísticas de final de período, utilizamos as atribuições de *ratings* também de final de período para o caso daqueles países que receberam mais de uma atribuição de *rating* por ano. Portanto, para os países que a agência *Standard & Poor's* atribuiu mais de uma escala de *rating* no mesmo ano, utilizamos nas estimações deste trabalho apenas observações da última atribuição de *rating* naquele ano.

Além disso, os *outliers* da amostra foram excluídos, o que não gera nenhuma perda de informação em nosso modelo e, diferentemente dos modelos econométricos onde existem tratamentos para este tipo de problema, os *outliers* em redes neurais podem e devem ser

⁵ As escalas AA+, AA-, C, SD e D, não foram encontradas na amostra utilizada de atribuições de *ratings*.

excluídos da amostra. A razão pela qual eles são excluídos da amostra é simples. Na fase de treinamento das possíveis arquiteturas utilizadas na estimação final do trabalho, eles dificultam este treinamento, o que pode causar, entre outras conseqüências, perda de robustez do modelo.

5 Implementação da Rede Neural

Nesta seção, enumeramos alguns passos básicos depois de definidos a seleção e tratamento da amostra de dados, constituído pela fase de treinamento e teste da rede neural.

Segundo Kaastra e Boyd (1996), uma prática comum é dividir a amostra de dados em duas sub-amostras, denominadas amostra de treinamento e de teste. A amostra de treinamento é a maior em tamanho e compreende cerca de 90% do tamanho total da amostra de dados. Os 10% restantes é deixado para o teste. O pesquisador deve utilizar o tipo de rede neural que obteve melhor desempenho na fase de treinamento e teste, isto é, a rede neural que possuir menor erro de predição.

A escolha sobre qual tipo de função de treinamento utilizar na rede neural, assim como outras escolhas na elaboração de uma arquitetura de rede neural, é um processo também experimental. Logo, dado o critério de erro⁶ da rede neural na fase de treinamento, escolhe-se uma função que melhor se adaptou à amostra de dados para ela apresentada.

A amostra de teste pode ser definida a partir de duas abordagens diferentes. Ela pode ser escolhida aleatoriamente a partir da amostra de treinamento ou pode ser definida com observações mais recentes que sucedem as observações da amostra de treinamento (para o caso de séries de tempo). Uma vantagem do uso da segunda abordagem é testar a rede com observações mais recentes que podem ser informações mais relevantes para a explicação do problema a ser tratado pelas redes neurais (KAASTRA e BOYD, Op. Cit.).

A arquitetura da rede neural, isto é, o número de camadas de neurônios e o total de neurônios por camada, assim como qual tipo de interconexão entre estes, depende da natureza e do tamanho da amostra de dados que se pretende utilizar na rede neural. O número de neurônios utilizados na entrada e na saída da rede neural é, respectivamente, o número de variáveis independentes e dependentes do modelo a ser estimado.

A arquitetura ideal da rede neural deve ser tal que ela seja tão grande quanto necessária para conseguir obter as representações necessárias, mas ao mesmo tempo pequena o suficiente para se obter um treinamento mais rápido. Não existem regras claras para se definir quantas unidades devem existir nas camadas escondidas, quantas camadas, ou como devem ser as conexões entre essas unidades (SIU et al., 1995).

Teoricamente, uma rede neural com uma camada de neurônios escondida com um número suficiente de neurônios nesta camada, seria capaz de aproximar qualquer tipo de função contínua. Na prática, redes neurais com uma ou duas camadas de neurônios escondidas são amplamente utilizadas e possuem performances bastante satisfatórias.

Deve-se ressaltar que aumentar tanto o número de camadas como também o número de neurônios da rede neural, além de aumentar o custo computacional, também expõe a arquitetura da rede neural a problemas de *overfitting*.

6 Análise de Resultados

Este trabalho se destinou a fazer inferências sobre o comportamento dos *ratings* de risco soberano a partir dos fundamentos macroeconômicos. Desta forma, neste capítulo, detalhamos inicialmente os aspectos técnicos da aplicação dos procedimentos metodológicos

⁶ O critério a ser adotado para se estabelecer desempenho da rede neural pode ser o *MSE*, *SSE* ou *MSEREG*.

sobre os dados empíricos e, logo após, procuramos, à luz da teoria econômica, discutir estes resultados.

