

Joaquim Ignacio Alves de Vasconcellos e Lima

**Um arcabouço computacional para estudo do
setor bancário através de modelos baseados em
agentes**

Brasília

2014

Joaquim Ignacio Alves de Vasconcellos e Lima

**Um arcabouço computacional para estudo do setor
bancário através de modelos baseados em agentes**

Dissertação apresentada ao Programa de Mestrado em Economia da Universidade de Brasília como requisito à obtenção do título de Mestre em Ciências Econômicas

Universidade de Brasília

Faculdade de Economia, Administração e Contabilidade

Departamento de Economia

Orientador: Prof. Daniel Oliveira Cajueiro, PhD

Brasília

2014

Joaquim Ignacio Alves de Vasconcellos e Lima

Um arcabouço computacional para estudo do setor bancário através de modelos baseados em agentes

Dissertação apresentada ao Programa de Mestrado em Economia da Universidade de Brasília como requisito à obtenção do título de Mestre em Ciências Econômicas

Trabalho aprovado. Brasília, 23 de abril de 2014:

Prof. Daniel Oliveira Cajueiro, PhD
Orientador

Prof. José Guilherme de Lara Resende, PhD
Universidade de Brasília

Bernardo Alves Furtado, PhD
Instituto de Pesquisa Econômica Aplicada

Brasília
2014

Resumo

Este trabalho descreve a concepção e a construção de um arcabouço computacional para estudo do setor bancário através de modelos baseados em agentes. A estrutura do arcabouço baseia-se em uma versão iterada do modelo Diamond-Dybvig, com um número arbitrário de agentes de diferentes tipos, como instituições financeiras, firmas, depositantes e bancos centrais. Inspirado pelo paradigma de sistemas complexos adaptativos, o estudo focaliza a auto-organização e as propriedades emergentes decorrentes das interações entre agentes heterogêneos, dotados de racionalidade limitada, implementada usando a abordagem *Experienced-Weighted Attraction*. Por fim, apresentam-se exemplos demonstrando as capacidades do arcabouço, com aplicações envolvendo seguro de depósitos, prestador de última instância, mercado interbancário com câmara de pagamentos, bancos grandes demais para quebrar, risco de crédito e requerimento de capital.

Palavras-chaves: Sistemas complexos adaptativos, modelos baseados em agentes, aprendizagem, economia, setor bancário.

Abstract

This paper design and construct a computational framework for the study of the banking sector through agent-based models. The structure of the framework is based on an iterated version of the Diamond-Dybvig model with an arbitrary number of agents of different types, such as financial institutions, firms, central banks and depositors. Inspired by the paradigm of complex adaptive systems, this study focuses on the self-organization and emergent properties arising from the interactions between heterogeneous agents, who are endowed with bounded rationality, implemented using the *Experienced-Weighted Attraction* approach. Finally, examples are shown, demonstrating the capabilities of the framework, with applications involving deposit insurance, lender of last resort, interbank market with clearing house, banks too big to fail, credit risk and capital requirement.

Keywords: Complex adaptive systems, agent-based models, learning, economy, banking sector

Lista de ilustrações

Figura 1 – Emprestador de última instância	65
Figura 2 – Resultados - LoLR	66
Figura 3 – <i>Too big to fail</i>	68
Figura 4 – Resultados - TBTF	69
Figura 5 – Risco de crédito e requerimento de capital	72
Figura 6 – Resultados - Risco de crédito e requerimento de capital	73
Figura 7 – Seguro de depósitos	75
Figura 8 – Resultados - Seguro de depósitos	76
Figura 9 – Câmara de pagamentos	78
Figura 10 – Resultados - Interbancário	79

Lista de tabelas

Tabela 1 – Classes de passivos	49
Tabela 2 – Classes de ativos	49
Tabela 3 – Configuração padrão dos parâmetros	56

Lista de algoritmos

1	Ciclo básico da economia	57
2	Aprendizagem	59
3	Fluxo principal	60

Lista de abreviaturas e siglas

ABM	<i>Agent-Based Model ou Agent-Based Modelling</i>
ACE	<i>Agent-based Computational Economics</i>
BC	<i>Banco Central</i>
CL	<i>Computational Laboratory</i>
IB	<i>Índice de Basileia</i>
IL	<i>Índice de Liquidez</i>
LGD	<i>Loss Given Default</i>
LoLR	<i>Lender of Last Resort</i>
PD	<i>Probabilidade de Default</i>
PRNG	<i>Pseudorandom Number Generator</i>
RWA	<i>Risk-Weighted Assets</i>
TBTF	<i>Too big to fail</i>
UML	<i>Unified Modelling Language</i>
ZI	<i>Zero Intelligence</i>

Sumário

	Introdução	17
I	Referenciais teóricos	21
1	Sistemas complexos adaptativos	23
2	Modelos baseados em agentes	29
2.1	Introdução e motivação	29
2.2	Metodologia	32
2.3	Problemas potenciais e desvantagens	35
3	Aprendizagem	39
4	Trabalhos relacionados	43
II	Arcabouço	45
5	Estrutura do modelo	47
5.1	Instituições financeiras	48
5.2	Banco Central	50
5.3	Depositantes	51
5.4	Firmas	52
5.5	Sequência básica de eventos	52
6	Implementação	55
6.1	Aspectos da implementação da aprendizagem	57
6.2	Metodologia de simulação	58
III	Estudos de caso	61
7	Exemplos	63
7.1	Liquidez e o prestador de última instância	63
7.1.1	Introdução	63
7.1.2	Simulação	64
7.1.3	Resultados	64
7.2	Bancos Grandes Demais para Quebrar	65
7.2.1	Introdução	65
7.2.2	Simulação	67
7.2.3	Resultados	68

7.3	Risco de crédito e requerimentos de capital	69
7.3.1	Introdução	69
7.3.2	Simulação	70
7.3.3	Resultados	71
7.4	Seguro de depósitos e a disciplina de mercado	72
7.4.1	Introdução	72
7.4.2	Simulação	74
7.4.3	Resultados	74
7.5	Mercado interbancário, garantias e contágio	75
7.5.1	Introdução	75
7.5.2	Simulação	77
7.5.3	Resultados	77
	Conclusão	81
	Referências	85

Introdução

O sistema econômico e seus subsistemas podem ser classificados como sistemas complexos adaptativos (HOLLAND; MILLER, 1991; CHEN, 2005; FOSTER, 2005; FOSTER, 2006). Portanto, para obtermos modelos mais abrangentes e significativos, devemos focalizar em métodos e ferramentas que consideram não somente as características de agentes econômicos, mas também a estrutura de suas interações, considerando complexidade, problemas de coordenação e aprendizado endógeno (COLANDER et al., 2008).

Em sistemas complexos, agentes individuais não dispõem do conhecimento necessário para entender plenamente seu ambiente e computar regras de decisões ótimas. Como agentes aprendem neste ambiente, como adaptam seu comportamento à medida que a economia evolui e como a aprendizagem individual gera comportamento agregado? (FARMER et al., 2012)

Agentes econômicos (firmas, consumidores, bancos, etc.) constantemente mudam suas ações e estratégias em resposta ao resultado que eles conjuntamente criam; essas mudanças, por sua vez, alteram o resultado agregado, o que leva os agentes a readaptarem-se. Ou seja, a economia não está necessariamente em equilíbrio. A partir desta proposição, constrói-se a noção de complexidade em sistemas econômicos (ARTHUR, 2013).

Entretanto, até mesmo em estruturas de mercado relativamente simples, incorporar algumas das características mais realistas das interações entre atores torna rapidamente o modelo analiticamente intratável (KIRMAN, 2010). Dado que este desafio está usualmente além dos limites da análise matemática, a simulação desempenha um papel chave em lidar com este tipo de problema (ISASI et al., 2007). A dificuldade em obter soluções de equilíbrio na presença de não-linearidades pede o uso de métodos numéricos, ao invés de dedução matemática; portanto, a computação é útil no estudo de sistemas econômicos, principalmente considerando que a crescente eficiência e disponibilidade de computadores com alta capacidade de processamento tornam as simulações um método atrativo para a pesquisa de comportamentos de sistemas complexos (HUBERMAN; GLANCE, 1993; ARTHUR, 1999; FOSTER, 2006).

Uma alternativa potencialmente poderosa para simular sistemas complexos, que tem ganhado destaque, é a modelagem baseada em agentes (ABM, *agent-based modelling*). Por incorporar naturalmente aspectos como heterogeneidade, autonomia, interações locais e racionalidade limitada, a modelagem baseada em agentes é regularmente citada como sendo a ferramenta ideal para o estudo de sistemas complexos. (EPSTEIN, 1999; ISASI et al., 2007; GALÁN et al., 2009; BORRILL; TEFATSION, 2011; FARMER et al., 2012)

Modelos baseados em agentes são *softwares*, representações computacionais, que

descrevem economias artificiais, consistindo em uma coleção de entidades discretas autônomas (“agentes”) que interagem entre si dentro de um mundo computacional, em que uma população de objetos é definida com um conjunto de características, regras de comportamento, comunicação e aprendizado próprios juntamente com um ambiente onde as interações se realizam. Esses objetos são programados para comportarem-se de acordo com o interesse próprio — por isso o nome agentes (BROWN, 2006; GAFFEO et al., 2008; BORRILL; TEFATSION, 2011).

Uma desvantagem atual de ABM é a necessidade da habilidade de programação, mesmo não sendo a única — nem a mais importante — competência do campo da ciência da computação necessária para explorar ABMs adequadamente (RAILSBACK; LYTINEN; JACKSON, 2006). Linguagens mais fáceis de serem aprendidas, como Starlogo, não são suficientemente poderosas para muitas aplicações em economia. Linguagens de programação de propósito geral como C++ e Java e ferramentas específicas de elaboração como AgentSheets, Ascape, RePast e Swarm¹ possuem repositórios de código para modelos econômicos baseados em agentes, mas são recursos voltados para programadores experientes (TEFATSION, 2002). Adicionalmente, estas ferramentas específicas de ABM são muito genéricas, por serem feitas para atender ao vasto campo das ciências sociais, e não possuem particularidades que as tornam extremamente atraentes para as ciências econômicas.

Para evitar essas dificuldades, há uma alternativa potencialmente promissora: um laboratório computacional (CL, *computational laboratory*) específico para algum campo das ciências econômicas. O CL é um arcabouço computacional que permite o estudo de sistemas de múltiplos agentes através de experimentos controlados e replicáveis. CLs com uma interface adequada permitem que pesquisadores explorem modelos baseados em agentes sem a necessidade de uso intenso de habilidades em programação. Por exemplo, pesquisadores podem testar a sensibilidade de um sistema a uma ampla variação de parâmetros, sem a necessidade de implementar novos programas. Por outro lado, um CL pode ser desenhado para ser modular e extensível. Assim, futuros usuários podem implementar módulos alternativos para ampliar a sua gama de aplicações (TEFATSION, 2002).

Este trabalho descreve a construção e o uso de um arcabouço computacional adequado para o estudo do setor bancário, para ajudar tanto no entendimento de fenômenos existentes como para auxiliar o desenho e o teste de possibilidades alternativas. A motivação do trabalho é o desejo de obter uma ferramenta capaz de lidar com experimentos consistindo em agentes artificiais que permita o controle de utilidade, aversão a risco, informação, conhecimento, expectativas e aprendizagem de cada indivíduo e, assim, depender o menos possível de pressupostos convenientes, mas irreais (HOLLAND; MILLER, 1991; TEFATSION, 2002; CHEN, 2005). Finalmente, apresenta-se um conjunto de estudos de

¹ Vide Railsback, Lytinen e Jackson (2006) para uma descrição de algumas dessas plataformas

caso simples, que exploram temas comumente presentes na literatura relacionada ao setor bancário, como seguro de depósitos, mercados interbancários, bancos grandes demais para quebrar, o papel do Banco Central (BC), entre outros.

Parte I

Referenciais teóricos

1 Sistemas complexos adaptativos

A visão da economia como um sistema complexo é no mínimo tão velha quanto Adam Smith, quem descreveu — não nestas palavras — a economia e o bem-estar social criado por ela como um processo emergente baseado no comportamento auto-organizado de agentes automotivados agindo independentemente (FARMER et al., 2012).

Agentes econômicos, sejam eles bancos, consumidores, firmas ou investidores, continuamente ajustam seus movimentos, decisões, preços e previsões de acordo com a situação que esses movimentos, decisões, preços e previsões conjuntamente criam. Entretanto, “elementos” econômicos — agentes humanos — reagem estrategicamente, ao considerarem os resultados que podem surgir como consequência do comportamento que adotam. Este fato representa uma camada adicional de complexidade para a ciência econômica que não é observada nas ciências naturais. Teorias econômicas convencionais optam por não estudar os desdobramentos dos padrões que seus agentes criam, decidindo simplificar suas questões com intuito de obter soluções analíticas. Não é suficiente corrigir certas “imperfeições” dos modelos tradicionais: é necessário repensar rigorosamente diversos pressupostos básicos da economia e da teoria das finanças para obter uma abordagem mais satisfatória para lidarmos com muitos dos problemas socioeconômicos atuais (ARTHUR, 1999; HELBING; KIRMAN, 2013).

