



**UNIVERSIDADE FEDERAL DE
PERNAMBUCO**
CENTRO ACADÊMICO DO AGRESTE
NÚCLEO DE TECNOLOGIA
CURSO DE GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

**APLICAÇÃO DA TEORIA DOS CONJUNTOS
APROXIMATIVOS PARA AVALIAÇÃO DE CRÉDITOS
SOBERANOS**

JULIO CEZAR SOARES SILVA

CARUARU
2018

JULIO CEZAR SOARES SILVA

**APLICAÇÃO DA TEORIA DOS CONJUNTOS
APROXIMATIVOS PARA AVALIAÇÃO DE CRÉDITOS
SOBERANOS**

Proposta de trabalho a ser apresentado ao Curso de Engenharia de Produção do Centro Acadêmico do Agreste - CAA, da Universidade Federal de Pernambuco - UFPE, como requisito para a disciplina **Projeto Final de Curso**.

Área de concentração: Gestão Econômica e Financeira

Orientador: Lucimário Gois de Oliveira Silva

Coorientador: Prof. Adiel Teixeira de Almeida Filho

Caruaru
2018

Catálogo na fonte:
Bibliotecária – Simone Xavier - CRB/4 - 1242

S586a Silva, Julio Cezar Soares.
Aplicação da teoria dos conjuntos aproximativos para avaliação de créditos soberanos.
/ Julio Cezar Soares Silva. - 2018.
37 f. il. : 30 cm.

Orientador: Lucimário Gois de Oliveira Silva
Coorientador: Adiel Teixeira de Almeida Filho
Monografia (Trabalho de Conclusão de Curso) – Universidade Federal de Pernambuco, CAA, Engenharia de Produção, 2018.
Inclui Referências.

1. Multicritério. 2. Avaliação de riscos. 3. Títulos de crédito. I. Silva, Lucimário Gois de Oliveira (Orientador). II. Almeida Filho, Adiel Teixeira de (Coorientador). III. Título.

658.5 CDD (23. ed.)

UFPE (CAA 2018-250)

JULIO CEZAR SOARES SILVA

APLICAÇÃO DA TEORIA DOS CONJUNTOS
APROXIMATIVOS PARA AVALIAÇÃO DE CRÉDITOS
SOBERANOS

Trabalho de Conclusão de Curso apresentado à coordenação do Curso de Engenharia de Produção do Centro Acadêmico do Agreste - CAA, da Universidade Federal de Pernambuco - UFPE, em cumprimento às exigências para obtenção do grau de Bacharel em Engenharia de Produção.

Área de concentração: **Gestão Econômica e Financeira**

A banca examinadora composta pelos professores abaixo, considera o candidato ALUNO COM NOTA_____.

Caruaru, 06 de Dezembro de 2018

Banca examinadora:

Prof. Dr. Lucimário Gois de Oliveira Silva: _____
Universidade Federal de Pernambuco – UFPE (Orientador)

Prof. Me. José Leão e Silva Filho _____
Universidade Federal de Pernambuco – UFPE (Avaliador)

Prof. Dr. Rodrigo Sampaio Lopes _____
Universidade Federal de Pernambuco – UFPE (Avaliador)

Prof. Dr. Thalles Vitelli Garcez _____
Universidade Federal de Pernambuco – UFPE (Coordenador da disciplina)

AGRADECIMENTOS

Agradeço primeiramente ao meu pai, Eleno, e a minha mãe, Josy, por todo amor e apoio proporcionados durante minha infância até este momento, pelo investimento feito na minha educação e pelos ensinamentos da vida, que guardarei comigo sempre.

Agradeço ao meu orientador, Lucimário Gois, por me apoiar e por sempre estar presente, realizando reuniões para o acompanhamento de atividades e esclarecimento de dúvidas. Agradeço também ao professor Adiel Filho, que me orientou em diversos trabalhos durante a graduação, me proporcionou grandes oportunidades de aprendizado e sempre esteve me aconselhando e acreditando nas horas mais difíceis.

Agradeço ao Grupo de Pesquisa em Gerenciamento de Riscos e Estudos em Engenharia Financeira e Otimização (GREEFO), do qual fiz parte durante a elaboração deste Trabalho de Conclusão de Curso, e em especial à Diogo, que é um exemplo de pesquisador para mim e rendeu uma parceria frutífera.

Agradeço ao meu primeiro orientador de PIBIC, Rogério Soares por compartilhar seus conhecimentos em matemática computacional, que foram fundamentais para meu desenvolvimento acadêmico. Também agradeço ao professor Marcelo Alencar por me dar oportunidade para trabalhar em seu campo de estudo, na reta final da graduação, como bolsista PIBIC.

Agradeço à Universidade Federal de Pernambuco, a direção e a todo o corpo docente do curso de Engenharia de Produção por todos os ensinamentos e cursos oferecidos durante minha trajetória na graduação. Agradeço ao professor Rodrigo Sampaio por proporcionar infraestrutura quando o espaço físico do GREEFO ainda não existia no CAA e pelos momentos de descontração ao longo deste percurso.

RESUMO

Apesar do fato que títulos soberanos representam alternativas de baixo risco que podem trazer bons rendimentos a investidores, a avaliação de risco para estes títulos ainda é considerada bastante subjetiva devido à falta de informação relacionada aos critérios, pesos e metodologias utilizadas pelas agências responsáveis. A crise econômica desencadeada em 2007 refletiu a falta de clareza em procedimentos adotados pelas agências de risco, apesar de toda a regulamentação do setor financeiro. Com o intuito de trazer maior transparência ao processo de classificação, este trabalho apresenta o uso de uma metodologia baseada na teoria dos conjuntos aproximativos com dominância, Dominance Based Rough Sets Approach (DRSA). Tendo em vista os trabalhos encontrados na literatura, buscou-se aprimorar o uso de aspectos considerados pelo Banco Mundial e agências de *rating* como a *Standard & Poor's* e *Moody's*. Através da perspectiva obtida com a DRSA foi possível verificar a consistência dos ratings das agências e induzir regras de decisão para reconhecer padrões, que podem explicar, através de um conjunto de critérios não-redundantes, a classificação de risco de crédito de um determinado título soberano. Foi obtida uma taxa de acerto considerável na extrapolação com dados reais e houve um aumento no escopo de países classificados. Sendo esta uma análise baseada apenas em aspectos objetivos, observou-se que a ausência de atributos subjetivos, como estabilidade política, provocam divergências nos resultados quando comparados àqueles fornecidos por agências de *rating*.

Palavras-chave: DRSA. Classificação Multicritério. Títulos Soberanos. Avaliação de Risco.

ABSTRACT

Despite the fact that sovereign bonds represent low risk alternatives for healthy income to investors, the risk assessment process for these bonds is still considered to be very subjective because of the lack of criteria-related information and methodologies used by international credit rating agencies. The economic crisis of 2007 reflected the lack of clarity in procedures adopted by the agencies, although the financial sector was rigorously regulated. With the intent of bringing more transparency to the classification process, this work presents the use of a methodology based on the theory of rough sets based on dominance, the Dominance Based Rough Sets Approach (DRSA). Taking into consideration related works in the literature, the use of aspects considered by the World Bank and credit rating agencies like *Standard & Poor's* and *Moody's* was sought to be improved. Through the perspective obtained with DRSA it was possible to verify the consistency of agencies' ratings and to induce rules for pattern recognition, that can explain, using a set of non-redundant criteria, the classification of credit risk of sovereign bonds. A considerable accuracy rate was obtained in the extrapolation using real data and there was an increase in the number of sovereign bonds analyzed. Since this analysis only use objective criteria, it was inferred that the absence of subjective attributes, i.e. political stability, provoke divergencies in the results when compared to those provided by the credit rating agencies.

Palavras-chave: DRSA. Multicriteria Sorting. Sovereign Bonds. Risk Assessment.