Nossas análises foram feitas a partir de variações do modelo de redes neurais artificiais *Multi Layer-Perceptron* (MLP). O motivo pelo qual foi utilizado tal procedimento justifica-se pelo tipo de problemática, neste caso uma classificação das atribuições de *ratings* de risco soberano, onde problemas envolvendo classificação constituem a principal aplicação da MLP.

Aplicamos no processo de treinamento da rede neural a aprendizagem do tipo supervisionada. Testamos diversas redes neurais e, de acordo com o caráter experimental das estimativas por este procedimento metodológico, iniciamos com uma arquitetura de rede neural composta por onze neurônios na primeira camada, isto é, onze variáveis macroeconômicas compunham o *input* da rede. A saída ou *output* da rede neural foi composto inicialmente por 18 neurônios, pois na amostra de *ratings* da *Standard & Poor's* utilizada nas estimativas, tínhamos 18 escalas de *ratings*.

Especificamente, testamos arquiteturas de redes neurais do tipo *feedforward* e *cascade-forward*⁷. Foi observado que as arquiteturas *feedforward* obtiveram desempenho ligeiramente superior ao desempenho das arquiteturas *cascade-forward*, assim optamos por definirmos os resultados finais a partir da primeira arquitetura.

De acordo com o princípio da parcimônia, para encontrarmos uma rede neural robusta e evitarmos problemas como, a presença de *overfitting*, construímos inicialmente uma rede neural com apenas uma camada escondida e com 10 neurônios nesta camada, aumentando gradativamente o número de neurônios de acordo com os testes de performance da rede. Além disso, testamos também redes com mais de uma camada escondida o que não aumentou a performance da rede. A rede neural utilizada nas estimativas do trabalho foi uma rede com uma camada escondida composta por 40 neurônios, uma camada de entrada composta por 4 neurônios e uma camada de saída composta por 8 neurônios.

O tipo de função de aprendizado constitui também uma peça importante da rede neural e a função utilizada na estimação deste trabalho foi a aprendizagem chamada *backpropagation* com uma constante de *momentum*, descrita na seção de procedimentos metodológicos.

Testamos diversos tipos de algoritmos de treinamento, onde os mais importantes foram Levenberg-Marquardt⁸, *backpropagation* com uma constante de *momentum* e *Resilient-Propagation*⁹. O tipo de treinamento de melhor performance seja pelo critério de melhor previsão ou por possuir menor custo computacional, foi o *Resilient-Propagation* o que nos levou a utilizá-lo na estimação do trabalho.

A mensuração da performance da rede neural foi realizada pela função *msereg* definida pela equação (32) que permitiu a regularização da performance ótima da rede. O valor para o parâmetro g escolhido onde a rede neural obteve uma performance satisfatória foi $g = 1,0$.

Após testes, definimos a função de transferência ou ativação entre os neurônios da rede neural como uma função do tipo tangente hiperbólica.

Adicionalmente, testamos qual o número ótimo de iterações a partir da performance do erro-quadrado-médio apresentado pelas diferentes redes neurais testadas e, de acordo com esta performance, escolhemos não mais que cerca de cem iterações necessárias, pois nota-se claramente que a partir de cinquenta iterações o erro-quadrado-médio converge para um valor mínimo.

⁷ Ver mais sobre arquiteturas do tipo *cascade* em Arbib (2003) p. 648.

⁸ Descrito em detalhes em HANGAN e MENJAH, 1994.

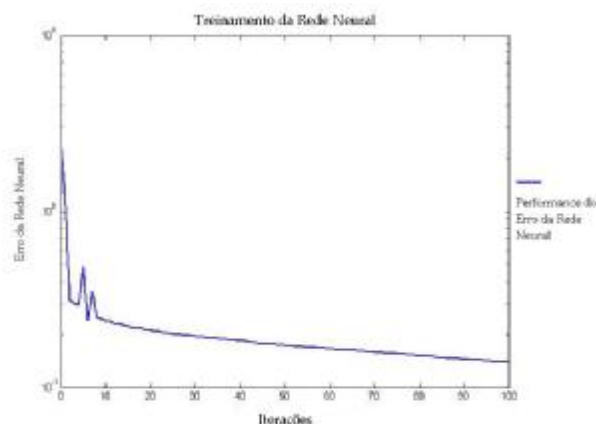
⁹ Descrito pela equação (30).