Apesar de não haver consenso em uma definição universal de sistema complexo, é geralmente aceito que tais sistemas possuem diversas características que contribuem para sua intratabilidade em modelos convencionais de equilíbrio, como interação dispersa, ausência de controlador global, adaptação contínua e dinâmica fora de equilíbrio (*out-of-equilibrium dynamics*) (CHAKRABARTI, 2000). A ciência da complexidade basicamente estuda como os elementos interagindo em um sistema geram padrões globais, e como estes forçam os elementos a adaptarem-se. Ou seja, a complexidade é o estudo das consequências das interações; estuda padrões, estruturas, fenômenos, que emergem das interações entre elementos (partículas, células, dipolos, agentes, firmas, etc.) (ARTHUR, 2013).

A característica que define um sistema como complexo é a incapacidade de prever os seus comportamentos globais, resultados de interação entre um grande número de suas partes, simplesmente a partir das leis que regem essas interações. Dadas as propriedades das partes e as leis de suas interações, não é uma questão trivial inferir as propriedades do todo; ou seja, é possível que nem mesmo o entendimento perfeito das partes e de suas interações possa fornecer informação suficiente para prever fenômenos emergentes, que são os comportamentos em escala global que parecem não ter explicação em termos das partes constituintes do sistema. Mais formalmente, fenômenos emergentes são aqueles

em que a simulação é o meio ótimo para sua previsão, *i.e.*, a quantidade de computação necessária para simular o sistema e obter seus resultados é menor ou igual à quantidade de computação necessária para obter esses resultados a partir de um conjunto ótimo de regras, classificações e análises, até mesmo derivados de um entendimento perfeito idealizado para prevê-los (SIMON, 1962; DARLEY, 1994).

Em todas as variantes da teoria de sistemas complexos, as propriedades macroscópicas não podem ser formal ou analiticamente deduzidas a partir das propriedades de suas partes (MARKOSE, 2005). Em outras palavras, a ferramenta adequada para realizar previsões em tais sistemas é a simulação, que, conseqüentemente, torna-se um método importante para investigação (DARLEY, 1994).

Um sistema complexo adaptativo é um sistema complexo que contém agentes adaptativos. Um agente em um sistema é *adaptativo* se ele satisfaz dois critérios: as ações do agente no seu ambiente resultam em um valor (performance, utilidade, retorno, *etc.*) e o agente age com intuito de melhorar este valor ao longo do tempo (HOLLAND; MILLER, 1991).

Qualquer economia — particularmente economias grandes, compostas por milhões de entidades individuais — pode e deve ser descrita como um sistema complexo adaptativo. Neste tipo de sistema, a complexidade surge por causa das interações dispersas e não lineares entre um grande número de componentes heterogêneos. Embora naturalmente seja possível observar resultados agregados do sistema — por exemplo, quantidades, índices de preços e suas taxas de crescimento —, não seria possível inferir essas medições a partir do exame comportamental de um indivíduo típico isoladamente (ARTHUR; DURLAUF; LANE, 1997; GAFFEO et al., 2008).

Dentre os pressupostos convencionais e postulados da teoria econômica normalmente abandonados quando se estuda a economia através do paradigma de sistemas complexos, destacam-se (KIRMAN, 1992; HELBING; KIRMAN, 2013):

- a) A economia é um sistema em equilíbrio. Em outras palavras, é um sistema em que os mercados estão sistematicamente em equilíbrio em cada ponto do tempo, mas onde o equilíbrio pode ser perturbado de tempos em tempos por choques exógenos.
- b) Indivíduos e firmas decidem racionalmente. Isto é, agentes otimizam sob restrições que enfrentam e suas escolhas satisfazem alguns axiomas de consistência convencionais.
- c) O comportamento de todos os agentes em conjunto pode ser tratado como correspondente ao comportamento da média ou de um indivíduo representativo.
- d) Quando um setor financeiro é analisado, assume-se que os mercados são eficientes, no sentido de que todas as informações relevantes a respeito de um ativo estão

refletidas no seu preço.

É necessário desenvolver um novo pensamento econômico baseado na ciência de sistemas complexos e encontrar novas maneiras de superar ou mitigar os problemas correntes. A ideia principal é que um retrato mais natural do sistema econômico parece ser aquele de um sistema complexo adaptativo com muitos componentes — firmas, bancos, consumidores, reguladores, *etc.* — interagindo entre si de forma não linear. Logicamente, não se trata de abandonar ferramentas e metodologias tradicionais, mas ressaltar e combater o perigo de nos apoiarmos em uma única ferramenta, metodologia ou paradigma (HELBBING; KIRMAN, 2013).

Propriedades típicas de sistemas complexos adaptativo são (HOLLAND; MILLER, 1991; DURLAUF, 1998; BORRILL; TEFATSION, 2011; HELBBING; KIRMAN, 2013):

- a) O sistema é intrinsecamente heterogêneo.
- b) O sistema é inerentemente não linear.
- c) Dinâmica fora de equilíbrio: o sistema pode transitar por longos períodos distante de qualquer ótimo ou equilíbrio global, que pode até mesmo não ser atingido.
- d) O sistema pode apresentar múltiplos equilíbrios.
- e) O equilíbrio pode ser instável.
- f) O sistema não pode ser estritamente otimizado em tempo real, mesmo com vasta capacidade de processamento disponível.
- g) Adaptação contínua: agentes modificam suas ações e crenças à medida que ganham experiência.
- h) Interação dispersa: o resultado do sistema é determinado pela interação de diversos agentes dispersos agindo em paralelo.
- i) Realimentação e efeitos adversos são comuns.
- j) O sistema exibe dinâmica de auto-organização.
- k) O sistema pode ter propriedades emergentes, isto é, que não podem ser entendidas a partir dos componentes, mas das interações entre eles.
- l) O comportamento do sistema pode ser contra-intuitivo.
- m) O comportamento do sistema pode ser probabilístico e difícil de ser previsto (não apenas devido à aleatoriedade).
- n) O sistema pode apresentar efeitos em cascata e eventos extremos. A probabilidade de eventos extremos é mais alta que aquela esperada de acordo com distribuições Gaussianas e seu impacto pode ser de qualquer tamanho, inclusive de escala global.

- o) O comportamento do sistema é difícil de ser controlado de uma maneira centralizada ou de cima para baixo (*top-down*).
- p) Ausência de controlador global: não há autoridade determinando as interações e os comportamentos, que são resultados de mecanismos de competição e coordenação, além de arranjos institucionais.
- q) Partes interessadas regularmente podem falhar em se comportar da maneira que preferem (ou que deveriam se comportar), porque não podem agir de forma independente.
- r) Possibilidade de dependência de caminho (*path dependence*), em que algumas inovações ou choques podem ter consequências permanentes ou serem persistentes, *i.e.*, não são compensados por outros choques.

Padrões econômicos, quando observados na sua formação fora de equilíbrio, algumas vezes convergem para equilíbrios simples e homogêneos observados da teoria econômica convencional. Mas, algumas vezes, eles mostram comportamentos continuamente inovadores e fenômenos emergentes. Complexidade, portanto, retrata a economia não com determinística, previsível e mecanicista, mas como condicionada ao processo, orgânica e sempre em evolução (ARTHUR, 1999).

Contudo, é extremamente difícil modelar aspectos físicos, institucionais e comportamentais de sistemas sociais com fidelidade empírica e ainda manter a tratabilidade analítica. A modelagem analítica consegue, algumas vezes, deduzir os resultados gerais que podem ser observados em um sistema real sendo modelado, mas geralmente isto requer circunstâncias simples ou premissas fortes para que seja possível (GALÁN et al., 2009). Entidades em sistemas sociais não são infinitamente pequenas ou em número infinito e suas identidades e comportamento não são necessariamente indistinguíveis uns dos outros. Simplificações comuns, como comportamentos homogêneos e existência de agentes representativos únicos são, portanto, problemáticas (BORRILL; TEFATSION, 2011). Sempre quando agentes são heterogêneos no que se refere a suas estratégias e conjuntos de informação, a aderência plena à modelagem de comportamento estratégico resulta em problemas computacionalmente complexos, isto é, aqueles cujo tempo de solução — medido como o número de passos computacionais simples necessários para resolvê-lo — aumenta exponencialmente com a dimensão do problema (GAFFEO et al., 2008).

A percepção de que muitos sistemas são computacionalmente irreduzíveis¹ obscurece a ideia clássica de que é sempre possível deduzir soluções (ou “estados futuros”) para sistemas puramente a partir do estudo de suas características estruturais. Mais precisamente, para sistemas que são fortemente interativos e/ou altamente sensíveis a condições iniciais,

¹ Wolfram (2002) define “computacionalmente irreduzível” como a impossibilidade de prever o comportamento de um sistema sem o uso de simulações

comumente não é prático — ou até mesmo possível — antever os resultados globais mesmo quando suas “leis de movimento” são conhecidas. (BORRILL; TEFATSION, 2011)

Sistemas sociais parecem estar sujeitos a esta forma de irreducibilidade computacional. Não apenas na prática, mas também agora na teoria, percebe-se que a única opção para compreender as propriedades globais e o comportamento de muitos sistemas sociais, econômicos principalmente, é construir e executar modelos computacionais destes sistemas e observar o resultado, pois a análise não é capaz de prever suas soluções. A verdade desconfortável é que nosso universo não é o lugar perfeitamente ordenado e determinístico imaginado por Laplace e Hilbert, mas é o mundo rico, indisciplinado e em grande parte não computável de Kurt Gödel, Alonzo Church e Alan Turing (BORRILL; TEFATSION, 2011; MARKS, 2012).

Para uma abordagem *bottom-up*, com um grande número de indivíduos adaptativos heterogêneos interagindo entre si, é natural considerar subdisciplinas da ciência da computação, como inteligência artificial distribuída e sistemas multi-agentes. Por possibilitar uma síntese elegante de características de complexidade, como princípios de auto-organização, heterogeneidade e métodos de computação evolucionária, uma ferramenta promissora para o cultivo e o estudo de economias artificiais evolutivas compostas por inúmeros agentes é a ACE (*Agent-based Computational Economics*, economia computacional baseada em agentes), que basicamente é uma especialização de modelagem baseada em agentes para as ciências econômicas. (TEFATSION, 2002; MARKOSE, 2005).

2 Modelos baseados em agentes

2.1 Introdução e motivação

A modelagem baseada em agentes é um paradigma que modela explicita e individualmente as entidades que populam o sistema-alvo a ser modelado, além das interações entre eles (GALÁN et al., 2009).

Modelos baseados em agentes (ABM, *agent-based models*) são uma alternativa — e potencialmente uma forma mais apropriada — de matemática para as ciências sociais, sendo a ferramenta ideal para simular sistemas complexos destas áreas, dado que heterogeneidade, autonomia, interações locais e racionalidade limitada são as características principais desta abordagem (EPSTEIN, 1999; GALÁN et al., 2009; BORRILL; TEFATSION, 2011; FARMER et al., 2012). Dentro das ciências econômicas, áreas de pesquisa em ABM particularmente ativas incluem economia ambiental, mercados automatizados, administração de negócios, mercados de eletricidade, economia financeira, organização industrial, mercados de trabalho, macroeconomia, economia política e formação de redes econômicas (BORRILL; TEFATSION, 2011).

Modelos baseados em agentes são *softwares*, representações computacionais, que descrevem economias artificiais, basicamente consistindo em uma coleção de entidades discretas autônomas (“agentes”) que interagem entre si dentro de um mundo computacional. Primeiramente, uma população de objetos é definida com um conjunto de características, regras de comportamento, comunicação e aprendizado próprios juntamente com um ambiente onde as interações se realizam. Esses objetos são programados para comportarem-se de acordo com o interesse próprio — daí o nome agentes. O conjunto de instruções que definem as regras comportamentais seguidas por agentes geralmente reflete o conhecimento disponível sobre como agentes econômicos reais comportam-se sob diferentes configurações ambientais (BROWN, 2006; GAFFEO et al., 2008; BORRILL; TEFATSION, 2011).

ABMs pertencem a uma categoria de modelos conhecida como simulações de eventos discretos, que são executados a partir de um conjunto de condições iniciais durante um período de tempo, permitindo que os agentes ajam até que um critério de parada seja satisfeito, normalmente indicado por um tempo máximo de simulação ou algum estado de sistema específico (BROWN, 2006).