LISTA DE FIGURAS

Figura 1 - Estrutura dos Rating Soberano da Standard & Poor's	15
Figura 2 - O processo de suporte à decisão pela abordagem de desagregação de preferências. Adaptado de Doumpos e Zopounidis (2002).	17
Figura 3 - Metodologia do trabalho	24

LISTA DE QUADROS

Quadro 1. Critérios utilizados na análise.	25
Quadro 2. Conversão de Ratings; Fonte: Silva et al. (2018).....	26
Quadro 3. Conjunto de Referência.....	27
Quadro 4. Redutos gerados pelo jMAF.	28
Quadro 5. Regras induzidas pelo jMAF.....	28
Quadro 6. Resultado da classificação de 107 países.....	29

SUMÁRIO

1	INTRODUÇÃO	10
1.1	OBJETIVO GERAL	11
1.2	OBJETIVOS ESPECÍFICOS.....	11
1.3	JUSTIFICATIVA E RELEVÂNCIA	11
1.4	ESTRUTURA DO TRABALHO.....	12
2	BASE CONCEITUAL E REVISÃO DA LITERATURA	14
2.1	TÍTULOS PÚBLICOS E RISCO SOBERANO.....	14
2.2	MCDM/A E DECISÃO MULTICRITÉRIO POR DESAGREGAÇÃO DE PREFERÊNCIAS PARA RATING DE CRÉDITOS SOBERANOS	15
2.3	DOMINANCE-BASED ROUGH SET APPROACH (DRSA).....	18
3	METODOLOGIA.....	24
4	MODELO PROPOSTO	25
4.1	ESCOLHA E COLETA DE INDICADORES	25
4.2	ESCOLHA DOS CRITÉRIOS DE DECISÃO.....	25
5	ANÁLISE DOS RESULTADOS	27
6	CONCLUSÕES.....	30
	REFERÊNCIAS	32
	ANEXO A – DEFINIÇÃO DE INDICADORES	36

1 INTRODUÇÃO

Com o processo cada vez mais amplo de internacionalização dos investimentos, pode-se associar um aumento no grau de incerteza dos investidores em relação à formulação de suas carteiras individuais. A grande questão associada ao risco de aplicações em títulos soberanos é a possibilidade de que os acordos não sejam cumpridos, portanto a análise do risco de inadimplência deste instrumento é de importância fundamental em finanças (MOUSAVI; OUENNICHE, 2018).

Existem avaliações referentes ao risco dos títulos soberanos que são disponibilizadas ao público por agências internacionais de avaliação de crédito, como Standard & Poor's e Moody's. Essas agências aplicam ratings aos países, e assim, indicam o grau de risco associado aos seus respectivos títulos públicos. Assim, as agências indicam se um governo soberano se enquadra em um grau de investimento ou não (CANUTO et al, 2012).

Canuto et al. (2012) explicam que as agências de avaliação do risco de crédito têm o papel de servir, internacionalmente, como principal instrumento de referência dos agentes financeiros na avaliação do risco. Neste contexto, títulos de governos que possuem ratings das agências são preferidos, pelos investidores, em relação aos títulos que não possuem ratings. Entretanto, muitos autores atentam para a subjetividade, falta de transparência e possível falta de qualidade das avaliações das agências (SALVADOR et al., 2014; BELLOTI et al., 2011; ROTHELI, 2010; ANDERSEN et al., 2011) que contribuíram inclusive para a crise do subprime, que começou em 2007.

Segundo Carneiro (2009), muitos chefes de estado têm se queixado das conclusões da agências de risco, que têm sido acusadas de interpretar erroneamente a solvabilidade financeira e se defendem alegando que, algumas vezes, os emissores classificados não providenciam todas as informações importantes para a avaliação. Neste cenário, avaliações e aplicações de ferramentas adicionais são interessantes para agentes financeiros (SILVA et al., 2018).

O presente trabalho dá continuidade ao trabalho realizado por (SILVA et al., 2018) estendendo o estudo de Couto e Gomes (2016) ao utilizar um conjunto maior de indicadores e, principalmente, por classificar a partir da abordagem DRSA um conjunto de países em três diferentes classes de risco. A partir das alocações apresentadas em Silva et al. (2018), realizadas de acordo com os ratings de duas agências de risco, Moody's e Standard & Poor's, para o ano

de 2014, foi realizada a validação da abordagem proposta. Portanto, utiliza-se assim a metodologia DRSA para encontrar padrões e classificar títulos soberanos dentre as classes de risco a partir de 9 indicadores, objetivos, disponíveis em World Bank (2018). Os indicadores referem-se a variáveis econômicas do ano de 2014, e a escolha foi baseada em Silva et al. (2018).

1.1 OBJETIVO GERAL

Encontrar padrões em avaliações de agências de análise de risco de crédito e classificar títulos soberanos dentre as classes de risco a partir de indicadores (critérios), objetivos, disponíveis na base de dados do Banco Mundial (WORLD BANK, 2018).

1.2 OBJETIVOS ESPECÍFICOS

- Definir modelo de decisão multicritério para avaliação de títulos soberanos.
- Coletar e tratar dados necessários para a análise
- Realizar aplicação da técnica DRSA para avaliação de títulos soberanos
- Analisar e comparar os resultados com aqueles obtidos por outros autores na literatura

1.3 JUSTIFICATIVA E RELEVÂNCIA

O investidor precisa quantificar o prêmio pelo risco ao decidir poupar recursos financeiros em algum país, podendo usar informações sobre o crescimento do PIB, conflitos internos, fluxo líquido de exportações, entre outras. O prêmio pelo risco cresce quando um poupador não tem conhecimento suficiente acerca do país no qual planeja investir, isso traduz uma assimetria de informação, o que, possivelmente, virá a inviabilizar a compra do título soberano. Uma das formas de reduzir essa assimetria, que inclusive garante que o suprimento de recursos financeiros não se restrinja à bancos internacionais, é se basear em classificações de risco ou ratings de títulos soberanos, fornecidos por agências de risco, como Moody's e Standard and Poor's (S&P).

Essas duas agências de risco utilizam letras, números e símbolos (+ e -) em seu sistema de classificação, por exemplo, a Moody's classifica os países com mais chance de cumprir com suas obrigações como Aaa e a S&P como AAA. Os ratings fornecidos pelas agências representam riscos relativos Canuto et al. (2012), isto é, refletem a frequência na qual ocorrem os pagamentos dos títulos, portanto, não é necessariamente verdade que um país classificado como Aaa pela Moody's sempre pagará seus débitos.

Isso, aliado a outros fatos, como a incapacidade de prever crises financeiras, a falta de transparência sobre a importância de cada variável econômica, política e social (BELLLOTI et al 2011), faz com que esses ratings sejam objeto de críticas, o que gera a necessidade da construção de um modelo mais preciso de classificação de títulos soberanos. Devido às características da avaliação de riscos soberanos, com representação de múltiplos objetivos no processo decisório a partir de diferentes critérios Standard & Poor's (2014), esse processo pode ser entendido como um problema de decisão multicritério.

DRSA estende a filosofia Rough Sets ao contexto do apoio à decisão multicritério ao substituir as relações de indiscernibilidade (semelhança) por relações de dominância. Com isso, aumenta-se o grau de aplicabilidade da abordagem, relaxando premissas exigidas na abordagem anterior, como a transitividade e a simetria (SLOWINSKI; GRECO; MATRAZZO, 2012). No contexto da problemática de classificação, o DRSA estuda a existência de inconsistências a partir do confronto entre as relações de dominância e a utilização de partições, obtidas através das alternativas dentre as classes da decisão.

Alguns elementos são de particular importância nas abordagens DRSA, sendo descritos a seguir com base em Greco, Matarazzo e Slowinski (2001). Os redutos, conjuntos de critérios que atendam a propriedade de não-redundância, são importantes, já que podem ser utilizados quando novos dados forem coletados, requerendo menos informações do que antes. Por exemplo, se vários redutos forem gerados, o analista pode escolher aquele conjunto de critérios que são mais fáceis de coletar.

As regras de decisão, por sua vez, servem para melhorar o processo de apoio a decisão, de modo a transformar as indicações sobre a classificação de um exemplo de decisão (objeto) em uma linguagem que o decisor compreenda facilmente. As regras de decisão no contexto de Rough Sets são do tipo if/then e contextualizam os fatores que podem ser determinantes, com base na eliciação das preferências do decisor, para decisões futuras

1.4 ESTRUTURA DO TRABALHO

Os próximos capítulos do trabalho têm a seguinte estrutura:

- O capítulo 2 consiste na base conceitual utilizada neste trabalho e na apresentação de artigos e estudos relacionados ao tema;
- O capítulo 3 apresenta a problemática e a metodologia utilizada no trabalho;
- O capítulo 4 apresenta o modelo proposto baseado na metodologia do trabalho;

- O capítulo 5 consiste na análise dos resultados alcançados;
- Por fim, o capítulo 6 apresenta as conclusões do trabalho.