Das 18 escalas de *ratings* trabalhadas inicialmente na rede neural, optamos por deixar apenas 8, pois, observamos que, com este número de escalas, a performance da rede foi mais robusta. A simbologia escolhida, por ordem crescente de risco, da escala de *ratings* utilizada na rede foi: A, AA, AAA, B, BB, BBB, CC e CCC.

Foi realizada uma análise de sensibilidade da rede aos *inputs* que acrescentaram pouca informação ao modelo, análise esta presente nos modelos econométricos como o método *stepwise*¹⁰. Desta forma, as variáveis escolhidas para serem utilizadas na estimação foram: Nível de reservas totais como percentual do produto; dívida externa total como percentual das exportações de bens e serviços; balança externa de bens e serviços como percentual do produto; e taxa de crescimento do produto *per capita*.

As Figuras 2 e 3 ilustram, respectivamente, as performances do treinamento e teste realizados na rede neural escolhida. Na Figura 2, em azul encontra-se a performance de treinamento de rede, onde podemos observar que seu erro atinge um nível satisfatório em torno de 0,13944 na centésima iteração realizada pelo treinamento.

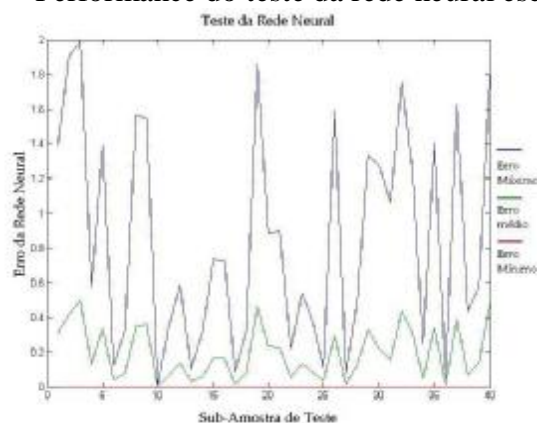
Figura 2– Performance do treinamento da rede neural escolhida



Fonte: Elaboração própria a partir de dados da *Stancard* e *Poor's* e *World Bank*.

Na Figura 3, em verde temos a média de erros da rede, em azul temos seu erro máximo e em vermelho seu erro mínimo.

Figura 3 – Performance do teste da rede neural escolhida



Fonte: Elaboração própria a partir de dados da *Stancard* e *Poor's* e *World Bank*.

O erro de predição da rede neural ilustrado pelos pontos mais elevados das linhas de erro, constituem a falha da rede neural em prever, dados os fundamentos macroeconômicos

¹⁰ Este método consiste em reduzir a necessidade de computação intensiva para selecionar o melhor subconjunto de regressores, adicionando ou reduzindo algum regressor. Ver mais em Greene (1997).

apresentados à ela, qual deveria ser a atribuição de *rating*. Assim, observamos que a rede consegue com certa robustez, para oito escalas de *ratings*, predizer as atribuições de *ratings* a partir dos 4 tipos de variáveis macroeconômicas apresentados a ela.

Teoricamente, de acordo com Kaastra e Boyd (1996), uma rede neural com uma camada escondida consegue aproximar qualquer tipo de função. Contudo, ao aplicarmos redes neurais dos tipos descritas anteriormente neste capítulo, aos determinantes quantitativos empíricos dos *ratings* de risco soberano de longo prazo, observamos certo grau de dificuldade que nos levou a diminuir o número de escalas de *ratings* da saída da rede. Embora este problema não tenha prejudicado significativamente a análise deste trabalho ele surgiu por que a rede escolhida não conseguiu, a partir dos dados macroeconômicos, fazer distinção entre 18 escalas diferentes de *ratings*.