Agentes podem representar um amplo espectro de entidades, de materiais físicos passivos governados por métodos dinâmicos relativamente simples, até agentes individuais ou compostos tomadores de decisão e com competências sociais (BORRILL; TEFATSION, 2011). Para modelagem de comportamento humano, simulações baseadas em agentes

mostram um notável grau de flexibilidade. Ao invés de deduzir relações agregadas a partir de problemas de maximizações de indivíduos representativos racionais e da imposição de condições de equilíbrio de mercado, agentes artificiais podem ser instruídos a se comportarem de acordo com evidência resultante de pesquisas empíricas e trabalhos econométricos usando dados reais (GAFFEO et al., 2008).

O que diferencia esta abordagem de outras é que ABM facilita uma correspondência mais direta entre as entidades no sistema-alvo e partes do modelo que as representam, permitindo uma representação explícita do ambiente e da maneira com as entidades interagem nele. O processo de abstração conduzido leva a uma descrição — potencialmente — mais formal e ainda assim mais natural e transparente do sistema-alvo. Esta abordagem mais direta tem o potencial de reforçar a solidez, a exatidão descritiva e o rigor no processo de modelagem. Modelos baseados em agente também permitem estudar sistematicamente comportamentos transientes duradouros e podem capturar comportamento emergente (EPSTEIN, 1999; GALÁN et al., 2009).

A economia computacional baseada em agentes (ACE, *Agent-based computational economics*) é o estudo computacional de economias modeladas como sistemas evolutivos de agentes autônomos que interagem entre si. Ou seja, ACE é uma especialização do paradigma de sistemas complexos adaptativos, abordada através de ABMs, para a economia (TESFATSION, 2003). Modelos em ACE têm o potencial de serem sofisticados, consistentes e fiéis à complexidade de diversos fenômenos melhor do que abordagens tradicionais de modelagem, como econometria, teoria dos jogos e até mesmo abordagens mais antigas de simulação, como dinâmica de sistemas, além de facilitarem a modelagem de construções hierárquicas, isto é, em que agentes são compostos de outros agentes. Ao considerar as interações diretas entre agentes — em vez de somente através de *market-clearing prices*, por exemplo —, esta classe de modelos permite acomodar um conjunto mais amplo de fenômenos, comparada às abordagens convencionais (DURLAUF, 1998; MIDGLEY; MARKS; KUNCHAMWAR, 2007; BORRILL; TEFATSION, 2011).

Os dados e métodos de cada agente são encapsulados, no sentido de que sua forma e conteúdo podem ser invisíveis para os demais agentes. Um agente comunica-se com outros agentes apenas através de sua interface pública, um subconjunto de seus dados e métodos que outros agentes podem ver. Assim, em relação à modelagem tradicional baseada em equações, a encapsulação de agente em ACE permite uma representação mais realista de sistemas compostos por entidades distribuídas com limitações de informação, recursos e capacidades computacionais (BORRILL; TEFATSION, 2011).

Em suma, ABMs são modelos — representações abstratas da realidade — nos quais (i) inúmeros objetos interagem entre si e com o ambiente, (ii) os objetos são autônomos — não há um controle central *top-down* sobre seu comportamento e (iii) o resultado de suas interações é computado numericamente. ABMs são caracterizados pelo fato de que

resultados agregados (o “todo”) são computados como soma das características individuais (suas “partes”). Entretanto, o comportamento agregado pode frequentemente ser reconhecido como distinto daquele de seus agentes constituintes, resultando na descoberta de propriedades inesperadas (“emergentes”) (RICHIARDI, 2012).

Os objetivos visados por pesquisadores de ABM tomam, basicamente, quatro formas (AXELROD; TEFATSION, 2006; BROWN, 2006; BORRILL; TEFATSION, 2011):

- a) Entendimento empírico, buscando entender, por exemplo, como regularidades em larga escala evoluem e persistem mesmo na ausência de controle de cima para baixo (*top-down*). Ou seja, o propósito é explicativo.
- b) Entendimento normativo, visando a explorar como o uso de ABM pode ser aproveitado em laboratórios para a descoberta de arranjos satisfatórios, envolvendo extrapolação de tendências e avaliação de cenários. Pesquisa normativa com uso de ABM aborda geralmente duas questões quanto a mudanças no sistema. Primeiro, as consequências pretendidas realmente surgem? Segundo, sob quais condições uma mudança aplicada a um sistema poderia apresentar efeitos colaterais?
- c) Heurística, quando o objetivo é a busca por conhecimentos mais profundos dos mecanismos causais fundamentais em sistemas sociais.
- d) Avanço metodológico, em que o objetivo é prover pesquisadores com métodos e ferramentas necessários para o estudo rigoroso de sistemas sociais através de experimentos computacionais controlados. Este é o principal objetivo deste trabalho.

Há, basicamente, três categorias de uso de ABM, de acordo com a existência ou não de soluções para o modelo base do problema (EPSTEIN, 1999; AXTELL, 2000):

- a) Primeiro caso: quando os modelos podem ser formulados e completamente resolvidos, simbolicamente ou numericamente. Nesta situação, o uso de ABM visa a validar uma solução numérica, inclusive através de simulações de Monte Carlo¹. Também é possível usar ABM para testar a robustez de teorias convencionais. Especificamente, é possível relaxar premissas sobre comportamento individual no nível micro e observar se resultados convencionais no comportamento macro comportam-se bem ou colapsam.
- b) Segundo caso: modelos parcialmente resolvíveis, ou seja, quando não é possível resolver completamente um modelo matemático analiticamente. Neste caso, o ABM é usado como *complementar* a análise matemática.

¹ Ampla classe de algoritmos computacionais que dependem de repetidas amostras aleatórias para obtenção de resultados numéricos; por exemplo, simular um modelo diversas vezes para obter a distribuição de uma entidade probabilística desconhecida

- c) Terceiro caso: modelos aparentemente intratáveis ou comprovadamente sem solução. Quando um modelo de um processo é completamente intratável (aparente ou comprovadamente), há pouca esperança de progresso apenas com manipulações simbólicas. Neste caso, o ABM é *substituto* para a análise.

2.2 Metodologia

Ao realizar um experimento com uso de ABM, um pesquisador tipicamente implementa os seguintes passos (BORRILL; TESFATSION, 2011):

- a) Passo 1: desenvolver um desenho experimental para a exploração sistemática de um problema teórico de interesse.
- b) Passo 2: construir um mundo computacional consistindo em uma coleção de agentes apropriados para o problema.
- c) Passo 3: configurar o mundo computacional de acordo com a concepção experimental.
- d) Passo 4: compilar e executar o mundo computacional sem qualquer outra interferência externa e registrar os resultados de interesse.
- e) Passo 5: repetir o “mesmo” experimento computacional múltiplas vezes com diferentes valores iniciais para o PRNG (*Pseudorandom Number Generator*, gerador de números pseudoaleatórios), para gerar um conjunto de resultados a partir do qual distribuições amostrais podem ser derivadas.
- f) Passo 6: repetir os passos 3 a 5 até que toda a gama de configurações especificadas na concepção experimental tenha sido explorada.
- g) Passo 7: analisar a distribuição das amostras dos resultados de interesse observados e analisar suas implicações teóricas.
- h) Passo 8: usar os sumários teóricos para formar hipóteses/conjecturas que podem ser testadas e validadas em comparação a dados históricos ou em tempo real.

O desenvolvimento e a construção de ABMs (passos 1 e 2 acima) podem ser resumidamente descritos nas seguintes etapas (BROWN, 2006):

- a) Modelagem conceitual, em que o modelador identifica questões básicas, objetivos, elementos e agentes do sistema, comportamentos relevantes dos atores e os resultados mensuráveis de interesse. Na prática, um estudo começa com modelos simples, para avaliar e entender as dinâmicas do sistema.
- b) Desenho do programa de computador, com o objetivo de obter uma representação suficientemente rigorosa do modelo conceitual que seja computacionalmente

- eficiente. Na abordagem por ABM, o desenho dos programas normalmente usa o paradigma de orientação a objetos ².
- c) Desenvolvimento do programa, usando as linguagens de programação orientada a objetos, com ou sem o uso de ferramentas específicas para ABM.
 - d) Verificação, para testar se os agentes programados comportam-se conforme esperado, normalmente usando hipóteses e condições iniciais cujo resultado já é conhecido, dado o modelo conceitual.
 - e) Calibração, quando a estrutura e o valor dos parâmetros são ajustados de maneira a refletirem situações do mundo real, com a maior exatidão e precisão possíveis. Tipicamente, este passo requer dados no nível micro dos processos que o modelo está programado para representar. Esta etapa está fora do escopo do presente projeto, por não ser um processo muito comum em ABM.
 - f) Validação, com o intuito de confirmar que o modelo se comporta de maneira substancialmente similar ao sistema alvo, usualmente comparando resultados em nível macro do modelo com o mundo real. Como não há calibração, este estágio também não é tratado nesta dissertação.

Implementado o modelo, sua execução se resume a instanciar uma população de agentes, deixando-os interagirem entre si e monitorar os resultados. Ou seja, executar o modelo — simular a passagem de tempo — é o necessário para “resolvê-lo”. Evidentemente, se o modelo é estocástico, são necessárias múltiplas execuções para caracterizar adequadamente o resultado (AXTELL, 2000). Muitos modelos são baseados em funções estocásticas, em que o resultado do modelo é dependente de entrada estocástica, mesmo quando a relação funcional entre entrada e saída seja determinística. Nestes casos, amostragem estocástica pode ser aplicada através de múltiplas simulações baseadas em agente, usando valores aleatórios de entrada e determinando valor de saída, em uma simulação de Monte Carlo (HOOG; DEISSEBERG; TEGLIO, 2007).

Pesquisadores em ACE geralmente se apoiam em laboratórios computacionais, ferramentas que permitem o estudo de sistemas de múltiplos agentes, para estudar a evolução de economias descentralizadas sob condições experimentais controladas. Usualmente, um modelador em ACE começa por construir uma economia com uma população inicial de agentes, que inclui tanto agentes econômicos como agentes que representam outros fenômenos sociais e ambientais. Um modelador caracteriza um estado inicial da economia ao especificar os atributos iniciais dos agentes. Esses atributos podem incluir normas comportamentais, inclusive modos de comunicação e aprendizado e informações armazenadas sobre si mesmo e também sobre outros agentes. A economia então evolui

² Paradigma de programação que representa conceitos como “objetos” (instâncias de “classes”), que possuem atributos que o descrevem e procedimentos associados, chamados de métodos. C++ e Java são exemplos de linguagens de programação orientada a objetos (WIKIPEDIA, 2014b).

ao longo do tempo sem mais intervenções do modelador. Todos os eventos que ocorrem subsequencialmente são devidos às interações entre os agentes (TESFATSION, 2003).

O uso de simulações — método para usar programas de computador para modelar a operação de processo, sistemas ou eventos do mundo real — é uma terceira maneira de investigar cientificamente, complementando a dedução e a indução. Cientistas usam a dedução para obter teoremas a partir de um conjunto de pressupostos e a indução para encontrar padrões em dados empíricos. A simulação, assim como a dedução, começa com um conjunto explícito de premissas, mas diferentemente, a simulação, em geral, não prova teoremas com generalidade, mas gera dados adequados para análise por indução. Todavia, diversamente de indução, os dados obtidos através de simulação são gerados a partir de um conjunto de premissas rigorosamente definidas relacionadas a um sistema de interesse, ao invés de serem medições diretas do mundo real. Consequentemente, a simulação difere da dedução e indução convencionais tanto na sua implementação quanto nos seus objetivos. A simulação permite aprofundar conhecimentos de sistemas por meio de experimentos computacionais controlados (AXELROD; TEFATSION, 2006; DAVIS; EISENHARDT; BINGHAM, 2007; HOOG; DEISSEBERG; TEGLIO, 2007).

A vantagem de simulações, comparadas com o uso de outros métodos de pesquisa, é principalmente o fato de que o criador da simulação pode controlar qualquer parâmetro para adaptar o problema para circunstâncias específicas. Experimentações empíricas são restringidas por limitações de dados e exercícios de modelagem formal são restringidos pela tratabilidade matemática. Em contraste, métodos de simulação permitem experimentação através de uma ampla faixa de condições, “simplesmente” alterando o código do programa (DAVIS; EISENHARDT; BINGHAM, 2007). Isto permite estudos normativos e descritivos, auxiliando a explicação, predição e exploração de fenômenos e os elementos e interações que os produzem. Um sistema de simulação bem desenhado pode ajudar no entendimento e explicação de sistemas reais e a descrever certos fenômenos observados ao comparar diferentes simulações sob condições experimentais variantes (por exemplo, hipóteses alternativas e diferentes valores de parâmetros) (HOOG; DEISSEBERG; TEGLIO, 2007; MARKS, 2007).