2 BASE CONCEITUAL E REVISÃO DA LITERATURA

2.1 TÍTULOS PÚBLICOS E RISCO SOBERANO

O Banco Central do Brasil (2018a), explica que os títulos públicos federais são instrumentos de renda fixa (pré-fixados ou pós-fixados) emitidos pelo governo federal com objetivo primordial de financiar as suas despesas. Megalli Filho e Ishikawa (2003) explicam as diferenças entre títulos pós-fixados e pré-fixados e entre títulos de renda fixa e de renda variável:

- a. Títulos pós-fixados são reajustados periodicamente por algum parâmetro econômico previamente decidido entre as partes. Por outro lado, os títulos pré-fixados definem, previamente, o valor nominal dos rendimentos a serem pagos no futuro.
- b. Títulos de renda fixa têm o valor de rendimento estabelecido previamente no contrato, sendo assim, livre de incerteza. Por outro lado, os títulos de renda variável possuem uma incerteza relacionada ao valor que assume, ao longo do tempo, o ativo cuja posse foi tomada.

Ao analisar as possibilidades de investimentos em títulos públicos internacionais, os investidores levam em consideração as possibilidades de que o país, ao qual o investimento foi realizado, não retorne os rendimentos acordados. As agências de classificação de risco procuram traduzir a qualidade do crédito ao qual um investidor irá se expor por meio de ratings. No que se refere aos títulos públicos federais, o correspondente das agências é o risco de crédito soberano. O risco soberano é definido por Canuto et al (2012) como o risco de crédito associado às operações que envolvem o crédito de estados soberanos.

Segundo o Banco Central do Brasil (2018b), o rating soberano reflete os fundamentos macro e microeconômicos de um país no longo prazo e, apesar de ter uma definição diferente das medidas risco-país, os dois indicadores possuem uma forte correlação negativa: países com ratings soberanos elevados tendem a apresentar um risco-país mais baixo.

Segundo a Standard & Poor's (2015), a sua metodologia de ratings de governos soberanos “aborda os fatores que afetam a disposição e capacidade de um governo soberano de pagar as suas dívidas integral e pontualmente.” A agência de risco aponta cinco áreas principais para a análise dos ratings soberanos, como apresentado na Figura 2.1, são elas: avaliação institucional, avaliação econômica, avaliação externa, avaliação fiscal e avaliação monetária.




Figura 1. Estrutura dos Rating Soberano da Standard & Poor's

2.2 MCDM/A E DECISÃO MULTICRITÉRIO POR DESAGREGAÇÃO DE PREFERÊNCIAS PARA RATING DE CRÉDITOS SOBERANOS

Ao longo do tempo, estudos voltados à resolução de problemas de decisão multicritério foram realizados e resultaram em uma série de modelos e métodos que auxiliam decisores em diversos ramos de atividade. Um problema de decisão multicritério pode ser definido como uma situação onde existem diferentes cursos de ação para escolher, de forma a múltiplos objetivos (representados por critérios), que podem ser conflitantes entre si (ALMEIDA, 2013).

Neste contexto a tomada/apoio de decisão multicritério (MCDM/A) trabalha a tomada/apoio da decisão com base na estruturação de preferências de um decisor. Almeida (2013) define um modelo de decisão multicritério como “uma representação formal e com simplificação do problema enfrentado com suporte de um método multicritério de apoio a decisão”. A escolha do método MCDM/A é um passo muito importante para a tomada de decisão e depende de fatores tais como a racionalidade da decisão, o tipo de problemática em que o problema a decisão se encontra, a estrutura de preferências do decisor, entre outros.

Em relação às problemáticas, Roy (1996) classifica os problemas de decisão multicritério em quatro diferentes tipos, sendo eles: Problemática de Escolha, Problemática de Classificação, Problemática de Ordenação e Problemática de Descrição. Neste contexto, a problemática de classificação leva em consideração a preferência entre classes e no domínio de cada critério, diferentemente da classificação com base em atributos (*classification*), existe restrição de monotonicidade, sendo esta problemática chamada de *sorting* na literatura (DOUMPOS; ZOPOUNIDIS, 2002).

O autor indica que, na problemática de classificação, um conjunto de classes (categorias) é definido a priori e cada alternativas é alocada a uma das classes desse conjunto. Esse é exatamente o contexto em que se insere o problema apresentado no presente estudo. Zopounidis et al. (2015) exploram diversas aplicações encontradas na literatura referentes à utilização do apoio à decisão multicritério no ramo financeiro.

Doumpos e Zopounidis (2002) afirmam que existem duas formas do modelo de classificação: o modelo quantitativo e o simbólico. A característica em comum desses modelos é que ambos precisam desenvolver relações entre critérios e classificação antes de sua atuação. A abordagem quantitativa baseia-se no uso de técnicas de regressão para desenvolver um modelo com forma funcional $f(g) \rightarrow C$, dependendo da otimização de uma medida de classificação (MOUSSEAU; SLOWINSKI, 1998; JACQUET-LAGREZE; SISKOS, 1982; DOUMPOS; ZOPOUNIDIS, 2004). O modelo simbólico desenvolve um conjunto de Regras de classificação (GRECO; MATARAZZO; SLOWINSKI, 2001).

Alguns métodos que auxiliam na tomada de decisão requerem um árduo trabalho cognitivo por parte dos tomadores de decisão e, possivelmente, consumo significativo de seu tempo. Por exemplo, é necessário obter alguns parâmetros que refletem as preferências do decisor, como pesos, especificação de limiares, entre outros, que possivelmente podem ser fornecidos imprecisamente pelo próprio decisor. Existe um gerenciamento de tempo no processo decisório, que leva em consideração o prazo para a tomada de decisão, o prazo que o analista tem para aplicar o modelo de decisão e a folga de tempo para agir depois da tomada de decisão (Almeida, 2013). Então, se o modelo do analista é “lento” no suporte a decisão por conta da elicitação e interação com o decisor, prazos podem deixar de ser atendidos.

Contudo, foi desenvolvida uma abordagem, denominada desagregação de preferências, que requer apenas que o decisor exerça suas decisões, para que estas sirvam de input para um algoritmo computacional, que, mediante otimização, obterá valores quantitativos dos elementos

do método de apoio a decisão (JACQUET-LAGREZE; SISKOS, 1982). O processo de aplicação do modelo pode ocorrer sem interferência, porém, se for necessário melhorar a precisão do modelo, pode haver uma interferência mínima do decisor. Na problemática de classificação usa-se um conjunto de referência como input para o modelo de apoio à decisão. Nestes conjuntos estão contidos exemplos de decisão reais, alocados previamente a uma classe, com suas respectivas avaliações intracritério. Para um modelo quantitativo, as etapas seguidas nesta abordagem são apresentadas a seguir na Figura 2.2 (MOUSSEAU; SLOWINSKI, 1998; DOUMPOS; ZOPOUNIDIS, 2002):




Figura 2. O processo de suporte à decisão pela abordagem de desagregação de preferências. Adaptado de Doumpos e Zopounidis (2002).

Com relação ao modelo simbólico, o processo segue-se até a determinação do conjunto de referência, critérios e alternativas, já que não é necessário um modelo de agregação e sim a indução de regras.

No campo financeiro, uma importante gama de aplicações de métodos de classificação multicritério é encontrada na literatura, indo desde avaliação de risco de créditos soberanos até risco de falência de empresas. Zopounidis et al. (2015) apresenta uma revisão da literatura relativa à MCDM/A em finanças, onde risco de crédito e soberano são campos que mais se destacam. Doumpos et al. (2001) aplicou uma abordagem por desagregação de preferências, chamada MHDIS, para classificar países em quatro níveis de risco.

Greco et al. (2009) avaliou o risco de investir em um conjunto de 52 países avaliados em 27 critérios, a partir de regras de decisão, induzidas com base na teoria clássica dos conjuntos aproximativos (Rough Sets). Silva et al. (2018) utilizou uma adaptação do PROMETHEE II para problemas de classificação, com desagregação de preferências a partir de programação matemática para obter os pesos de cada critério. Os autores classificaram países, avaliados em critérios financeiros objetivo, em três categorias de risco.

Hu e Chen (2011) propuseram um modelo multicritério de sobreclassificação, baseado na formulação do PROMETHEE II, e aplicaram este para prever quando um empreendimento iria falir. A qualidade de crédito de organizações também foi avaliada por Doumpos e Figueira (2018), usando um novo método chamado ELECTRE TRI-nC, em uma aplicação sobre títulos de créditos corporativos.