Possíveis explicações surgiram para tal problema. Como apontado por diversos estudos empíricos citados ao longo do trabalho, por exemplo, Partnoy (2002), Ferri, Liu e Stiglitz (1999), Bone (2004), Cantor e Packer (1996), Canuto, Santos e Porto (2004), mesmo para os determinantes quantitativos, é difícil encontrar uma relação direta entre estes e os *ratings* atribuídos pela *Standard & Poor's*, por causa do grande número de critérios adotados por esta agência. Pois, os *ratings* são construídos com base em análises das conjunturais sobre a vida econômica, social e política dos países e, por este motivo, podem ser subjetivos porque envolvem julgamentos sobre uma grande quantidade de variáveis.

Além disso, estes trabalhos tratam de inúmeros problemas envolvendo os *ratings* como problemas de ordem legal dos mercados financeiros como discutido no trabalho de Partnoy (2002), ou as antecipações das mudanças das variáveis econômicas às mudanças nas atribuições dos *ratings* como discutido neste mesmo trabalho e nos trabalhos de Bone (2004) e Ferri, Liu e Stiglitz (1999). Onde, este último, defende a idéia da existência de uma regra procíclica das agências de *rating* prolongando os efeitos de crises sobre as economias através de comportamentos excessivamente conservadores caracterizados por atribuírem *ratings* como remédio às crises financeiras. Isto é, quando as agências não conseguem antever uma crise sinalizando ao mercado o perigo desta, elas atribuem *ratings* na tentativa de remediá-la, porém o que elas conseguem é prolongá-la, pois os novos *ratings* atribuídos fazem com que os investidores componham uma carteira de investimentos de menor risco, vendendo os títulos dos países envolvidos nesta crise, provocando uma perda de liquidez destes fazendo com que esta se prolongue.

Estas possíveis explicações surgem em trabalhos elaborados dentro deste tipo de temática, onde a aplicação de diversos tipos de modelos quantitativos refinados a determinantes quantitativos empíricos dos *ratings* de risco soberano frequentemente não encontram resultados com precisão apurada.

Devemos ressaltar que a dificuldade de ajustamento de um modelo de redes neurais reflete a possibilidade de haver atribuições de *ratings* em desacordo com os fundamentos macroeconômicos dos países emergentes que compõem a amostra de dados deste trabalho. O que remete à idéia de que o peso dos determinantes qualitativos das atribuições de *ratings* para este grupo de países é instável, implicando num julgamento por parte das agências ainda mais subjetivo.

Do ponto de vista dos governantes destes países, a tarefa de se identificar a causa de um julgamento ruim das agências se torna mais difícil em consequência desta parcela dos determinantes qualitativos não possuir estabilidade.

Na outra mão, estes países ao buscar recursos no mercado internacional, têm que manter elevadas taxas de juros em face aos julgamentos das agências. O efeito mais perceptível deste fato no lado real da economia, é que elevadas taxas de juros levam a um retardo do investimento e logo, do crescimento econômico.

Mesmo com os problemas envolvendo a questão dos *ratings*, conseguiu-se chegar a um tipo de rede neural que generaliza relativamente bem 8 escalas de *ratings* a partir de 4 variáveis macroeconômicas como mencionado anteriormente.

A partir da escolha da rede neural de melhor poder de generalização, simulamos *cenários* para a economia brasileira, a partir de mudanças nos comportamentos dos fundamentos macroeconômicos que compõem os *inputs* da rede neural, nos quais o risco soberano nestes casos diminui atingindo um patamar menor saindo da escala de risco *B* para *BB*. Mais precisamente, tomamos as quatro variáveis macroeconômicas citadas anteriormente para escolha da rede neural e simulamos mudanças nestas variáveis para o ano de 2003¹¹.

Estas simulações consistiram na geração aleatória pela rede neural escolhida, com distribuição uniforme, de 1.000 *cenários* que gerariam um *rating* de risco igual a *BB* a partir dos valores observados das 4 variáveis macroeconômicas no ano de 2003.

Inicialmente, simulamos modificações nas observações de apenas uma variável macroeconômica de cada vez. Contudo, observamos que o *rating* de risco se manteve inelástico a esta modificação. Isto pode demonstrar que, para que haja uma nova atribuição de *rating* de risco soberano, seja necessário um conjunto de modificações nos fundamentos macroeconômicos e não apenas a modificação de apenas um destes fundamentos.