A simulação pode ser um método poderoso para especificar e estender teorias existentes de maneiras úteis. Ela é particularmente útil quando o foco teórico envolve fenômenos não lineares, como pontos de ruptura (*tipping points*), retroalimentação (*feedback*), catástrofes e assimetrias. (DAVIS; EISENHARDT; BINGHAM, 2007).

Particularmente, o uso de modelos computacionais de fenômenos econômicos é atraente por dois motivos: primeiro, para escapar das restrições de modelos necessárias para obter soluções em forma fechada e para explorar o espaço de possibilidades (MARKS, 2007). Com isso, é possível realizar estudos, por exemplo, sem a necessidade de impor condições de equilíbrio, dado que equilíbrio — ou múltiplos equilíbrios — é um resultado possível

ao invés de um requerimento imposto (COLANDER et al., 2008). A interdependência entre diversos atores pode criar múltiplos tipos de comportamentos agregados consistentes, inclusive possibilitando que o ambiente econômico convirja para um estado estacionário indesejado. (DURLAUF, 1998).

Resumindo, a ABM aplicada para processos sociais, dentre eles processos econômicos, usa conceitos e ferramentas de ciências sociais e da ciência da computação. Crucial para o desenvolvimento de ABM, tem sido, naturalmente, a disponibilidade crescente de poder computacional. Avanços recentes em computação e o advento de ABM em larga escala permitem um programa de pesquisa generativa em escopo e vigor sem precedentes (EPSTEIN, 1999; RICHIARDI, 2012). ABM representa uma abordagem metodológica que poderia permitir dois avanços importantes: o teste rigoroso, o refinamento e a extensão de teorias já existentes comprovadamente difíceis de serem formuladas e avaliadas usando ferramentas estatísticas e matemáticas convencionais; e uma compreensão mais profunda de fatores causais fundamentais em sistemas multi-agentes (AXELROD; TEFATSION, 2006). Com esta ferramenta, a tratabilidade analítica não é mais um motivo válido para simplificações (BORRILL; TEFATSION, 2011).

2.3 Problemas potenciais e desvantagens

Laboratórios computacionais podem ser construídos programando agentes para seguir comportamentos no contexto de instituições econômicas específicas, com intuito de obter afirmações condicionais sobre a ligação entre fenômenos individuais e agregados. Esta abordagem é claramente diferente daquela adotada pela economia convencional, que descreve o comportamento humano axiomaticamente e subsequentemente deduz os resultados (GAFFEO et al., 2008).

Entretanto, levar em conta a interação entre um grande número de agentes, potencialmente heterogêneos, torna a maioria dos modelos construídos desta maneira matematicamente intratáveis. Logo, para exploração e análise, não há outra escolha além de simulações computacionais, que podem ser muito complexas, tal que o seu entendimento com razoável nível de detalhe não seja um exercício simples. (GALÁN et al., 2009; RICHIARDI, 2012).

Frequentemente não é possível entender os detalhes das implementações de simulações baseadas em agente. A replicação é às vezes difícil, impossível em alguns casos, o que viola um dos princípios básicos da prática científica e confina o conhecimento gerado por simulações baseadas em agente para não mais que evidência anedótica (RICHIARDI et al., 2006).

O número de parâmetros e escolhas implícitas ou explícitas das regras comportamentais é tão grande (na ordem de dúzias até mesmo para os modelos mais simples) que os resultados das simulações parecem arbitrários e não confiáveis, fazendo com que a

calibração dos parâmetros seja uma tarefa muito difícil e altamente instável. (FARMER et al., 2012; GUALDI et al., 2013).

Em geral, a falta de interesse de economistas por ABM é, em parte, devido ao fato de que, em geral, simulação pode demonstrar suficiência, não necessidade (MARKS, 2007). Executar um modelo baseado em agentes em um computador resulta em uma prova formal que uma especificação particular é suficiente para gerar o comportamento global observado durante a simulação (GALÁN et al., 2009). Uma desvantagem significativa de ABM, quando comparada à modelagem matemática tradicional, é que, apesar de uma única execução de um modelo resultar em um teorema de suficiência, ela não provê informação sobre sua robustez. Em outras palavras, dado que um modelo A produz o resultado R , quanta mudança seria necessária em A para que R não mais seja obtido? A economia matemática resolve tais questões formalmente, usando diferenciações simples, teoremas de função implícita, estática comparativa, etc. A única maneira de lidar com esse problema na computação por agentes é através de múltiplas execuções, variando sistematicamente as condições iniciais e parâmetros de maneira a avaliar a robustez dos resultados. Na prática, a maldição da dimensionalidade³ impõe um limite no tamanho do espaço de parâmetros usado nos testes de robustez, mas o sempre crescente poder computacional disponível torna o problema severamente limitante em um administrável (AXTELL, 2000).

Uma vantagem de simulações baseadas em agentes sobre abordagens mais tradicionais reside na flexibilidade permitida na especificação do modelo. Claro que mais liberdade implica também maior heterogeneidade. Enquanto modelos analíticos em geral são construídos com base no trabalho de seus predecessores, simulações em ABM regularmente distanciam-se da literatura existente, dificultando a avaliação dos resultados (RICHIARDI et al., 2006). Para evitar esse problema, recomenda-se manter proximidade com modelos convencionais para aplicar o modelo em situações relativamente bem entendidas e previsíveis para verificar se o resultado obtido está de acordo com o comportamento esperado (GALÁN et al., 2009). O campo de pesquisa necessita de padrões para comparação de modelos e replicação de resultados, pois diferenças sutis podem ter consequências profundas (EPSTEIN, 1999). Por este motivo, os modelos usados na Parte III aproximam-se o máximo possível daqueles comumente adotados pela literatura.

A natureza complexa e exploratória da maioria dos modelos baseados em agentes implica que, antes do modelo ser executado, exista alguma incerteza sobre os resultados produzidos. O desconhecimento *a priori* do que é esperado dificulta saber se o produto de um experimento é gerado como um resultado legítimo das premissas incorporados no modelo ou, ao contrário, é devido a um erro ou artefato criado no seu desenho, implementação e/ou execução, impedindo pesquisadores de entenderem corretamente suas simulações

³ *curse of dimensionality*, referente a vários fenômenos que surgem ao analisar e organizar dados em espaços com muitas dimensões

(GALÁN et al., 2009).

Arfetos relacionam-se com situações em que há discrepância entre o conjunto de premissas do modelo que o pesquisador pensa que está produzindo certo fenômeno, e as premissas que são a real causa de tal fenômeno, ou seja, são fenômenos significativos causados por suposições acessórias no modelo que foram erroneamente dadas como irrelevantes para os resultados. Por exemplo, escolhas indevidas de geradores de números aleatórios e sincronia artificial de tomada de decisões podem ter um efeito significativo no resultado do modelo (GALÁN et al., 2009). Já erros aparecem quando um modelo não cumpre as especificações requeridas impostas por seu desenvolvedor. Em palavras simples, um erro é a discrepância entre o que o desenvolvedor pensa que o modelo é e o que o modelo realmente é (GALÁN et al., 2009).

Qualquer que seja a natureza de seus objetivos, pesquisadores que usam ABM devem abordar difíceis questões de verificação e validação empírica (BORRILL; TEFATSION, 2011). A verificação envolve consistência com objetivos: um modelo baseado em agentes realmente se comporta de maneira pretendida pelos seus criadores e implementadores ou há algum erro lógico ou conceitual de programação? Ou seja, consiste em verificar que o *software* implementa corretamente o modelo conceitual pretendido — ou seja, livre de erros —, assegurando que a representação computacional incorpora a lógica teórica com precisão, que a teoria seja internamente válida e que os resultados da simulação possam ser interpretados com confiança (MIDGLEY; MARKS; KUNCHAMWAR, 2007; BORRILL; TEFATSION, 2011).

Há várias técnicas de verificação, sendo mais comuns os métodos dinâmicos, tal como rastrear variáveis em passos intermediários e simulações com valores extremos de parâmetros. Discrepâncias encontradas nestes ensaios normalmente são devidas a erros de programação que são então corrigidos. Estes testes por vezes não tem implicações teóricas mas são um meio de assegurar que a representação computacional representa a lógica teórica subjacente com precisão e exatidão (DAVIS; EISENHARDT; BINGHAM, 2007). Pesquisas indicam que revisões externas reduzem erros significativamente. Isto inclui análises estáticas de código fonte (manuais, baseadas em ferramentas ou automatizadas) (MIDGLEY; MARKS; KUNCHAMWAR, 2007).

Já a validação diz respeito à consistência com a realidade: um modelo baseado em agentes captura apropriadamente as características salientes do sistema real de interesse e ele provê resultados aderentes a observações empíricas? A validação é o processo destinado a avaliar quão útil é um modelo para um propósito particular e envolve a comparação de resultados da simulação com dados empíricos. Um modelo é válido na medida que fornece uma gama satisfatória de precisão e exatidão consistente com o seu propósito (DAVIS; EISENHARDT; BINGHAM, 2007; GALÁN et al., 2009; BORRILL; TEFATSION, 2011).

A garantia de confiabilidade — verificação e validação — de ABM é difícil de

ser obtida, devido à heterogeneidade dos agentes e à possibilidade da emergência de novos padrões de comportamentos macro como resultado das interações de agentes no nível micro. Por este motivo, pesquisadores de ABM valorizam simplicidade mais do que sofisticação teórica na especificação do modelo e incorporar metodologias de garantia de qualidade desde o início do seu desenvolvimento (MIDGLEY; MARKS; KUNCHAMWAR, 2007, 2007).

Pesquisadores que usam simulação devem, adicionalmente, verificar suas representações computacionais com testes de robustez — também chamado análise de sensibilidade —, para assegurar que a representação computacional seja estável. A sensibilidade envolve o efeito no resultado (macroestrutura resultante) em pequenas mudanças na entrada (micro-especificação), normalmente testando o efeito de elementos aleatórios no modelo através de variações deliberadas, repetindo simulações com diferentes sequências de números randômicos gerados por computador para cada execução (EPSTEIN, 1999; RICHIARDI et al., 2006; DAVIS; EISENHARDT; BINGHAM, 2007).

Conclui-se que é necessário prover um conjunto de atividades para ajudar a eliminar erros e artefatos em simulações. Convém ressaltar que muitas das considerações não são específicas para ABM, mas para o processo geral de modelagem científica (GALÁN et al., 2009).

3 Aprendizagem

Um sistema complexo socioeconômico é um sistema com realimentação de expectativas entre o aprendizado individual e o comportamento agregado emergente. A realimentação de expectativas e o comportamento adaptativo através de aprendizagem são ingredientes chave que distinguem sistemas complexos socioeconômicos nas ciências naturais. Na economia, as “partículas pensam”: elas aprendem com a experiência e adaptam seu comportamento. De fato, os incentivos e a habilidade de humanos para adaptar seus comportamentos e suas decisões (e suas regras de tomada de decisões) distinguem sistemas sociais de sistemas físicos (PAGE, 1997; FARMER et al., 2012).

Agentes racionais, assim como o gás ideal e o fluido perfeito, são modelos idealizados, que desempenham importantes papéis pedagógicos e práticos. Servem para desenvolver a intuição das relações entre as variáveis-chave de uma classe de problemas e também para calcular soluções aproximadas. Apesar disso, é crescente o número de abordagens que visam, cada uma a sua maneira, a flexibilizar a dependência da racionalidade dos agentes econômicos, pois a racionalidade limitada deve ser a regra, não a exceção. Entre estas abordagens, destaca-se a ABM, pois, intrinsecamente, toda aplicação desta metodologia envolve de alguma forma a racionalidade limitada (*bounded rationality*). De forma geral, a insatisfação com a hipótese de agentes racionais é uma motivação comum para o uso dessa classe de modelos (AXTELL, 2000; GAFFEO et al., 2008).

Muitos dos algoritmos usados para representar o processo de aprendizagem de agentes computacionais foram desenvolvidos visando a otimalidade. Portanto devem ser usados com cuidado quando aplicados no contexto de processos com participantes humanos. Para modelos computacionais de processos econômicos do mundo real com participantes humanos, os algoritmos de aprendizagem geralmente devem incorporar as características salientes do real comportamento de tomada de decisão humano, caso seja necessário algum poder preditivo (TESFATSION, 2002).