2.3 DOMINANCE-BASED ROUGH SET APPROACH (DRSA)

DRSA é uma evolução da abordagem clássica da filosofia Rough Sets, sendo esta última introduzida por Pawlak (1982), que analisava semelhanças entre os objetos (alternativas) descritos por atributos para induzir regras de classificação, sendo aplicável na problemática *classification*. A DRSA é a abordagem perfeita para análise de decisão multicritério, mais especificamente para *sorting*, já que leva em consideração a descrição das alternativas e relação de dominância entre elas, e também a preferência entre as classes nas quais essas alternativas foram inseridas (GRECO; MATARAZZO; SLOWINSKI, 2001).

Na primeira etapa da análise, é realizada a identificação de inconsistências no conjunto de referência selecionado pelo analista. Dada uma tabela de dados $S = \langle U, Q, V, f \rangle$, onde U é um conjunto finito de objetos (alternativas), $Q = C \cup D$, onde C é o conjunto de critérios (ou critérios condicionais) e D é o conjunto de classes (ou critério de decisão), $V = \bigcup_{q \in Q} V_q$ é o domínio do critério q , que pode ser contínuo ou discreto, e $f: U \times Q \rightarrow V$ é a função informação, pode-se extrair o conhecimento primordial para a DRSA: os grânulos de informação.

$$D_p^+(x) = \{y \in U : yD_px\} \quad (1)$$

$$D_p^-(x) = \{y \in U : xD_py\} \quad (2)$$

As relações binárias D_p são de sobreclassificação. $D_p^+(x)$, o conjunto p-dominante, contém todas as alternativas que dominam a alternativa x com relação a um conjunto $P \subseteq C$ de critérios. De maneira oposta, $D_p^-(x)$, o conjunto p-dominado, contém todas as alternativas que são dominadas pela alternativa x . Baseando-se nestes grânulos do conhecimento, denominados cones de dominância, deve-se verificar a existência de inconsistências particionando-se o conjunto U da seguinte forma:

$$Cl_t^{\geq} = \bigcup_{s \geq t} Cl_s \quad (3)$$

$$Cl_t^{\leq} = \bigcup_{s \leq t} Cl_s \quad (4)$$

$Cl_t^{\geq}$ é a união ascendente de classes, enquanto $Cl_t^{\leq}$ é a união descendente de classes, considerando que a direção de preferência cresce da classe 1 para a classe n . Se um objeto x pertence a uma classe t ou melhor, ou seja, pertence a partição $Cl_t^{\geq}$, mas é dominado por um objeto $y \in Cl_{t-1}^{\leq}$ (pertence a uma classe pior que t), então existe inconsistência nesta tabela de dados, já que estes objetos não atendem às restrições de monotonicidade. Inconsistências ocorrem quando: $x \in Cl_t^{\geq}$ e $D_p^+(x) \cap Cl_{t-1}^{\leq} \neq \emptyset$ ou $x \notin Cl_t^{\geq}$ e $D_p^-(x) \cap Cl_{t-1}^{\geq} \neq \emptyset$. Percebe-se que x possivelmente pertence a uma determinada partição quando existe inconsistência dessa alternativa com relação ao princípio de dominância. Então dado que existe ambiguidade sobre a alocação de x a uma classe, deve-se encontrar formas de representa-la. Estas formas serão desenvolvidas a seguir.

$$P_*(Cl_t^{\geq}) = \{x \in U : D_p^+(x) \subseteq Cl_t^{\geq}\} \quad (5)$$

$$P^*(Cl_t^{\geq}) = \{x \in U : D_p^-(x) \cap Cl_t^{\geq} \neq \emptyset\} \quad (6)$$

Todos os elementos que com certeza pertencem a $Cl_t^{\geq}$, sem ambiguidade, fazem parte do conjunto $P_*(Cl_t^{\geq})$, que é a aproximação inferior de $Cl_t^{\geq}$. Todos os elementos que possivelmente pertencem a $Cl_t^{\geq}$ fazem parte do conjunto $P^*(Cl_t^{\geq})$, que é a aproximação superior de $Cl_t^{\geq}$. De maneira análoga:

$$P_*(Cl_t^{\leq}) = \{x \in U : D_p^-(x) \subseteq Cl_t^{\leq}\} \quad (7)$$

$$P^*(Cl_t^{\leq}) = \{x \in U : D_p^+(x) \cap Cl_t^{\leq} \neq \emptyset\} \quad (8)$$

O conjunto que contém todos os elementos ambíguos é denominado P-fronteira. Se existe região de fronteira, então existem conjuntos aproximativos (Rough Sets), que são aproximações de determinadas partições de U.

$$Bn_p(Cl_t^{\geq}) = P^*(Cl_t^{\geq}) - P_*(Cl_t^{\geq}) \quad (9)$$

$$Bn_p(Cl_t^{\leq}) = P^*(Cl_t^{\leq}) - P_*(Cl_t^{\leq}) \quad (10)$$

Após a verificação de inconsistência, prossegue-se com a identificação de critérios redundantes. Existe uma razão de elementos classificados sem ambiguidade em uma partição com relação a um conjunto $P \subseteq C$ de critérios, essa razão é a qualidade de aproximação da partição X:

$$\gamma_p(X) = \frac{|P_*(X)|}{|X|} \quad (11)$$

Doumpos e Zopounidis (2002, apud Roy, 1985) reforçam que para ser consistente, uma das propriedades que a família de critérios C deve satisfazer é a de não-redundância. Portanto, se a eliminação de qualquer critério implica na continuidade de satisfação das restrições de monotonicidade, então C é redundante. A filosofia Rough Sets desenvolveu formas de gerar redutos, ou seja, conjuntos de critérios que atendam a propriedade de não-redundância. Desse modo, qualquer subconjunto $P \subseteq C$ que satisfaça $\gamma_p(X) = \gamma_c(X)$ é um reduto de C. Os redutos são importantes, já que podem ser utilizados quando novos dados forem coletados, requerendo menos informações do que antes. Por exemplo, se vários redutos forem gerados, o analista pode escolher aquele conjunto de critérios que são mais fáceis de coletar.

$$Core = \cap Red_i \quad (12)$$

Vale reforçar que critérios que estão contidos em todos os redutos são parte do *Core*, sendo estes critérios indispensáveis na análise. Atributos comutáveis/permutáveis estão contidos em alguns redutos, mas não no *Core*, e critérios redundantes não são nem indispensáveis nem comutáveis, assim, não pertencem a nenhum reduto.

Regras de decisão servem para melhorar o processo de apoio a decisão, de modo a transformar as indicações sobre a classificação de um exemplo de decisão (objeto) em uma linguagem que o decisor compreenda facilmente. A tabela de dados S contém atributos condicionais (conjunto C) e atributos de decisão (conjunto D), que, durante o processo de indução de regras, terão suas dependências funcionais exploradas. Ao final do processo serão geradas regras do tipo “Se ..., Então”, em que a primeira parte é a parcela condicional, que descreve os exemplos de decisão (elementos de U) em termos dos elementos de C, e a segunda

é a parte é a conclusão sobre o objeto, que descreve os exemplos de decisão em termos dos elementos de D. Segue exemplo da estrutura geral de uma regra:

$$\begin{aligned} se f(x, q_1) = r_{q_1} e f(x, q_2) = r_{q_2} e \dots e f(x, q_p) = r_{q_p}, \\ então x pertence a Y_{j_1} ou Y_{j_2} ou \dots ou Y_{j_k} \end{aligned} \quad (13)$$

Onde Y_{ji} são os elementos de D. Se $k = 1$ a regra é exata e se $k > 1$ então a regra pode ser aproximada ou ambígua. Agora serão discutidos os tipos de regras, mas antes é necessário definir o que são exemplos positivos e o que são exemplos negativos. Exemplos positivos são os exemplos pertencente ao conjunto D-elementar e todos os outros são exemplos negativos. O conjunto D-elementar pode assumir várias formas no processo de indução:

$$D_A = P_*(Cl_t^{\geq}) \cup P_*(Cl_s^{\leq}) \quad (14)$$

$$D_B = P^*(Cl_t^{\geq}) \cup P^*(Cl_s^{\leq}) \quad (15)$$

$$D_c = P^*(Cl_t^{\geq}) \cap P^*(Cl_s^{\leq}) \quad (16)$$

As formas de D-elementar dependem da existência do conjunto no qual este se transformará. As regras induzidas pelo conjunto D_A sugerem que x deve ser atribuído *com certeza* a uma classe $Cl_t^{\geq}$ ou $Cl_s^{\leq}$ ($s < t$), as induzidas pelo conjunto D_B sugerem que x deve ser *possivelmente* atribuído a uma classe $Cl_t^{\geq}$ ou $Cl_s^{\leq}$ ($s < t$) e as induzidas pelo conjunto D_c sugerem que x deve ser *aproximadamente* atribuído a algumas classes entre $Cl_t^{\geq}$ e $Cl_s^{\leq}$. Os tipos de regras são apresentados a seguir:

- Regras de decisão $D_{\geq}$ certas: caracterizam, por perfis inferiores, objetos que pertencem a $P_*(Cl_t^{\geq})$. Forma geral: $f_{i_1}(x) \geq r_{i_1} e \dots e f_{i_p}(x) \geq r_{i_p}$, então $x \in Cl_t^{\geq}$.
- Regras de decisão $D_{\geq}$ possíveis: caracterizam, por perfis inferiores, objetos que pertencem a $P^*(Cl_t^{\geq})$. Forma geral: $f_{i_1}(x) \geq r_{i_1} e \dots e f_{i_p}(x) \geq r_{i_p}$, então x possivelmente $\in Cl_t^{\geq}$.
- Regras de decisão $D_{\leq}$ certas: caracterizam, por perfis superiores, objetos que pertencem a $P_*(Cl_s^{\leq})$. Forma geral: $f_{i_1}(x) \leq r_{i_1} e \dots e f_{i_p}(x) \leq r_{i_p}$, então $x \in Cl_s^{\leq}$.
- Regras de decisão $D_{\leq}$ possíveis: caracterizam, por perfis superiores, objetos que pertencem a $P^*(Cl_s^{\leq})$. Forma geral: $f_{i_1}(x) \leq r_{i_1} e \dots e f_{i_p}(x) \leq r_{i_p}$, então x possivelmente $\in Cl_s^{\leq}$.
- Regras de decisão $D_{\geq \leq}$ aproximadas: caracterizam, por perfis superiores e inferiores, objetos que pertencem a classes entre $Cl_t^{\geq}$ e $Cl_s^{\leq}$, sem distinguir a qual das classes eles pertencerão.

Com o que foi dito acima, depois do processo de indução de regras, faz-se necessário saber o quão atrativas ou confiáveis são essas regras. Neste trabalho usaremos o software jMAF (BLASZCZYNSKI et al., 2012) para realizar algumas análises simples de consistência, geração de redutos e indução de regras de decisão. O jMAF utiliza alguns conjuntos e medidas estatísticas que mostram o quanto uma regra é suportada pelos elementos do conjunto universo, também para verificar se a parte de decisão da regra é confirmada por sua parte condicional. (BLASZCZYNSKI et al., 2012; GRECO; PAWLAK; SLOWINSKI, 2004).

- *LearningPositiveExamples*: Esse é o conjunto dos elementos que satisfazem pelo menos a condição de decisão (conclusão) de uma determinada regra. Neste conjunto, o algoritmo do jMAF (BLASZCZYNSKI et al., 2012) tenta discriminar os exemplos positivos (que serão alocados pela parte de decisão da regra) e os exemplos negativos, para então induzir a regra. Ou seja, o algoritmo aprende sobre os exemplos positivos. O resultado da discriminação do algoritmo induz três tipos de regras: regras que diferenciam, precisamente, os exemplos positivos dos negativos, são consistentes e denominadas de regras *discriminantes*; regras cuja remoção de qualquer atributo da parte condicional implica na cobertura de exemplos negativos são denominadas regras *mínimas*; e por fim, existem também as regras *parcialmente discriminantes* podem cobrir uma quantidade limitada de exemplos negativos, desse modo, é de extrema importância a medição de sua confiança (*confidence*), medida que será discutida mais adiante. Se o conjunto *LearningPositiveExamples* é igual aproximação inferior de uma determinada classe disjunta (ex.: pelo menos Cl3, até Cl2), então a regra induzida é *certa*. Se o conjunto *LearningPositiveExamples* é igual aproximação superior de uma determinada classe disjunta, então a regra induzida é *possível*. Se o conjunto *LearningPositiveExamples* é igual a interseção entre aproximações superiores de classes disjuntas, então a regra induzida é *aproximada*, tendo atribuições de exemplos entre classes dessa interseção.
- *Support e SupportingExamples*: O conjunto *SupportingExamples* contém elementos que satisfazem a premissa (parte condicional) e a conclusão (decisão) da regra. *Support* é a cardinalidade desse conjunto.
- *Strength*: *Strength* é a razão entre *Support* e o conjunto universo, ou seja, é a razão entre os elementos de U (conjunto universo) que satisfazem as partes condicional e de decisão da regra e o número total de elementos contidos em U.

- *CoverageFactor, Coverage e CoveredExamples*: *CoveredExamples* de uma regra, é o conjunto dos elementos que satisfazem pelo menos a parte condicional dessa regra. *Coverage* é a cardinalidade desse conjunto. *CoverageFactor* é a razão entre a *Coverage* e os *LearningPositiveExamples*, ou seja, a razão entre o número de elementos que satisfazem pelo menos a parte condicional da regra e o número de elementos que satisfazem pelo menos a parte de decisão da regra.
- *Confidence/Certainty Factor*: Razão entre *Support* e *Coverage*, ou seja, a razão entre a quantidade de elementos que satisfazem a regra como um todo e a quantidade de elementos que satisfazem pelo menos a parte condicional dessa regra. Se for igual a 1, a regra é certa. Esse índice é característico das regras parcialmente discriminantes, pois, verifica a razão entre os exemplos positivos e os mesmos exemplos positivos somados a uma parcela de exemplos negativos. Percebe-se que o software jMAF (BLASZCZYNSKI et al., 2012) supõe que as regras que serão induzidas serão parcialmente discriminantes.

Shen e Tzeng (2014) utilizaram a metodologia DRSA integrada a um modelo que realiza previsão da melhoria de performance de bancos comerciais, com o objetivo de selecionar critérios financeiros críticos. Shen e Tzeng (2015) reduziram critérios financeiros e induziram regras de decisão a partir da DRSA como parte de um modelo que classifica ações como “boas” ou “ruins”.

Em relação à aplicações em gestão de títulos soberanos, Couto e Gomes (2016) analisam os ratings soberanos sob uma abordagem multicritério com utilização do princípio de Dominância (DRSA), utilizando um conjunto de 8 critérios e duas possíveis recomendações da agência Standard & Poor's: investir ou não investir. Os autores, assim, encontram padrões dentro do conjunto de variáveis econômicas que podem explicar as recomendações aos países.

3 METODOLOGIA

A metodologia deste trabalho é mostrada na Figura 1 abaixo. A etapa de preparação para análise consiste na escolha dos critérios e conjunto de decisão do modelo multicritério. Além disso, uma vez que DRSA é uma técnica que obtém conhecimento sobre o decisor por aprendizado supervisionado, é necessário construir um conjunto de referência, pré-alocando alternativas às classes consideradas. Nesta etapa, deve-se também escolher o ano para a coleta de dados e o universo de países que serão analisados.




Figura 3. Metodologia do trabalho

Em seguida, serão gerados subconjuntos de critérios não-redundantes, denominados redutos, possibilitando, possivelmente, incluir países avaliados em subconjuntos dos critérios considerados na análise. Para escolher o reduto que será utilizado na etapa posterior, será levado em consideração o número de países que este abrange e a quantidade de critérios contida nele.

Após a escolha do reduto, serão induzidas regras de decisão para classificar países. Deve-se analisar a atratividade e confiança das regras, verificando o tipo de regra (certa, possível ou aproximada) e avaliando as medidas de confirmação bayesianas associadas. Depois de gerar as regras de classificação os países avaliados no reduto escolhido serão classificados, avaliando-se por fim o desempenho das regras de decisão induzidas.