Diante disso, a partir dos *cenários* simulados, obtivemos uma média de possíveis realidades macroeconômicas para a economia brasileira em 2003. A Tabela 2 resume estes tipos de *cenários* simulados, onde na primeira coluna de dados, temos os valores observados das variáveis macroeconômicas em 2003 e, nas demais colunas, temos os tipos de *cenários*.

Tabela 2 – Simulações de *cenários* macroeconômicos

Variáveis (em %)	Observações 2003	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Balança externa / Produto	6	6,4	7,6	7,6	7,6
Dívida externa total / Exportações	265	235	235	235	265
Crescimento do produto <i>per capita</i>	-1	2	1	2	2
Nível de reservas totais / Produto	9	15,75	15,75	13,75	15,75

Fonte: Elaboração própria a partir de dados da *Stancard* e *Poor's* e *World Bank*.

A partir das simulações destes 4 diferentes *cenários*, percebemos inicialmente que, para o Brasil alcançar uma nova atribuição de *rating* de risco, as 4 variáveis econômicas que fazem parte dos fundamentos macroeconômicos dos *ratings* devem se alterar.

De maneira geral, observamos que mudanças mais acentuadas em alguns fundamentos permitem que outros fundamentos se modifiquem menos ou se mantenham constantes de modo que, no conjunto, melhoras dos fundamentos descritas nos *cenários* implicam num *upgrade* do conceito de *rating*. Isto é, políticas que agem no sentido de melhorar o Balanço de Pagamentos fazem com que as condições de captação de crédito no mercado externo melhorem. O que se traduz em termos reais na possibilidade de maior crescimento e desenvolvimento, via diminuição do *sread* da taxa de juros em relação às taxas de juros pagas pelo tesouro americano.

Observamos que, para que haja uma mudança da atribuição de *rating* de risco para a economia brasileira, há uma combinação das mudanças dos fundamentos macroeconômicos. Desta forma, o crescimento do produto *per capita* e a razão do nível de reservas totais como percentual do produto se mostram variáveis importantes, pois em todos os *cenários*, estas se elevam mais acentuadamente.

Com exceção do *cenário* 4, onde todas as variáveis que se relacionam diretamente com a escala de *rating* de risco soberano, aumentam mais acentuadamente, a dívida externa

¹¹Diante da indisponibilidade de dados macroeconômicos dos anos 2004 e 2005 pelo Banco Mundial, tomamos o ano de 2003 para fazermos nossas análises.

total como percentual das exportações de bens e serviços diminui. Logo, esta variável também se mostra importante para que as condições de captação de recursos pelo Brasil nos mercados internacionais melhorem.

O aumento da razão do nível de reservas totais como percentual do produto também se mostra sempre crescente de acordo com a melhora de atribuição de *rating*. Observamos que o aumento do nível de reservas é importante para melhorar as condições de crédito no mercado internacional.

Uma das características dos fundamentos macroeconômicos de todos os *cenários* simulados, é que todos são possíveis de serem alcançados no curto prazo através de instrumentos de políticas econômicas. Contudo, não faz parte dos objetivos do presente trabalho discutir quais as políticas econômicas ou quais os instrumentos destas, devem ser utilizados.

De acordo com Mankiw (2004), questões do tipo *como aumentar a taxa do produto da economia, ou até que ponto a dívida do governo pode se transformar em um grave problema*, fazem parte de importantes questões onde os macroeconomistas frequentemente discordam. Assim, baseados na amostra escolhida e nos resultados obtidos, verificamos quais as variáveis que exercem forte interferência no processo de atribuição de *rating* soberano. E, no caso do Brasil, apresentamos possíveis modificações dos fundamentos macroeconômicos que poderiam levar à melhor atribuição de *rating* risco soberano.

7 Conclusão

Os problemas em torno da assimetria de informação na economia, e suas conseqüências diretas sobre as vidas das pessoas, podem ser mensurados pela quantidade e qualidade dos estudos produzidos em torno deste tipo de temática.