Uma maneira de incorporar racionalidade limitada é representar os agentes como organismos adaptativos, isto é, que aprendem e fazem escolhas de acordo com suas experiências passadas (CAMERER; HO, 1999; POUGET, 2007). Em grandes sistemas interativos, processos de decisões individuais tornam-se inevitavelmente adaptativos, isto é, ajustados de acordo com resultados observados através de um método seletivo de tentativa e erro que não seja completamente aleatório (SIMON, 1962; SIMON, 1987). Em modelos grandes, maneiras dedutivas de raciocínio não são aplicáveis ou bem definidas. Agentes devem dispor de alguma forma de raciocínio indutivo, construindo modelos mentais internos de representação, aprender a partir dos resultados de escolhas prévias e extrapolar do caso

particular para o caso geral (GAFFEO et al., 2008).

A adaptação é um processo *backward-looking*, sequencial e dependente de caminho (*path-dependent*). Escolhas de preços, quantidade, estoques, composições de portfólios desejados são atualizadas de acordo com procedimentos de “correção de erro”. Expectativas em relação a eventos e resultados futuros são claramente uma parte importante dos processos de tomada de decisão, mas previsões são feitas por horizontes finitos e modificadas sequencialmente à luz dos resultados obtidos (GAFFEO et al., 2008).

O modelo de aprendizado adaptativo considerado neste trabalho é o de Barroso (2011), que aplica o método de *Experience-Weighted Attraction* (EWA) de Camerer e Ho (1999) para o setor bancário.

O EWA compreende tipos de aprendizagem baseados em reforço e crença, ou seja, captura a *lei do efeito atual* e a *lei do efeito simulado*. A lei do efeito atual afirma que a probabilidade da escolha de alguma ação é ajustada somente se esta ação já foi selecionada previamente: se a ação selecionada gerou um resultado positivo (negativo) para o agente, a probabilidade que a ação seja escolhida novamente aumenta (diminui). Já a lei do efeito simulado afirma que a probabilidade de ações que não foram escolhidas previamente é ajustada de acordo com o resultado que seria obtido caso tivessem sido selecionadas, *ceteris paribus* (CAMERER; HO, 1999; POUGET, 2007).

A lógica do processo de aprendizagem por EWA é que agentes fazem suas escolhas de acordo com as atrações das ações. Para um dado agente, estas atrações representam a propensão de escolher entre as ações disponíveis. Atrações dependem da experiência dos agentes no jogo e nos ganhos passados, isto é, ganhos ou perdas resultantes ou potencialmente resultantes das diversas ações possíveis (CAMERER; HO, 1999; POUGET, 2007).

Neste modelo de aprendizagem, os agentes são indexados por i ($i = 1, \dots, n$). Um agente i dispõe de um conjunto de m_i estratégias possíveis descrito por $S_i = \{s_i^1, s_i^2, \dots, s_i^{m_i}\}$. O produto cartesiano do espaço de estratégias individuais, $S = S_1 \times \dots \times S_n$, corresponde ao espaço de estratégias do jogo. $s_i \in S_i$ denota uma estratégia do agente i . $s = (s_1, \dots, s_n) \in S$ é uma combinação de n estratégias, uma para cada agente. $s_{-i} = (s_1, \dots, s_{i-1}, s_{i+1}, \dots, s_n)$ é uma combinação de estratégias de todos os agentes, exceto a do agente i . No período t , a estratégia escolhida pelo agente i é representada por $s_i(t)$, enquanto $s_{-i}(t)$ denota a combinação de estratégias escolhidas pelos demais jogadores. A função de recompensa (*payoff*) do jogador i é representada por $\pi_i(s_i(t), s_{-i}(t))$.

O EWA assume que cada estratégia tem uma atração, que é um número monotonicamente relacionado à probabilidade de escolha da estratégia. $A_i^j(t)$ representa a atração da estratégia s_i^j para o agente i , após a execução do tempo t .

A experiência $N_i(t)$, interpretada como número equivalente de observações passadas,

é regida pela equação:

$$N_i(t) = \rho_i N_i(t-1) + 1 \quad (3.1)$$

O parâmetro de decaimento ρ de um agente i captura o decaimento da força de crenças prévias; é um fator de desconto retrospectivo e mede o impacto de experiência prévia, comparada à de um novo período.

Um componente chave para a atualização dos níveis de atração é a recompensa obtida por uma estratégia em um período (ou a recompensa que teria sido obtida, caso a estratégia tivesse sido escolhida, *ceteris paribus*). O modelo pesa recompensas hipotéticas que estratégias não escolhidas teriam retornado através do parâmetro δ , e pondera recompensas realmente recebidas da estratégia escolhida $s_i(t)$, por um peso adicional de $1 - \delta$, resultando um peso total de 1. Ou seja, o parâmetro δ mede a importância relativa dada a recompensas potencialmente realizáveis comparado ao resultado efetivamente obtido.

Usando uma função indicador $I(x, y)$, tal que $I(x, y) = 1$ se $x = y$ e 0 caso contrário, a recompensa ponderada por ser escrita como $[\delta + (1 - \delta) \cdot I(s_i^j, s_i(t))] \cdot \pi_i(s_i^j, s_{-i}(t))$

Assim, a regra para atualização dos conjuntos de atrações $A_i^j(t)$ é a soma da atração anterior $A_i^j(t-1)$ depreciada, ponderada pela experiência, com a recompensa ponderada do período t , normalizada pelo peso da experiência:

$$A_i^j(t) = \frac{\phi \cdot N_i(t-1) \cdot A_i^j(t-1) + [\delta + (1 - \delta) \cdot I(s_i^j, s_i(t))] \cdot \pi_i(s_i^j, s_{-i}(t))}{N(t)} \quad (3.2)$$

Na equação acima, o fator de desconto ϕ é a taxa de decaimento que deprecia atrações passadas. Nota-se que há dois termos referentes a decaimento, ϕ e ρ . Esta distinção é necessária, pois estes termos são tratados de forma diferente pelos modelos de aprendizagem por reforço e por crenças, que são casos especiais do EWA.

As atrações devem determinar a probabilidade de escolha das estratégias, $P_i^j(t)$, que deve ser monotonicamente crescente em $A_i^j(t)$ e decrescente em $A_i^k(t)$, para $k \neq j$. As atrações são transformadas em probabilidades de escolha segundo o modelo logit, por ser adequado para estudos que envolvam risco e incerteza, da seguinte forma:

$$P_i^j(t+1) = \frac{e^{\lambda \cdot A_i^j(t)}}{\sum_{k=1}^{m_i} e^{\lambda \cdot A_i^k(t)}} \quad (3.3)$$

O parâmetro λ acima mede a sensibilidade de agentes às atrações, podendo representar, por exemplo, a percepção e a motivação de agentes.

4 Trabalhos relacionados

[Georg \(2013\)](#) estuda o efeito da estrutura da rede interbancária no contágio e choques comuns usando um modelo dinâmico multi-agentes. Neste modelo, os bancos otimizam um portfólio composto de investimentos arriscados e reservas livres de risco de acordo com suas preferências por risco, retorno e liquidez.

O trabalho de [Chakrabarti \(2000\)](#) desenvolve um modelo baseado em agentes para o mercado interbancário de moedas estrangeiras em que os agentes aprendem de maneira bayesiana. Através de simulações, o autor consegue replicar resultados observados empiricamente no mercado intradiário de moedas estrangeiras.

O modelo baseado em agentes feito por [Montagna e Kok \(2013\)](#) explora redes interbancárias em múltiplas camadas, considerando que os bancos relacionam entre si em diferentes segmentos de mercado, constatando não-linearidades significativas na propagação de choques. Resumidamente, os efeitos de contágio resultantes de propagação de choques simultaneamente em todas as camadas da rede interbancária é maior do que a soma das perdas resultantes de contágio quando cada camada é considerada individualmente.

[Kirman \(2010\)](#) explora os processos através dos quais agentes aprendem a agir em ambientes econômicos. Há outros trabalhos que também usam EWA em modelos baseados em agentes, como [Hoog, Deissenberg e Teglio \(2007\)](#) e [Pouget \(2007\)](#).

Já [Souza \(2012\)](#) desenvolve um modelo baseado em agentes de uma economia fechada, utilizado para analisar o seu comportamento e para investigar os mecanismos associados a crises. Neste modelo, a economia é formada por firmas interligadas em redes heterogêneas e por bancos, interligados no mercado interbancário, que atuam como agentes de pagamento das firmas e como provedores de crédito.

Finalmente, os trabalhos de [Barroso \(2011\)](#) e [Barroso \(2014\)](#) — no qual este presente estudo se baseia — apresentam um modelo baseado em agentes para o setor bancário com formação endógena do mercado interbancário, também usando EWA para aprendizagem, para investigar a estabilidade financeira sob diferentes cenários.

Entretanto, este presente trabalho distingue-se dos citados por visar a descrever e construir um arcabouço computacional para simular diversos cenários para o setor bancário, incluindo a possibilidade de aprendizagem por outros tipos de agentes, como depositantes e bancos centrais. Variados estudos de casos são apresentados, com intuito de explorar o potencial que modelos baseados em agentes apresentam.

Parte II

Arcabouço

5 Estrutura do modelo

Um problema não resolvido particularmente importante para a área de ACE é a necessidade de se assegurar que os resultados de experimentos reflitam aspectos fundamentais da aplicação considerada e não simplesmente peculiaridades das ferramentas e computadores utilizados (TESFATSION, 2002; RICHIARDI et al., 2006). Por este motivo, apesar da flexibilidade possível com ABM, este trabalho evita distanciar-se dos modelos comumente adotados pela literatura, para não dificultar a avaliação dos resultados e manter, na medida do possível, consistência com pesquisas prévias.

A análise é construída usando uma versão iterada do modelo de Diamond e Dybvig (1983), assim como Temzelides (1997) e, principalmente, Barroso (2011) e Barroso (2014). O modelo do sistema bancário trabalha em ciclos de simulação, em que cada ciclo c é subdividido em três períodos¹ $t = 0, 1, 2$, que podem ser interpretados como hoje, curto prazo e longo prazo. Esta sequência dos períodos t dentro de um ciclo de simulação segue os exemplos da vasta literatura iniciada por Diamond e Dybvig (1983), como Allen e Gale (1998), Allen e Gale (2000), entre outros.

A versão iterada adotada por Barroso (2011) pode ser resumida na seguinte forma: no período 0, bancos ajustam, de acordo com a estratégia selecionada, a quantidade de empréstimos para o setor real, ativos líquidos e o capital próprio. No período 1, bancos sofrem um choque de liquidez representado pela proporção de depositantes impacientes que sacam seus recursos antecipadamente. Instituições financeiras com escassez de liquidez tomam emprestado de outros bancos no mercado interbancário ou do Banco Central (BC). Finalmente, no último período $t = 2$, os investimentos no setor real vencem, os depositantes remanescentes consomem e os bancos computam seu lucro medido como o retorno sobre capital próprio, que será usado para ajustar a probabilidade de escolhas futuras através do mecanismo de aprendizagem.

Nota-se que na literatura destacada, a ênfase é dada para instituições financeiras. Este trabalho busca descrever e construir um arcabouço computacional capaz de simular diversas situações, com variados tipos de agentes, como depositantes e Banco Central, inclusive permitindo que aprendam.

O desafio principal reside em especificar como os agentes se comportam e, em particular, escolher as regras que eles usam para tomar decisões. Em muitos casos isto ainda é feito usando o senso comum e por tentativa e erro, que algumas vezes é suficiente para imitar comportamento real. Uma tentativa de modelar todos os detalhes de problemas

¹ O período t citado no Capítulo 3 refere-se ao ciclo neste contexto. Os ciclos podem também ser entendidos como períodos e os tempos $t = 0, 1, 2$ podem ser interpretados como subperíodos.

realistas pode rapidamente levar a simulações complicadas em que é difícil determinar o que causa o quê. Para tornar ABM útil, deve-se prosseguir sistematicamente, evitando hipóteses arbitrárias, fundamentando e testando cada parte do modelo contra a realidade e introduzir complexidades adicionais somente quando necessário. Feito de maneira correta, o ABM pode prover um entendimento de propriedades emergentes de partes interagindo em circunstâncias complexas onde a intuição e métodos convencionais falham (FARMER; FOLEY, 2009).

Assim, apesar de permitir inúmeras possibilidades de configuração, é importante ter em mente que nem todas as capacidades do arcabouço computacional são habilitadas simultaneamente para o mesmo estudo de caso. Por exemplo, é possível estudar o setor bancário através do arcabouço considerando depositantes e/ou Banco Central passivos e ausência de mercado interbancário, entre outras simplificações. Ou seja, um dos objetivos deste projeto é prover uma ferramenta genérica e configurável, que permita estudar diversos aspectos do setor bancário, mas sem abrir mão da capacidade de isolar comportamentos e mecanismos específicos.

Os agentes considerados no modelo são bancos, depositantes, firmas e o Banco Central, descritos com detalhes a seguir. De maneira geral, várias simplificações foram feitas para que o trabalho fosse factível. Por exemplo, as taxas de juros são exógenas, não há requerimentos de colateral, bancos não podem levantar capital próprio adicional, *etc.* Incontestavelmente, há aproximações perniciosas, mas convém enfatizar que um dos objetivos deste trabalho é ser uma base para futuras adequações.