4 MODELO PROPOSTO

4.1 ESCOLHA E COLETA DE INDICADORES

Foi considerado o resultado obtido por Silva et al. (2018), em que este último encontrou, utilizando análises estatísticas, critérios, dentre 18 encontrados no website do World Bank (2018), que, potencialmente, influenciam a classificação por parte das agências de risco. Os 18 critérios são expostos no Quadro 1, e os que realmente serão utilizados na análise, por influenciarem a classificação, têm o campo *Nomenclatura* preenchido

Nº	Critério	Nomenclatura na análise	Tipo
1	GDP growth (annual %)	-	Max
2	GDP per capita (current US\$)	Gdpp	Max
3	Current account balance (BoP, current US\$)	-	Max
4	Inflation, GDP deflator (annual %)	-	Min
5	Exports of goods and services (% of GDP)	Exp	Max
6	Gross savings (% of GDP)	Grosssav	Max
7	External debt stocks, total (DOD, current US\$)	-	Min
8	Foreign direct investment, net inflows (BoP, current US\$)	Foreigninv	Max
9	GDP at market prices (current US\$)	Gdppmp	Max
10	Total reserves (includes gold, current US\$)	Totalreserv	Max
11	GNI per capita, Atlas method (current US\$)	Gnip	Max
12	Lending interest rate (%)	Lendinirate	Min
13	Risk premium on lending (lending rate minus treasury bill rate, %)	-	Max
14	S&P Global Equity Indices (annual % change)	-	Max
15	Real interest rate (%)	Realinrate	Min
16	Net flows on external debt, long-term (NFL, current US\$)	-	Max
17	Depth of credit information index (0=low to 8=high)	-	Max
18	Money and quasi money growth (annual %)	-	Max

Quadro 1. Critérios utilizados na análise.

4.2 ESCOLHA DOS CRITÉRIOS DE DECISÃO

Foram adotadas as três classes do modelo de Silva et al. (2018): C_1 , que contém países de baixíssimo risco, C_2 , contendo países de risco baixo a moderado, e C_3 , contendo países que possuem grau especulativo e alto risco. Estas classes constituem o domínio do critério de decisão, no qual existe relação de dominância, assim, a classe C_1 é a mais preferível e a classe C_3 é a menos preferível.

Considerou-se o cenário pessimista/conservador de Silva et al. (2018): a alocação para uma das classes é feita a partir da pior classificação daquele país entre as agências. No quadro abaixo é mostrado o espectro de cada classe com base no sistema de classificação da Moody's e S&P.

Ratings – Agências de Classificação			
TIPO	CLASSES	Moody's	Standard & Poor's
Grau de investimento (qualidade alta)	CLASSE C_1	Aaa Aa1 Aa2 Aa3 A1 A2 A3	AAA AA+ AA AA- A+ A A-
Grau de investimento (qualidade média)	CLASSE C_2	Baa1 Baa2 Baa3	BBB+ BBB BBB-
Grau de especulação (qualidade baixa)	CLASSE C_3	Ba1 Ba2 Ba3 B1 B2 B3	BB+ BB BB- B+ B B-
Alto risco de inadimplência		Caa1 Caa2 Caa3 Ca C	CCC+ CCC CCC- CC C D

Quadro 2. Conversão de Ratings; Fonte: Silva et al. (2018).

Exemplos de alocação nas classes são apresentados na Tabela 1 a seguir.

País	S&P	Moody's	CLASSE
P1	A+	A1	1
P2	AA	Aa2	1
P3	BBB-	Baa2	2
P4	BBB	Baa2	2
P5	CCC-	Caa3	3
P6	B-	Caa3	3

Tabela 1. Exemplos de alocação nas classes do modelo.

5 ANÁLISE DOS RESULTADOS

Como não é possível classificar todos os países com os 9 critérios selecionados para a análise, devido a falta de mensuração destes indicadores em vários países, a intenção é gerar redutos, induzir regras de decisão usando um desses redutos, e por fim, classificar o maior número possível de títulos soberanos de 2014 utilizando o software jMAF (BLASZCZYNSKI et al., 2012).

Uma vez que a base de dados do World Bank (2018) não contém todos os valores dos indicadores para cada um dos países em seus bancos de dados, focou-se em 45 países, avaliados em todos os 9 indicadores, para a escolha dos exemplos de treinamento que servirão de input para indução de regras no software jMAF (BLASZCZYNSKI et al., 2012), em virtude de que esses são os únicos avaliados nos nove critérios destacados pelo quadro 1 e que foram avaliados ou na Moody's ou na S&P no ano de 2014. Esses países foram realocados nas três classes do modelo de Silva et al. (2018)

Na problemática de classificação escolhe-se uma amostra para que o modelo utilizado aprenda sobre a população. Seria necessária a opinião de especialistas sobre possíveis conjuntos de referência, porém, como o trabalho aqui procurará utilizar a filosofia de desagregação de preferências, ou seja, reduzir ao máximo o esforço do decisor no processo de tomada de decisão, será selecionado um conjunto de referência aleatório para testar uma aplicação do jMAF (BLASZCZYNSKI et al., 2012) para a classificação de títulos soberanos. O conjunto escolhido é mostrado no Quadro 3.

Classe C_1	Classe C_2	Classe C_3
Austrália	Índia	Argentina
Estônia	Filipinas	Hungria
Reino Unido	Itália	Bulgária

Quadro 3. Conjunto de Referência.

Os redutos encontrados para o conjunto de referência estão expostos no Quadro 4.

Nº	Reduto
1	{grosssav,foreigninv,lendinintrate}
2	{exp,grosssav,foreigninv}
3	{grosssav,gdpmp,lendinintrate}
4	{exp,grosssav,gdpmp,realintrate}
5	{grosssav,gnip}
6	{gdpp,grosssav}
7	{totalreserv,gnip,lendinintrate}
8	{totalreserv,gnip,realintrate}

9	{exp,totalreserv,gnip}
10	{gdppmp,gnip,lendinintrate}
11	{foreigninv,gdppmp,gnip,realintrate}
12	{exp,gdppmp,gnip}
13	{gdpp,totalreserv,lendinintrate}
14	{gdpp,totalreserv,realintrate}
15	{gdpp,exp,totalreserv}
16	{gdpp,gdppmp,lendinintrate}
17	{gdpp,foreigninv,gdppmp,realintrate}
18	{gdpp,exp,gdppmp}

Quadro 4. Redutos gerados pelo jMAF.

Estes redutos mantêm a qualidade de aproximação dos 9 critérios originais, mantendo apenas indicadores não-redundantes. Foi escolhido o reduto 15 para a induzir regras de classificação, visto que são critérios que foram aferidos em boa parte dos países que foram classificados pela Moody's e Standard & Poor's no ano de 2014 (107 países no total). Outro critério de escolha foi o reduto com o menor número de elementos. Pode-se ver que os redutos 5 e 6 são os que contém menos elementos, porém, o critério grossavings, presente em ambos, foi quantificado em apenas 66 países, o que diminui a quantidade de países avaliados pelas regras de classificação na etapa seguinte. As regras induzidas a partir do conjunto de referência e reduto escolhidos são apresentadas no quadro abaixo.

Nº	Regras	Str	Cov	Conf
1	(gdpp >= 46331.9774103502) => (RiskClass >= 1)	0.2222	0.6667	1
2	(gdpp >= 20161.581794126) & (exp >= 83.9053173221231) => (RiskClass >= 1)	0.1111	0.3333	1
3	(totalreserv >= 53910.3460844978) => (RiskClass >= 2)	0.5556	0.8333	1
4	(gdpp >= 20161.581794126) => (RiskClass >= 2)	0.4444	0.6667	1
5	(gdpp <= 14028.7220956269) & (totalreserv <= 42019.8817324703) => (RiskClass <= 3)	0.3333	1	1
6	(gdpp <= 14028.7220956269) => (RiskClass <= 2)	0.5556	0.8333	1
7	(gdpp <= 34908.5009745916) & (exp <= 29.5691525396354) => (RiskClass <= 2)	0.4444	0.6667	1

Quadro 5. Regras induzidas pelo jMAF.

Todas as regras geradas tem *Confidence* igual 1.

As regras 1 e 2, que classificam países pelo menos na classe C_1 , são satisfeitas por 22.22% e 11.11% dos países de referência, respectivamente. A chance de um país de referência satisfazer a parte condicional da regra 1 é maior que a da regra 2.

Uma única regra para classificar países até a classe 3 foi gerada, já que todos os países de referência pertencentes à classe 3, utilizados para induzi-la, têm probabilidade 1 de satisfação das partes condicionais dessa regra.

As regras 3 e 4, que classificam países pelo menos na classe C_2 , são satisfeitas por 55.56% e 44.44% dos países de referência, respectivamente. A chance de um país de referência satisfazer a parte condicional da regra 3 é maior que a da regra 4.

As regras 6 e 7, que classificam países na classe C_2 ou C_3 , são satisfeitas por 55.56% e 44.44% dos países de referência, respectivamente. A chance de um país de referência satisfazer a parte condicional da regra 6 é maior que a da regra 7.