Diante do desenvolvimento e maior integração entre os mercados financeiros mundiais, instituições e dispositivos que têm por objetivo minimizar os transtornos gerados pela assimetria de informações são de muita importância. Desta forma, a magnitude da importância dos *ratings* na economia, como síntese clara e simples de informações sobre as futuras condições de pagamento de um emitente de dívida, também é incomensurável. Haja vista que as condições de captação de recursos no mercado estão fortemente atreladas a eles como foi discutido por Partnoy (2002).

Uma determinada atribuição de *rating* para um emitente de dívida soberano como um país, por exemplo, pode levá-lo a conseqüências permanentes e desastrosas ou levá-lo a uma marcha rumo ao desenvolvimento sócio-econômico via aumento da sua taxa de investimentos. No caso de países emergentes como o Brasil, que têm ampla necessidade de captação de recursos no mercado externo para concretizar projetos de investimentos, sejam privados ou estatais, esta atribuição pode conter um peso substancialmente maior, pois eleva o custo de captação destes recursos. Isso pode acontecer porque dada uma atribuição de *rating* de risco soberano elevada, os dirigentes da economia brasileira serão obrigados a aumentar o prêmio de risco pago por eles, isto é, a taxa de juros paga pelos papéis e títulos financeiros emitidos pelo governo brasileiro.

Em outras palavras, o governo será obrigado, se por hipótese houver um *downgrade* nos *ratings* de risco soberano, ou seja, uma elevação do risco de crédito concedido para o Brasil no mercado internacional, a aumentar o *spread* de prêmio pago entre títulos do governo brasileiro e os títulos do governo norte-americano, causalidade esta apresentada pelo trabalho de Cantor e Packer (1996).

Mesmo levando em consideração características das agências de *ratings* que as justificam como fornecedoras deste tipo de serviço na economia, críticas tanto do meio acadêmico quanto do mercado, têm surgido no sentido de atacar sua capacidade preditiva

frente a eminências de crises financeiras. Logo, estudar-se uma ferramenta objetiva de apoio à decisão em torno deste tipo de problema se torna fundamental.

Assim, a utilização de redes neurais artificiais no aprendizado da *regra* que rege o processo de atribuição de *rating* de risco soberano objetivou elucidar um processo decisório que, como levantado por Ferri, Liu e Stiglitz (1999), funciona de maneira vaga. Além disso, utilizamos esta *regra* na construção de cenários para a economia brasileira a fim de sabermos como se modificariam as variáveis macroeconômicas determinantes destas atribuições.

Vimos que 4 variáveis macroeconômicas estão mais diretamente conectadas a estas atribuições. São elas: nível de reservas totais como percentual do produto, dívida externa total como percentual das exportações de bens e serviços, balança externa de bens e serviços como percentual do produto e taxa de crescimento do produto *per capita*.

Das 18 escalas diferentes de *ratings* que inicialmente faziam parte do *output* da rede neural, conseguiu-se através de uma arquitetura do tipo *feedforward*, com uma camada escondida composta por 40 neurônios, chegar-se a 8 escalas diferentes de *ratings*. Isto se deu em parte à dificuldade de implementação de métodos quantitativos à problemática envolvendo *ratings* de risco soberano como amplamente relatado na literatura e, em parte, a maior refinamento da rede neural. Embora, como foi descrito no capítulo 6, foram testadas diversas variações de composições de arquiteturas de redes.

Os *cenários* construídos nos mostraram que combinações de modificações dos fundamentos macroeconômicos foram necessárias para que o Brasil saltasse da escala de atribuição de *rating B* para *BB*. E, além disso, observamos que o sentido das modificações das variáveis foi de acordo com a teoria econômica e que a magnitude destas modificações podem ser alcançadas no curto prazo.

Dado o processo experimental de construção de uma arquitetura de rede neural adequada, podemos concluir que a busca de maior refinamento deste, se torna uma preocupação com a qual o pesquisador que o aplica terá sempre que lidar. Devemos ressaltar que o melhor modelo de redes neurais será sempre tangenciado.

Logo, o trabalho buscou alcançar seu principal propósito no sentido de auxiliar os formuladores de políticas econômicas que têm por objeto melhorar as condições de crédito no mercado internacional, a definir políticas com mais subsídio informacional, pois a comprovação científica é uma importante informação para processos de decisão.