5.1 Instituições financeiras

Em cada simulação, há um total de B bancos, caracterizados por seus balanços. Um banco b é financiado por capital próprio, k_b , depósitos d_b , empréstimos interbancários ib_b — na condição de tomador — e empréstimos do Banco Central c_b . Os ativos de um banco b são os empréstimos para o setor real r_b , ativos líquidos l_b , e empréstimos interbancários il_b — na condição de prestador.

O capital próprio k_b de um banco b é atualizado pelo seu lucro ou prejuízo no decorrer do ciclo de simulação. Há um total de D_b depositantes por banco b . Os depósitos dos correntistas do banco, cujo valor agregado é representado por d_b , é remunerado por uma taxa $d\%$. Caso um banco obtenha empréstimos de outros bancos, o seu valor agregado é dado por ib_b e sua remuneração é dada por $i\%$. Finalmente, c_b representa o valor dos empréstimos tomados do Banco Central, são remunerados a uma taxa $bc_l\%$.

Os ativos líquidos l_b correspondem à reserva bancária, disponíveis para conversão em dinheiro para uso imediato e não são remunerados. Os empréstimos interbancários il_b , valor agregado dos empréstimos feitos para outros bancos, são remunerados por $i\%$. O valor

agregado dos empréstimos para o setor real r_b corresponde ao somatório de empréstimos feitos para um total de F_b firmas e o seu retorno total depende da possibilidade de inadimplência, taxa de juros e do valor de cada um desses empréstimos.

A taxas de juros relativas a depósitos $d\%$, empréstimos do Banco Central $bc_l\%$ e empréstimos interbancários $i\%$ são todas exogenamente determinadas e idênticas para todos os bancos.

Tabela 1 – Classes de passivos.

Símbolo	Nome	Taxa
k_b	Capital próprio	-
d_b	Depósitos	$d\%$
c_b	Empréstimos tomados do Banco Central	$bc_l\%$
ib_b	Empréstimos interbancários	$i\%$

Tabela 2 – Classes de ativos

Símbolo	Nome	Taxa
l_b	Ativos líquidos	-
il_b	Empréstimos interbancários	$i\%$
r_b	Empréstimos para o setor real	$r_b\%$

A estratégia s_b^j de um banco b é representada pela dupla (α^j, β^j) , onde α^j representa a proporção de ativos líquidos em relação ao total de ativos e β^j representa a proporção de capital próprio em relação ao total de passivos. O tamanho de um banco b é determinado exogenamente e representado por T_b e corresponde ao total de ativos — ou, equivalentemente, total de passivos incluindo o capital próprio. Assim, no início de cada ciclo de simulação ($t = 0$), um banco b que escolha uma estratégia $s_b^j = (\alpha^j, \beta^j)$ possuirá inicialmente um montante de ativos líquidos $l_b = \alpha^j \cdot T_b$ e capital próprio $k_b = \beta^j \cdot T_b$. Como em $t = 0$ não há interação entre bancos, que só ocorre após choques em $t = 1$, não há então empréstimos interbancários. Assim, os valores agregados iniciais dos depósitos d_b e dos empréstimos para o setor real r_b serão determinados, respectivamente, por $T_b - k_b$ e $T_b - l_b$. Os valores agregados de depósitos e empréstimos são divididos igualmente entre os respectivos clientes do bancos. Assume-se que os bancos são capazes de aumentar sua captação de depósitos, sem custo².

Ou seja, a estratégia escolhida por um banco b no período inicial $t = 0$ determina todo o seu balanço. Ao final de um ciclo de simulação, composto pelos períodos $t = 0, 1, 2$,

² Uma alternativa potencial seria considerar que em cada ciclo surge uma massa de depositantes com um valor fixo de recursos; entretanto, isto implicaria que o tamanho inicial de cada banco — e a economia, por consequência — variaria de acordo com suas estratégias, potencialmente distorcendo resultados. Este problema pode ser resolvido com uso de um modelo que considere emissão de capital novo ou retenções de lucros ao longo da simulação, o que está fora do escopo deste projeto.

um banco b obterá um lucro Π_b , determinado pela diferença entre k_b^2 e k_b^0 , onde k_b^2 e k_b^0 são o capital próprio k_b nos períodos $t = 2$ e $t = 0$, respectivamente. Sua lucratividade π_b é dada por $\frac{\Pi_b}{k_b^0}$. A lucratividade π_b resultante é usada pra alimentar o esquema de aprendizagem do banco b . No próximo ciclo de simulação, o banco b retorna ao seu tamanho inicial, preservando a experiência adquirida.

O Índice de Basileia IB_b de um banco b é determinado pela razão entre capital próprio k_b e a soma dos ativos ponderados pelo risco (RWA, *Risk-Weighted Assets*), sendo que ativos líquidos possuem peso zero e empréstimos para o setor real e para outros bancos são ponderados em 100%. Ou seja, $IB_b = \frac{k_b}{r_b + il_b}$.

Já o Índice de Liquidez IL_b de um banco b é a proporção que ativos líquidos em relação ao total de ativos, ou seja, $IL_b = \frac{l_b}{l_b + il_b + r_b}$.

Como o arcabouço não abrange a emissão de capital próprio, um banco ajusta seu Índice de Basileia, se necessário, vendendo parte de sua carteira de empréstimos ou sendo impedido de distribuir lucros. No caso de vendas de parte de sua carteira de empréstimos por um banco, aplica-se um desconto $\delta_L\%$ no valor dos ativos vendidos, para refletir a sua baixa liquidez intrínseca.

Finalmente, quando um banco é liquidado, seus ativos mais arriscados sofrem um desconto $\delta_I\%$, para refletir a deterioração da qualidade do ativo, por dificuldades econômicas e financeiras, além dos custos administrativos e legais decorrentes do processo de liquidação.

5.2 Banco Central

Neste arcabouço, bancos centrais agem como prestamistas de última instância e supervisores bancários — seu papel na política monetária é ignorado. Nas simulações nas quais o BC atua como emprestador emergencial, ele socorre bancos com falta de liquidez, isto é, bancos com montante de ativos líquidos inferior ao total de pedidos de retirada de depósitos incapazes de suprir a diferença usando outras fontes, como através de empréstimos interbancários. Não há limite para a quantidade de empréstimos feitos pelo Banco Central. Já quando assume o papel de supervisor bancário, um BC atua sobre bancos que não estejam adequadamente capitalizados. Especificamente, a estratégia s_{bc}^j adotada por um BC é representada por um Índice de Basileia mínimo IB_{min}^j , que todos as instituições financeiras devem respeitar, sob risco de serem liquidadas ou serem impedidas de distribuírem parte de lucros para acionistas. Matematicamente, caso um banco b tenha um índice de Basileia IB_b insuficiente, ou seja, $IB_b < IB_{min}^j$, ele é obrigado pelo BC a enquadrar-se ao mínimo imposto; caso não consiga, ele é liquidado.

Os pontos centrais da aprendizagem de um BC são a estabilidade do sistema

financeiro e o montante de empréstimos para o setor real. Evidentemente, se a preferência fosse simplesmente minimizar a ocorrência de falências bancárias, bastaria um Índice de Basileia mínimo IB_{min} excessivamente alto, o que poderia limitar a oferta de crédito. Em simulações nas quais o BC assume o papel de supervisor, ele age estrategicamente e aprende usando preferências lexicográficas. Seja $B_{insolvent}^{c1}$ e $B_{insolvent}^{c2}$ o número de instituições financeiras insolventes e R^{c1} e R^{c2} o montante agregado, de todos os bancos, de empréstimos para o setor real resultantes de dois ciclos de simulação, $c1$ e $c2$. Se $B_{insolvent}^{c1} < B_{insolvent}^{c2}$, então o resultado de sua escolha em $c1$ será preferível. Se $B_{insolvent}^{c1} = B_{insolvent}^{c2}$, então sua preferência será determinada por R^{c1} e R^{c2} : entre duas escolhas envolvendo o mesmo número de bancos insolventes, será preferível aquela que resultar em mais empréstimos para o setor real. O *payoff* de um BC nas simulações, caso não haja insolvências, é dado por r_B , o montante agregado de empréstimos para o setor real; a penalidade por insolvência é $-T_B$, tamanho total em ativos, garantido que a função de utilidade se comporte como descrito. Evidentemente, é uma aproximação muito rudimentar, mas descreve parcialmente as preferências do BC sem necessidade de acrescentar mais características no modelo.

5.3 Depositantes

O arcabouço permite dois tipos de depositantes: aqueles que agem estrategicamente e os que decidem sacar depósitos aleatoriamente. Os depositantes incapazes de aprender são utilizados em simulações nas quais busca-se usar somente agentes passivos, que se distinguem entre pacientes e impacientes aleatoriamente. Os depositantes inteligentes são utilizados em simulações onde é necessário dotá-los de uma capacidade de perceber que estão sob o risco de perderem seus depósitos, de acordo com a estratégia adotada pelos bancos dos quais são clientes.

Para um depositante d com inteligência, o único parâmetro de sua estratégia s_d é a tolerância de risco γ_d , que define o limite do Índice de Basileia do seu banco b abaixo do qual o depositante decide sacar depósitos. Em outras palavras, se um depositante d possui depósitos em um banco b cuja estratégia escolhida resulte em um Índice de Basileia IB_b tal que $IB_b < \gamma_d$, o depositante d opta por retirar seus recursos, preferindo consumir antes a correr o risco de perder seus depósitos. Caso o depositante opte por manter seus recursos depositados e seu banco não venha a falir durante o ciclo de simulação, ele consumirá mais no período final $t = 2$, devido aos rendimentos da poupança.

Todos os depositantes são avessos ao risco, com a função de utilidade de um depositante d dada por $\ln(\frac{c_{d1} + c_{d2}}{T_d})$, onde c_{d1} e c_{d2} são o consumo no período 1 e 2, respectivamente, e T_d representa o montante inicial em depósitos. Assim, haverá uma penalidade caso o consumo final seja inferior ao potencial inicial. Ou seja, não há agente inerentemente impaciente; todos preferem, *a priori*, consumir mais no segundo período

— considerando o rendimento do depósito —, mas, caso o banco adote uma estratégia suficientemente arriscada, agentes preferirão consumir somente no primeiro período. Ou seja, trata-se de um jogo sequencial.

Em simulações nas quais depositantes são aleatoriamente distinguidos entre pacientes e impacientes, um depositante d tem a probabilidade $imp_d\%$ de ser impaciente e optar por consumir anteriormente ao invés de aguardar mais um período, mesmo que potencialmente possa consumir mais.

5.4 Firmas

As firmas são representadas individualmente para possibilitar a simulação com características mais realistas, como tamanho variável de empréstimos, diferentes classificações de risco, firmas relacionando-se com mais de um banco, e agrupamento por setores. Evidentemente, tais características estão presentes somente em simulações onde de fato são relevantes, para evitar complexidades desnecessárias.

Neste arcabouço, firmas não agem estrategicamente nem aprendem. Uma firma f é caracterizada pelo conjunto de bancos dos quais tomou empréstimos e seus valores. A chance de uma firma f não honrar seus compromissos é dada por $PD_f\%$. A perda dada o *default* (LGD, *Loss Given Default*) de uma firma f é descrito por LGD_f . No período inicial $t = 0$, o valor total de empréstimos para o setor real de um banco é integralmente distribuído entre um número de firmas e, conseqüentemente, o retorno total obtido com estes empréstimos depende de seus desempenhos individuais. Como este modelo supõe demanda por crédito inelástica, um banco, ao escolher uma estratégia que resulte em menos empréstimos para o setor real, ele está, de fato, deixando de atender à demanda por crédito. Uma vez que, neste modelo, a probabilidade de *default* de uma firma não depende do valor empréstimo, as variações de oferta podem ser distribuídas entre as firmas.

5.5 Sequência básica de eventos

Cada ciclo de simulação é composto de três períodos, enumerados abaixo com a sequência de ações correspondentes:

Período 0: Hoje

- a) Agentes escolhem estratégias a serem efetivamente seguidas, de acordo com o mecanismo de aprendizagem descrito no [Capítulo 3](#).
- b) Toda a economia é configurada de acordo com as estratégias escolhidas, ou seja, determinam-se as quantidades de capital próprio, depósitos, ativos líquidos

e empréstimos para o setor real, de acordo com as estratégias eleitas pelos agentes.