Os resultados da razão de países classificados corretamente estão resumidos no quadro 6. No total, 79 países de 107 (73.87%) foram classificados corretamente. Países que originalmente pertencem à C_1 , foram incorretamente classificados mais frequentemente. Isso se deve ao fato de que a classificação desses países pelas agências dependem, de maneira significativa, de critérios subjetivos tais como variáveis políticas e sociais, não incluídas na análise.

Classe C_1	Classe C_2	Classe C_3	Total
53.13%	73.91%	86.54%	73.87%

Quadro 6. Resultado da classificação de 107 países.

Houve um aumento na taxa de acertos na classe C_2 e na C_3 . Isto mostra que os critérios utilizados na indução das regras, ainda que sendo um subconjunto menor do que o original considerado, representam bem as características dos países que são classificados pelas agências em categorias de risco moderada e alta. Pode-se considerar, a partir da extrapolação dos países classificados na C_3 , classe com maior taxa de classificações corretas, que o reduto contendo critérios financeiros objetivos são suficientes descrever países com maior risco associado, sem critérios subjetivos em futuras análises.

Percebe-se que esta ferramenta auxilia a análise do investidor de duas formas. A primeira é relacionada à redução da quantidade de informação na análise, que, consequentemente, implica em abranger um maior contingente de países com informações insuficientes. A segunda se refere à fácil interpretação dos padrões icógnitos nos dados, onde, por meio de regras de decisão, consegue-se um resumo linguístico do tipo “se..., então...” da tabela de dados rotulados.

6 CONCLUSÕES

Este trabalho apresentou uma avaliação de risco segundo a abordagem DRSA para títulos soberanos, através de um conjunto inicial de 18 indicadores financeiros. A partir de um dos redutos gerados no modelo, foi realizada uma indução de regras de decisão para a classificação de um conjunto de 107 países emissores dos títulos. Através da metodologia aplicada é possível justificar formalmente os ratings fornecidos por agências internacionais de classificação de risco como Standard & Poor's e Moody's, resultando numa semelhança de 73,87%.

Assim, os resultados são notáveis pela quantidade de países classificados a partir de um conjunto de 9 alternativas de referência. Dentre os aspectos que podem explicar em parte a não uma aderência total, pode-se citar, a adoção exclusiva de critérios objetivos (representados por indicadores econômicos) passíveis de auditoria ou reprodução por terceiros. Portanto, é importante ressaltar que nem sempre são fornecidas justificativas plausíveis para estes aspectos subjetivos considerados para o *rating* de títulos de crédito, o que abre espaço para os questionamentos que surgiram desde 2008, que reforçam a necessidade da observância de aspectos regulatórios para os agentes do sistema financeiro e a possibilidade de verificação e teste dos modelos de estimação de risco de crédito (ALMEIDA et al., 2017).

A utilização de redutos neste estudo gerou resultados interessantes, pois foram necessários menos critérios para obter as classificações, e também torna o modelo mais simples para compreensão e interpretação dos resultados. Assim, menor tempo e esforço são necessários na etapa de coleta de dados e pode-se classificar países que foram avaliados em poucos critérios. Além disso, redutos permitem aumentar o escopo de países que serão avaliados, pois, nem todos os dados de indicadores para cada um dos países estão disponíveis na base do World Bank (2018). Desta forma, enquanto Silva et al. (2018) classificaram apenas 36 países com o método PROMETHEE (DOUMPOS; ZOPOUNIDIS, 2004), as regras de decisão geradas pelo reduto analisado no presente trabalho estendem o trabalho apresentado por Silva et al. (2018), permitindo a classificação de 107 títulos soberanos dentre as classes de risco. Isso pode ser ainda mais promissor como um método de classificação para anos futuros, utilizando menos variáveis que estão relacionadas com o *rating* de crédito para estes títulos.

De maneira geral, a abordagem DRSA mostrou-se uma ferramenta mais adequada para a classificação de títulos soberanos. Com um reduto de apenas 3 critérios objetivos, um modelo apresentou uma performance significativa. Dessa forma, esse estudo contribui com a literatura

ao realizar uma aplicação multicritério com dados reais disponibilizados pelo World Bank, além de apresentar uma abordagem adicional para a análise de risco em investimentos.

REFERÊNCIAS

- ALMEIDA, A. T. **Processo de decisão nas organizações: construindo modelos de decisão multicritério**. São Paulo: Atlas, 2013.
- ALMEIDA, Heitor et al. The Real Effects of Credit Ratings: The Sovereign Ceiling Channel. **The Journal Of Finance**, [s.l.], v. 72, n. 1, p.249-290, 12 jan. 2017.
- ANDERSEN, L.b. et al. The financial crisis in an operational risk management context—A review of causes and influencing factors. **Reliability Engineering & System Safety**, [s.l.], v. 105, p.3-12, set. 2012.
- BANCO CENTRAL DO BRASIL (2018a). **Glossário**. Disponível em <<http://www.bcb.gov.br/GlossarioLista.asp?idioma=P&idpai=GLOSSARIO>> Acesso em 01 de junho 2016.
- BANCO CENTRAL DO BRASIL (2018b). **Risco-País**. Disponível em <<http://www4.bcb.gov.br/pec/gci/port/focus/FAQ%209-Risco%20Pa%C3%ADs.pdf>> Acesso em 01 de junho 2016.
- BELLOTTI, Tony; MATOUSEK, Roman; STEWART, Chris. Are rating agencies' assignments opaque? Evidence from international banks. **Expert Systems With Applications**, [s.l.], v. 38, n. 4, p.4206-4214, abr. 2011
- BLASZCZYNSKI, J., GRECO, S., MATARAZZO, B., SLOWINSKI, R., SZELAĞ, M. (2012). **jMAF**. Instituto de Ciência da Computação, Universidade de Tecnologia de Poznan, Polônia. Web page: <http://www.cs.put.poznan.pl/jblaszczyński/Site/jRS.html>. Acessado em 21 de julho 2018.
- CANUTO, O.; SANTOS, P. F. P.; PORTO, P. C. S. MACROECONOMICS AND SOVEREIGN RISK RATINGS. **Journal Of International Commerce, Economics And Policy**, [s.l.], v. 03, n. 02, jun. 2012.
- CARNEIRO, P. E. Ten years' analysis of sovereign risk: noise-rater risk, panels, and errors. **The Journal Of Risk Finance**, [s.l.], v. 10, n. 2, p.107-130, 27 fev. 2009.
- COUTO, A. B. G.; GOMES, L. F. A. M. **Análise do rating soberano por meio da DRSA – Dominance Based Rough Set Approach**. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 48., 2016, Vitória. Anais do XLVIII Simpósio Brasileiro de Pesquisa Operacional. Rio de Janeiro: Sobrapo, 2016. p. 194 – 204.

DOUMPOS, Michalis; FIGUEIRA, José Rui. A multicriteria outranking approach for modeling corporate credit ratings: An application of the Electre Tri-nC method. **Omega**, [s.l.], p.1-15, jan. 2018.

DOUMPUS, M.; PENTARAKI, K.; ZOPOUNIDIS, C; AGORASTOS, C. Assessing country risk using a multi-group discrimination method: a comparative analysis. **Managerial Finance**, [s.l.], v. 27, n. 8, p.16-34, ago. 2001

DOUMPOS, M.; ZOPOUNIDIS, C. Assessing financial risks using a multicriteria sorting procedure: the case of country risk assessment. **Omega**, [s.l.], v. 29, n. 1, p.97-109, fev. 2001

DOUMPOS, M.; ZOPOUNIDIS, C.. **Multicriteria Decision Aid Classification Methods**. Nova Iorque: Springer Verlag NY, 2002.

DOUMPOS, M.; ZOPOUNIDIS, C. A multicriteria classification approach based on pairwise comparisons. **European Journal Of Operational Research**, [s.l.], v. 158, n. 2, p.378-389, out. 2004.

GRECO, S.; MATARAZZO, B.; SLOWINSKI, R. ZANAKIS, S. Global investing risk: a case study of knowledge assessment via rough sets. **Annals Of Operations Research**, [s.l.], v. 185, n. 1, p.105-138, 6 maio 2009

GRECO, S.; MATARAZZO, B.; SLOWINSKI, R. Rough sets theory for multicriteria decision analysis. **European Journal Of Operational Research**, [s.l.], v. 129, n. 1, p.1-47, fev. 2001.