REFERÊNCIAS

AKOBIR, Shahidi. **Mathematical apparatus of the RPROP learning algorithm**. BaseGroup Labs. Disponível em: <<http://www.basegroup.ru/neural/rprop.en.htm>> Acesso em: jan. 2006.

ARBIB, Michael A. **The handbook of brain theory and neural networks**. 2 ed. London, England: MIT Press, 1995.

BLOCK, H.D. **The Perceptron: A Model for Brain Functioning**, In: I Review of Modern Physics, v. 34, 1962, p. 123-135.

BONE, Rosemarie Bröker. **Análise crítica dos fundamentos dos ratings soberanos: o caso da Argentina**. Banco Central del Uruguay. Montevideo, Uruguai, 2002. Disponível em: <<http://bcu.gub.uy/autoriza/peiees/jor/2002/iees03j060702.pdf>> Acesso em: out. 2005.

BONE, Rosemarie Bröker. **Ratings soberanos e corporativos: o rompimento do teto soberano pela Petrobrás e REPSOL-YPF**. Tese de Doutorado. Universidade Federal do Rio de Janeiro. Instituto de Economia. Rio de Janeiro, 2004.

- BONE, Rosemarie Bröker. **A importância dos fundamentos nos ratings soberanos brasileiros, 1994-2002**. In: XXXIII Encontro Nacional de Economia, Dez. 2005, Natal **Anais...** Natal: XXXIII Encontro Nacional de Economia, 2005. CD-ROM.
- CANTOR, R.; PACKER, F. **Determinants and Impact of Sovereign Credit Ratings**. *Economic Policy Review*, v. 2, nº 2, October 1996. Disponível em: <www.ny.frb.org/rmaghome/eco_pol/1096cant.html>. Acesso em: out. 2005.
- CANUTO, O.; SANTOS, P. F. dos; PORTO, Paulo C. de Sá. **Macroeconomics and sovereign risk ratings**. World Bank Discussion papers. Washington D. C., Jan. 2004.
- CANUTO, O.; SANTOS, P. F. dos. **Risco-soberano e prêmios de risco em economias emergentes**. Ministério da Fazenda, Secretaria de Assuntos Internacionais, Temas de economia internacional, Jan. 2003b.
- DEMUTH, H; BEALE, M. **Neural network toolbox**. For use with MATLAB. Computation, visualization, programming. User's guide. Version 3. The Math Works. 1998. Disponível em: <<http://www.mathworks.com/access/helpdesk/help/toolbox/nnet/>> Acesso em: jan. 2006.
- FAUSETT, Laurene. **Fundamentals of Neural Networks**. Prentice Hall, Englewood Cliffs, NJ, 1994.
- FERRI, G.; LIU, L-G.; STIGLITZ, J. E. **The procyclical role of rating agencies: evidence from the East Asian crisis**. *Economic Notes*, v. 28, n. 3, 1999, p. 335-355.
- GREENE, William H. **Econometric Analysis**. 5th ed. Upper Saddle River, New Jersey: Prentice Hall, 2002.
- HAQUE, Nadeem U.; MARK, Nelson; MATHIESON, Donald J. **The relative importance of political and economic variable in creditworthiness ratings**. IMF: working paper 98/46. Abr. 1998.
- HAYKIN, S. **Redes Neurais: Princípios e Práticas**. 2 ed. São Paulo: Bookman, 2001.
- KAASTRA, Iebeling; BOYD, Milton. **Designing a neural network for forecasting financial and economic time series**. *Neurocomputing*. v. 10, n. 3, jan. 1996.
- KRÖSE, Ben; SMAGT, Patrick van der. **An Introduction to Neural Networks**. Universidade de Amsterdã. 8 ed., Amsterdã, nov. 1996.
- KUMAR, A.; RAO, V. R.; SONI, H. **An empirical comparison of neural network and logistic regression models**. *Marketing Letters*, 1995.
- LEICHSENRING, Daniel. **Endogeneidade e mecanismos de transmissão entre a taxa de juros doméstica e o risco soberano: uma revisita aos determinantes do Risco-Brasil**. Dissertação de Mestrado – Universidade de São Paulo, Faculdade de Economia, Administração e Contabilidade, Departamento de Economia, São Paulo, 2004.
- MANKIW, N. Gregory. **Macroeconomia**. 5 ed. Tradução por A. B. Pinheiro de Lemos. Tradução de Macroeconomics. Rio de Janeiro: LTC, 2004.
- MAS-COLLEL, A.; WHINSTON, M D.; GREEN, J. R. **Microeconomics theory**. New York: Oxford University Press, 1995.
- MINSKY, M.; PAPERT, S. **Perceptrons: An Introduction to Computational Geometry**. London, England: MIT Press, 1969.
- MOODY'S INVESTORS SERVICE. **Moody's rating symbols & definitions**. Ago. 2003. Disponível em: <www.moodys.com>. Acesso em: set. 2005.