Período 1: Curto prazo

- a) Choque de liquidez: correntistas impacientes (ou cientes do risco que seus bancos tomaram) realizam saques, que são, inicialmente, atendidos pelos ativos líquidos disponíveis.
- b) Abertura do mercado interbancário: bancos com excesso ou falta de ativos líquidos realizam empréstimos entre si, diretamente ou através de uma contraparte central.
- c) Assistência de liquidez do Banco Central: caso o excesso de ativos líquidos não seja suficiente para atender o valor total de saques dos correntistas, mesmo considerando a atuação no interbancário, bancos podem recorrer a empréstimos do BC, caso disponível.
- d) Atuação do Banco Central como supervisor: bancos cujo Índice de Basileia não atenda ao mínimo exigido pela autoridade bancária são obrigados a adequarem-se.

Período 2: Longo prazo

- a) Atualização do balanços bancários: bancos atualizam o valor dos depósitos e empréstimos de acordo com as taxas de juros correspondentes, levando em consideração a possibilidade de inadimplência PD das firmas e a perda dada o *default* LGD.
- b) Falências bancárias: bancos podem tornar-se insolventes e serem liquidados pelo Banco Central.
- c) Contágio: em caso de inadimplência de banco devedor no mercado interbancário, a perda é propagada, com a possibilidade de levar outros bancos a se tornarem insolventes.
- d) Aprendizagem: todos agentes atualizam seus ganhos e perdas realizados, além de simularem potenciais resultados caso tivessem escolhido outras estratégias.

Encerrado o ciclo de simulação descrito acima, o próximo é iniciado. Todos os agentes voltam às suas condições iniciais, preservando o que aprenderam. Esta sequência de eventos é usada como base para todos os exemplos. Por questões de clareza, as configurações adicionais usadas por cada estudo de caso são explicadas separadamente.

6 Implementação

Linguagens de programação orientadas a objeto são particularmente adaptadas para o arcabouço multi-agentes. Objetos são estruturas de programas que encapsulam tanto dados quanto métodos para operar nestes dados em *templates* chamadas “classes”. Isto é, para cada objeto ou classe, é necessário especificar as propriedades do objeto, a estrutura de dados que ele pode armazenar e os métodos que oferece (PHAN, 2003). Cada agente possui estados (variáveis de instância) e regras de comportamento (procedimentos e funções, chamados de métodos no contexto de orientação a objetos) e são mais convenientemente representados no *software* como objetos (AXTELL, 2000).

Agentes são naturalmente representados por uma única classe. Tal arquitetura é intuitiva e útil para propósitos semânticos. Desta maneira, a arquitetura do software é mais próxima da organização conceitual do problema do que uma maneira procedural específica destinada a resolvê-lo. Além disso, a programação orientada a objetos provê um ambiente conceitual adequado para enxergar um problema em diferente nível de abstração. Finalmente, a representação em diagramas UML (*Unified Modelling Language*)¹ torna fácil o diálogo entre cientistas da computação e economistas e pode ajudar a aprimorar a semântica do modelo (PHAN, 2003).

Um ABM não tem uma solução intrínseca e seus resultados são dependentes dos métodos computacionais usados para implementar o modelo. A única maneira de reproduzir exatamente uma simulação em ABM é reproduzindo, rigorosamente, sua implementação em software (ROPELLA; RAILSBACK; JACKSON, 2002). Já que modelos baseados em agentes são programas de computador, é um requerimento que sua licença de distribuição seja de software livre²(RICHIARDI et al., 2006). Atualmente, há vários arcabouços computacionais para a construção de modelos baseados em agentes³. Algumas destas ferramentas não se enquadram na categoria de *software* livre, limitando seu aproveitamento. Outras são específicas para alguns campos de conhecimento, como ecologia, transporte urbano e fenômenos políticos. Finalmente, aquelas de propósito geral são normalmente dotadas de funcionalidades que não são valiosas para este trabalho, além de requerem personalizações para que atendam alguns requisitos deste projeto. Portanto, justifica-se a produção de um arcabouço de propósito específico para estudo do setor bancário.

Como representam sistemas complexos e abandonam conceitos como equilíbrio e convergência, ABMs normalmente apresentam resultados inesperados e dinâmicos,

¹ Na definição oficial (OMG2003), UML (Unified Modelling Language) é a linguagem para visualizar, construir e documentar artefatos de sistemas de software (RICHIARDI et al., 2006).

² O programa e os códigos-fonte deste trabalho estão disponíveis sob demanda; vide Conclusão para informações de contato.

³ Vide (WIKIPEDIA, 2014a) para uma lista de ferramentas e arcabouços disponíveis.

fazendo com que artefatos e erros de *software* sejam difíceis de serem distinguidos de resultados válidos (ROPELLA; RAILSBACK; JACKSON, 2002). A dependência próxima dos resultados de um ABM com sua implementação em *software* é, sem dúvida, uma das principais razões pelas quais vários pesquisadores ainda desconfiam desta técnica. O uso apropriado de métodos de engenharia de *software* são uma parte crítica para o avanço da técnica de ABM como uma ferramenta essencial para economistas (ROPELLA; RAILSBACK; JACKSON, 2002). Portanto, são essenciais a condução de revisões críticas, uso de gerenciamento de versão, uso de bibliotecas já difundidas, ferramentas para validação e verificação e cuidados com o uso de gerador de números pseudoaleatórios (ROPELLA; RAILSBACK; JACKSON, 2002). Este trabalho segue, na medida do possível, as principais diretrizes gerais de engenharia de *software*.

Uma outra importante preocupação teórica e prática para pesquisadores que usam ABM é como especificar a temporização relativa das interações entre os agentes e os métodos através dos quais eles atualizam seus estados internos baseada nessas interações. Tratamentos descuidados de problemas ligados à temporização podem induzir artefatos indesejados nos resultados da simulação, esconder importantes comportamentos do sistema e até mesmo resultar na incapacidade de gerar qualquer resultado empiricamente relevante (BORRILL; TEFATSION, 2011). Por este motivo, a ordem de ativação dos agentes é sistematicamente randomizada a cada período, para evitar a produção deste tipo de artefato — fenômeno espúrio resultante de peculiaridades na codificação (AXTELL, 2000).

O Algoritmo 1 descreve, simplificada, o núcleo da simulação, um ciclo da economia; e a Tabela 3 mostra os valores escolhidos para os parâmetros descritos anteriormente.

Tabela 3 – Configuração padrão dos parâmetros

Símbolo	Nome	Valor
B	Número de bancos	10
T	Tamanho de cada banco (em ativos)	1
D	Número de depositantes por banco	100
$imp_d\%$	Probabilidade de um depositante ZI sacar antecipadamente	20%
F	Número de firmas por banco	100
$PD\%$	Probabilidade de <i>Default</i> por uma firma	5%
LGD_f	Perda dada o <i>default</i> de uma firma	100%
$d\%$	Taxa de remuneração de depósitos	0.5%
$i\%$	Taxa de juros do mercado interbancário	1%
$bc_i\%$	Taxa de desconto do Banco Central	2.5%
$\delta_L\%$	Desconto na venda antecipada de carteira de empréstimos	25%
$\delta_I\%$	Desconto aplicado nos ativos em caso de insolvência	40%

Algoritmo 1 Ciclo básico da economia

```

procedure ECONOMY.RUN()
    ▷ Period t=0
    for all agent ∈ economy.agents do
        agent.selectNewStrategy()
        agent.setup()
    end for

    ▷ Period t=1
    for all depositor ∈ economy.depositors do
        depositor.withdrawDeposits()
    end for

    for all bank ∈ economy.banks do
        bank.useLiquidAssetsToPayDepositors()
    end for

    clearingHouse.organizeInterbankMarket()
    centralBank.organizeDiscountWindowLoans()

    ▷ Period t=2
    for all bank ∈ economy.banks do
        bank.updateBalanceSheet()
        if bank.isInsolvent then
            centralBank.liquidate(bank)
        end if
    end for

    clearingHouse.propagateBankDefaults()

    for all agent ∈ economy.agents do
        agent.learn()
    end for

end procedure

```

6.1 Aspectos da implementação da aprendizagem

Em cada ciclo de simulação, os agentes são ordenados aleatoriamente, para evitar o aparecimento de artefatos decorrentes de mantermos sempre a mesma sequência de ativação e, assim, minimizar a ocorrência de problemas relacionados a problemas de sincronização e simultaneidade de aprendizagem (PAGE, 1997). Como o arcabouço segue a base do modelo conforme Diamond e Dybvig (1983), não é possível atualizar as regras de tomada de decisão dos agentes de forma verdadeira assíncrona, pois cada ciclo de simulação compreende basicamente três períodos. Entretanto, é factível ampliar o teste de robustez de aprendizagem fazendo com que apenas um subconjunto aleatório de agentes aprenda em cada ciclo.

Na maioria dos modelos em ACE, os agentes aprendem e adaptam-se a seu ambiente econômico. Entretanto, em algumas situações, é desejável testar algum mecanismo de mercado removendo a complexidade estratégica do modelo com o uso de agentes com inteligência zero (*Zero Intelligence (ZI) agents*), termo adotado em alguns trabalhos em ACE para descrever agentes com total incapacidade para adaptação e aprendizagem (LADLEY, 2012).

O conceito de ZI é simples: agentes ZI não têm estratégia e se comportam aleatoriamente. Eles são úteis para observar o efeito isolado de certos mecanismos de mercado (LADLEY, 2012). Por exemplo, é conveniente, por questões de simplicidade, usar depositantes ZI em uma simulação usando o arcabouço computacional descrito neste trabalho para o estudo de interações entre instituições financeiras e o Banco Central em que depositantes não desempenham nenhum papel relevante; ou então manter o Banco Central inerte quando o objeto de estudo for relação entre depositantes e bancos.

Os valores dos parâmetros do modelo de aprendizagem EWA efetivamente utilizados neste trabalho são: a taxa de decaimento de experiência prévia $\rho = 0$, decaimento de atração $\phi = 1$ e experiência inicial $N(0) = 1$, ou seja, não há decaimento pela quantidade de experiência dos agentes; o peso de estratégias emuladas $\delta = 1$, ou seja, os agentes valorizam tanto a experiência obtida por reforço (efetivamente escolhida) quanto pela crença (estratégias simuladas); as atrações iniciais $A_i^j(0)$ são iguais a 0 para todos os agentes, implicando que, no início de cada repetição, todas as estratégias são igualmente prováveis de serem escolhidas. O parâmetro de sensibilidade às atrações $\lambda = 1$ mantém o mesmo peso para todas as atrações no cálculo de probabilidade de escolhas das estratégias.

Assim, a Equação 3.2, que atualiza as atrações para cada agente, resume-se a:

$$A_i^j(t) = A_i^j(t-1) + \pi_i(s_i^j, s_{-i}(t)) \quad (6.1)$$

Os parâmetros de aprendizagem são aproximações das estimações obtidas por Camerer e Ho (1999) e também foram usadas por Pouget (2007) e Barroso (2011).

O algoritmo 2 descreve o modelo de aprendizagem EWA.

Após a execução do algoritmo descrito, a probabilidade de escolha de todas as estratégias de cada agente está atualizada para uso no próximo ciclo $c + 1$ de simulação.

6.2 Metodologia de simulação

Para um estudo de caso, executa-se um número suficientemente alto de repetições independentes — que podem ser executadas em paralelo —, para minimizar a dependência de condições iniciais aleatórias e para análise de possíveis convergências de aprendizagem. Em cada uma dessas repetições, há um número suficientemente alto de ciclos sucessivos

Algoritmo 2 Aprendizagem

... ▷ Encerrado um ciclo c de simulação, isto é, passaram-se os períodos $t = 0, 1, 2$ do ciclo c

```

for all agent  $i \in \text{economy.agents}$  do
  for all strategy  $s \in \text{agent.S}$  do
    if  $s = \text{agent.chosenStrategyForThisCycle}$  then
      continue ▷ O payoff para a estratégia escolhida já é conhecido
    else
       $s.A(c) = s.A(c-1) + \pi_i(s, s_{-i}(c))$  ▷ Simulação
    end if
  end for
end for

```

▷ Todas as atrações foram atualizadas. Resta atualizar as probabilidades de escolha das estratégias correspondentes

```

for all agent  $i \in \text{economy.agents}$  do
   $\text{sumAttractions} = \sum_{k=1}^{m_i} \exp A_i^k(c)$ 
  for all strategy  $s \in \text{agent.S}$  do
     $s.P = \frac{\exp s.A(c)}{\text{sumAttractions}}$ 
  end for
end for

```

de aprendizagem, em que os agentes acumulam experiência, que é perdida ao fim de uma repetição.