GRECO, S.; PAWLAK, Z.; SLOWINSKI, R. Can Bayesian confirmation measures be useful for rough set decision rules? **Engineering Applications Of Artificial Intelligence**, [s.l.], v. 17, n. 4, p.345-361, jun. 2004.

HU, Y.; CHEN, C. A PROMETHEE-based classification method using concordance and discordance relations and its application to bankruptcy prediction. **Information Sciences**, [s.l.], v. 181, n. 22, p.4959-4968, nov. 2011.

JACQUET-LAGREZE, E.; SISKOS, J.. Assessing a set of additive utility functions for multicriteria decision-making, the UTA method. **European Journal Of Operational Research**, [s.l.], v. 10, n. 2, p.151-164, jun. 1982.

MELLAGI FILHO, A.; ISHIKAWA, S. **Mercado Financeiro e de Capitais**. - 2 ed. – São Paulo: Editora Atlas, 2003.

MOUSAVI, Mohammad Mahdi; OUENNICHE, Jamal. Multi-criteria ranking of corporate distress prediction models: empirical evaluation and methodological contributions. **Annals Of Operations Research**, [s.l.], v. 271, n. 2, p.853-886, 19 mar. 2018.

MOUSSEAU, V.; SLOWINSKI, R.. Inferring an ELECTRE TRI Model from Assignment Examples. **Journal Of Global Optimization**, [s.l.], v. 12, n. 2, p.157-174, 1998.

PAWLAK, Z. Rough sets. **International Journal Of Computer & Information Sciences**, [s.l.], v. 11, n. 5, p.341-356, out. 1982.

RÖTHELI, T. F. Causes of the Financial Crisis: Risk Misperception, Policy Mistakes, and Banks' Bounded Rationality. **Ssrn Electronic Journal**, [s.l.], p.119-126, 2010.

ROY, B. Multicriteria methodology for decision aiding. Kluwer Academic Publishers, 1996.

SALVADOR, C.; PASTOR, J. M.; GUEVARA, Juan Fernández de. Impact of the subprime crisis on bank ratings: The effect of the hardening of rating policies and worsening of solvency. **Journal Of Financial Stability**, [s.l.], v. 11, p.13-31, abr. 2014.

SHEN, K.; TZENG, G. A decision rule-based soft computing model for supporting financial performance improvement of the banking industry. **Soft Computing**, [s.l.], v. 19, n. 4, p.859-874, 2 set. 2014,

SHEN, Kao-yi; TZENG, Gwo-hshiung. Combined soft computing model for value stock selection based on fundamental analysis. **Applied Soft Computing**, [s.l.], v. 37, p.142-155, dez. 2015.

SILVA, D. F. L.; SILVA, J. C. S.; SILVA L. G. O.; FERREIRA, L.; ALMEIDA-FILHO, A. T. Sovereign credit risk assessment with multiple criteria using an outranking method. **Mathematical Problems in Engineering**. 2018.

SLOWINSKI, R.; GRECO, S.; MATARAZZO, B.. Rough set and rule-based multicriteria decision aiding. **Pesquisa Operacional**, [s.l.], v. 32, n. 2, p.213-270, ago. 2012.

STANDARD & POOR'S (2014). **Metodologia de Ratings Soberanos**. Disponível em <https://www.standardandpoors.com/pt_LA/delegate/getPDF?articleId=1494261&type=COMMENTS&subType=CRITERIA>. Acesso em 28 de julho de 2018.

STANDARD & POOR'S (2011). **Cr  rios Gerais: Princ  pios dos Ratings de Cr  dito**. Dispon  vel em: <https://www.standardandpoors.com/pt_LA/delegate/getPDF?articleId=1496202&type=COMMENTS&subType=CRITERIA>. Acesso em 01 de julho 2018.

STANDARD & POOR'S (2018). **S&P Global Ratings**. Dispon  vel em <https://www.standardandpoors.com/pt_LA/web/guest/home>. Acesso em 01 de julho de 2018.

ULUCAN, A.; ATICI, K. B. A Multiple Criteria Sorting Methodology With Multiple Classification Criteria And An Application To Country Risk Evaluation. **Technological And Economic Development Of Economy**, [s.l.], v. 19, n. 1, p.93-124, 2 abr. 2013

WORLD BANK (2018). **Indicators**. Dispon  vel em <<http://data.worldbank.org/indicator>>. Acesso em 08 de jun 2018.

ZOPOUNIDIS, C.; GALARIOTIS, E.; DOUMPOS, M.; SARRI, S.; ANDRIOSOPOULOS, K. Multiple criteria decision aiding for finance: An updated bibliographic survey. **European Journal Of Operational Research**, [s.l.], v. 247, n. 2, p.339-348, dez. 2015.

ANEXO A – DEFINIÇÃO DE INDICADORES

Neste anexo, estão contidas as definições, feitas pelo World Bank (2018), referentes aos 18 indicadores escolhidos para as análises estatísticas.

GDP growth (anual %) - taxa de crescimento anual do PIB a preços de mercado com base em moeda local constante.

GDP per capita (current US\$) – produto interno bruto (PIB) dividido pela população na metade do ano. O valor é calculado em dólares americanos correntes.

Current account balance (current US\$) - soma das exportações líquidas de bens e serviços, renda líquida primária e renda líquida secundária. Os dados são em dólares americanos correntes.

Inflation, GDP deflator (anual %) - inflação medida pela taxa de crescimento anual do deflator implícito do PIB. Mostra a taxa de variação de preços na economia como um todo. O deflator implícito do PIB é a razão do PIB em moeda corrente nacional em relação ao PIB em moeda local constante.

Exports of goods and services (% of GDP) - representam o valor de todos os bens e outros serviços de mercado fornecidos ao resto do mundo. Eles incluem o valor de mercadorias, fretes, seguros, transportes, viagens, royalties, taxas de licença, e outros serviços

Gross savings (% of GDP) - calculadas como a renda nacional bruta menos consumo total, mais transferências líquidas.

External debt stocks, total (DOD, current US\$) - é a soma do débito de longo prazo público, com garantia pública, e privado sem garantia, o uso do crédito do FMI, e a débito de curto prazo.

Foreign direct investment, net inflows (BoP, current US\$) - se refere aos fluxos diretos de títulos de investimento na economia. É a soma do capital próprio, do reinvestimento dos lucros, e de outros meios financeiros.

GDP at market prices (current US\$) - soma do valor bruto acrescentado por todos os produtores residentes na economia mais os impostos sobre os produtos e menos quaisquer subsídios não incluídos no valor dos produtos.

Total reserves (includes gold, current US\$) - compreendem explorações de ouro monetário, direitos de saque especiais, as reservas dos membros do FMI realizadas pelo FMI e explorações em cambio estrangeiro sob o controle das autoridades monetárias

GNI per capita, Atlas method (current US\$) - é o rendimento nacional bruto (RNB), convertido para dólares americanos utilizando o método Atlas do Banco Mundial, dividido pela população na metade do ano.

Lending interest rate (%) - é a taxa bancária que normalmente atende as necessidades de financiamento de curto e médio prazo do setor privado. Esta taxa é normalmente obtida de acordo com a qualidade de crédito de devedores e objetivos do financiamento.

Risk premium on lending (lending rate minus treasury bill rate, %) - é a taxa de juros cobrada pelos bancos em empréstimos a clientes do setor privado menos a taxa de título do tesouro "livre de risco" em que os títulos de curto prazos governos são emitidos ou negociados no mercado.

S&P Global Equity Indices (annual % change) - medem a variação de preço do dólar americano nos mercados de ações abrangidas pelos índices S&P/IFCI e S&P/Frontier BMI dos países.

Real interest rate (%) - é a taxa de juros de empréstimos ajustados para a inflação medida pelo deflator do PIB.

Net flows on external debt, long-term (NFL, current US\$) - Os fluxos líquidos (ou créditos líquidos ou desembolsos líquidos) recebidos pelo devedor durante o ano são representados pela subtração entre os desembolsos e reembolsos principais.

Depth of credit information index (0=low to 8=high) - mede as regras que afetam o escopo, a acessibilidade e qualidade das informações de crédito disponíveis através de registros de crédito públicos ou privados.

Money and quasi money growth (annual %) - taxa média anual de crescimento da soma representada pela moeda fora dos bancos, pelos depósitos à vista e a prazo exceto os do governo central, pela poupança e pelos depósitos em moeda estrangeira de setores residenciais, exceto o governo central.