NAG, A. K.; MITRA, A. **Forecasting Daily Foreign Exchange Rates Using Genetically Optimized Neural Networks**. Journal of Forecasting, 2002, p. 501–512.

NOVIKOFF, A. B. J. **On Convergence Proofs of Perceptrons**. Proc. Symp. on Math. Theory of Automata. Polytechnic Institute of Brooklyn. Brooklyn, NY, 1962, p. 615-622.

PARTNOY, F. **The paradox of credit ratings**. In: Levich; Majnoni e Reinhart, Ratings, Rating agencies and the global financial system. Boston – Kluwer, 2002.

PIAZZI, Fábio Silva. **Introdução às redes neurais**. Centro Brasileiro de Pesquisas Físicas. Seminários Internos. Rio de Janeiro: Novembro, 2001. Disponível em: <www.cbpf.br/cat/download/seminarios/internos/Fabio.ppt> Acesso em: set. 2005.

REINHART, Carmen M. **Sovereign credit ratings before and after financial crises**. University of Maryland and NBER. Working paper. fev. 2001.

RIEDMILLER, M.; BRAUN, H. **A direct adaptive method for faster backpropagation learning: The RPROP algorithm**. In: Proceedings of the IEEE International Conference on Neural Networks, San Francisco, 1993.

ROWLAND, Peter. **Determinants of spread, credit ratings and creditworthiness for emerging market sovereign debt: a follow-up study using pooled data analysis**. Banco de la Republica de Colombia. Bogotá, Colômbia: 2004. disponível em: <<http://www.banrep.gov.co/docum/ftp/borra296.pdf>> Acesso em: dez. 2005.

RUMELHART, D.; HINTON, G.; WILLIAMS, R. **Learning Internal Representations by Error Propagation**. Rumelhart e McClelland: Parallel Distributed Processing - In: Explorations in the Microstructure of Cognition - v. 1. Foundations. London, England: MIT Press, 1986.

SIU, Roychowdhury et al. **Toward massively parallel design of multipliers**. (context), 1995.

STANDARD & POOR'S. **Sovereign Ratings History Since 1975**. New York, USA: nov. 2005.

STANDARD & POOR'S. **Corporate ratings**. criteria. 2002a. Disponível em: <www.standardandpoors.com>. Acesso em: set. 2005.

STANDARD & POOR'S. **Critérios - comentários: ratings de crédito soberano: principais conceitos**. 2004. Disponível em: <www.standardandpoors.com>. Acesso em: set. 2005.

STANDARD & POOR'S. **Risco soberano e ratings acima do soberano**. critérios – comentários. ratings de crédito: soberanias. 23 jul. 2001a. Disponível em: <www.santandarandpoors.com.br>. Acesso em: set. 2005.

STIGLITZ, Joseph; GREENWALD, Bruce. **Rumo a um novo paradigma em economia monetária**. Tradução Laura Knapp e Cecília Camargo Bartalotti. São Paulo: Francis, 2004. Tradução de: Towards a new paradigm in monetary economics.

THE 2005 WORLD BANK DEVELOPMENT INDICATORS. Disponível em: <<http://ddp-ext.worldbank.org/ext/DDPQQ/member.do?method=getMembers&userid=1&queryId=19>> Acesso em: out. 2005.

VEELENTURF, L. P. J. **Analysis and applications of artificial neural networks**. United Kingdom: Prentice Hall International, 1995.