No início de uma repetição, as probabilidades de escolha associadas a cada uma das estratégias possíveis para um agente são idênticas, sendo atualizadas à medida que um agente aprende. A intenção é que, após um certo número de ciclos de aprendizagem, as probabilidades de escolha dos agentes converjam para ações consideradas mais adequadas por eles, conforme o processo de aprendizado de cada um. Em todos os ciclos, é feita a leitura de diversas variáveis de saída de interesse, tanto agregadas quanto individuais. Antes de serem apresentados em gráficos, os dados agregados são tratados com o uso de LOWESS (também conhecido como LOESS), que combina a simplicidade de regressões lineares por mínimos quadrados com a flexibilidade de regressões não-lineares para extrair a parte determinística das variações dos dados. É um método adequado neste caso, devido à grande quantidade de dados gerados que este método requer para seu correto funcionamento (CLEVELAND, 1981).

O fluxo principal descrito no algoritmo 3 é executado por um número suficientemente alto de repetições e ciclos. Em cada ciclo da simulação, diversos dados, granulares e agregados, são coletados e registrados para que sirvam tanto para depurar a execução da simulação, quanto para ser analisados e tratados para apresentação. A seguir, são

apresentados um conjunto de estudos de caso, explorando as capacidades do arcabouço em investigar diversos cenários específicos para o setor bancário.

Algoritmo 3 Fluxo principal

```
procedure MAIN(maxRepetitions, maxCycles)
  randomize()                                ▷ PRNG seed
  buildEconomy()

  for  $i \leftarrow 1, \text{maxRepetitions}$  do

    for  $c \leftarrow 1, \text{maxCycles}$  do
      economy.run()                            ▷ Períodos  $t = 0, 1, 2$  ocorrem aqui

      for all agent  $\in$  economy.agents do
        agent.learn()
      end for

    end for

    for all agent  $\in$  economy.agents do
      agent.reset()                            ▷ Após uma repetição, os agentes esquecem
    end for

  end for

end procedure
```

Parte III

Estudios de caso

7 Exemplos

7.1 Liquidez e o prestador de última instância

7.1.1 Introdução

Desde sua criação, bancos centrais assumiram como uma de suas responsabilidades principais a provisão de liquidez a instituições financeiras incapazes de encontrá-la em outro lugar. Intervenções do prestador de última instância podem ajudar a conter instabilidades financeiras durante crises e, portanto, são um componente chave do armamento de um Banco Central (OBSTFELD, 2009). A atividade de um prestador de última instância pode reduzir o risco de falências ao permitir que bancos obtenham liquidez através de desconto de ativos no Banco Central, ao invés de incorrer em perdas devido à venda desesperada de ativos com o objetivo de satisfazer necessidades de liquidez (BERGER; HERRING; SZEGÖ, 1995).

A política *Lender of Last Resort* (LoLR, prestador de última instância) tem uma longa história. A visão clássica de Bagehot (1878) assegurava que a política de LoLR deveria satisfazer três condições: (i) empréstimos deveriam ser somente para instituições solventes e contra colateral de qualidade, (ii) empréstimos feitos a taxas punitivas, para que bancos não os usem para financiar operações correntes, (iii) o Banco Central deve esclarecer previamente sua predisposição para emprestar sem limites para bancos que cumpram condições de solvência e colateral (FREIXAS; PARIGI; ROCHET, 2003).

Há várias dificuldades associadas com esta atividade de bancos centrais. Em primeiro lugar, se realmente a política de LoLR serve para emprestar contra colateral de qualidade, não está claro porque políticas de mercado aberto não seriam suficientes para garantir a eficiência, exceto no caso em que mercados monetários não operam corretamente — na hipótese de falhas de coordenação, por exemplo (FREIXAS; PARIGI; ROCHET, 2003).

Outra dificuldade é a distinção entre solvência e liquidez, que não é perfeitamente clara. Na prática, nem sempre é fácil diferenciar choques de liquidez de choques de solvência. A opacidade do balanço dos bancos impossibilita que o mercado — e também os supervisores bancários, logicamente — diferencie perfeitamente entre bancos insolventes, ilíquidos e aqueles operando normalmente (FREIXAS; PARIGI; ROCHET, 2003).

Finalmente, outro empecilho da política LoLR é o risco moral. A existência de um prestador de última instância crível reduz o custo privado de assunção de riscos. Então, dificilmente há dúvidas de que mais risco será assumido (SOLOW, 1982; FREIXAS; PARIGI; ROCHET, 2003).

Dada sua importância e seus efeitos, é um exercício interessante modelar a interação estratégica entre bancos e o LoLR e observar o efeito de sua existência e como os bancos reagem à taxas normais e punitivas.

7.1.2 Simulação

Para simular os efeitos da existência de prestador de última instância, usa-se uma adaptação do modelo proposto por [Repullo \(2005\)](#), em que o autor estudou a interação estratégica entre um banco, cujos depósitos sofrem choques aleatórios, e o prestador de última instância. No modelo original, o banco define o montante de ativos líquidos e seguros que mantém e o risco de seus empréstimos. O autor compara os resultados obtidos no equilíbrio para três situações: ausência de prestador de última instância, existência de prestador de última instância com e sem taxas punitivas.

Ao sofrer um choque de liquidez, advindo de retiradas aleatórias de depósitos, um banco usa seus ativos líquidos para pagar os depositantes que sacam seus recursos antecipadamente. Caso o montante disponível não seja suficiente, o banco poderá obter um empréstimo emergencial do BC, se possível, ou então vender parte de sua carteira de empréstimos, com uma taxa de desconto para refletir sua falta de liquidez.

Este estudo de caso considera que a exigência de colaterais é ignorada e também assume que o BC tenha informação perfeita sobre os balanços bancários. Ou seja, o foco deste exercício é avaliar o risco de liquidez e o risco moral decorrente da existência de um LoLR. O objetivo desta simulação é observar os efeitos da existência de um LoLR — inclusive os indesejados — e testar a configuração adicional de taxas punitivas. O primeiro cenário, em que não há LoLR, é simulado com os parâmetros *default* descritos anteriormente. Em seguida, simula-se um cenário em que há LoLR, cujas taxa de juros de seus empréstimos é a mesma dos depósitos. Finalmente, o terceiro e último cenário, que considera o LoLR cobrando taxas punitivas, cinco vezes maior que as do caso anterior. A [Figura 1](#) mostra o diagrama desta configuração.

7.1.3 Resultados

A [Figura 2](#) exhibe os resultados obtidos com a simulação. Nota-se que, na presença de um LoLR, os bancos reduzem sua liquidez e aumentam a quantidade de empréstimos para o setor real. Quando o Banco Central cobra uma taxa punitiva, os efeitos negativos — bancos assumindo estratégias mais arriscadas — são suavizados, sem comprometer a quantidade de empréstimos para as firmas. Tanto com taxas comuns e punitivas, o Banco Central é bem sucedido na missão de aumentar a estabilidade do sistema financeiro, reduzindo a média de instituições insolventes devido a choques de liquidez.

Figura 1 – Emprestador de última instância




Diagrama da simulação de LoLR, com conexões de Banco Central, bancos e grupos de depositantes

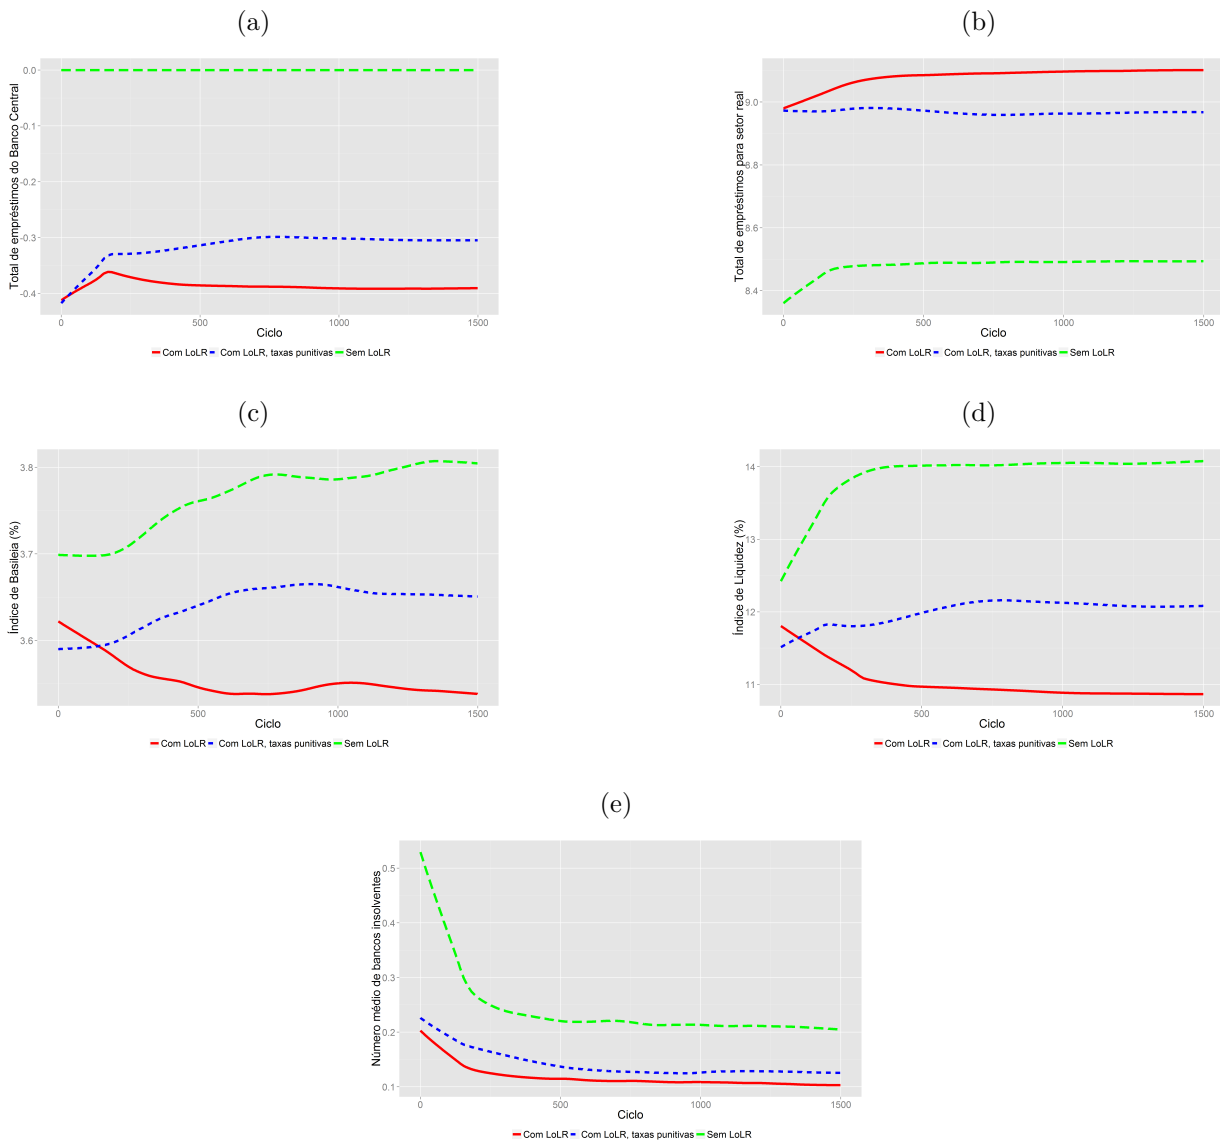
7.2 Bancos Grandes Demais para Quebrar

7.2.1 Introdução

A teoria do “Grande Demais Para Quebrar” (TBTF, *too big to fail*) afirma que certas instituições financeiras são tão grandes e interconectadas que, caso quebrassem, o resultado seria desastroso para a economia. Assim, deveriam existir políticas governamentais que ofereçam suporte caso estas instituições enfrentem alguma dificuldade. Esta possibilidade de *bailout* governamental é referida como política TBTF (ENNIS; MALEK, 2005; LIN, 2012).

Entretanto, a mera percepção da existência de políticas “Grandes Demais para Quebrar” é suficiente para distorcer alocações de portfólio em direção a empréstimos e investimentos mais arriscados. Esta percepção também cria uma vantagem competitiva para instituições que se enquadram como grandes demais para quebrar. Parece haver uma percepção entre participantes de mercados financeiros de que caso uma grande organização bancária enfrente problemas, o governo interviria, na maior parte das circunstâncias, para

Figura 2 – Resultados - LoLR



Resultados para a simulação de Banco Central agindo como prestamista de última instância para um total de 100 repetições, retirando a média por ciclo e suavizando o resultado com LOWESS

prevenir sua quebra (ou limitar as perdas, após a quebra, para depositantes não segurados). Ou seja, credores de instituições TBTF também têm algum benefício. A ideia atrás desta crença é que, em geral, *policymakers* se disporão a resgatar instituições consideradas sistemicamente importantes, cuja potencial quebra poderia ameaçar a estabilidade de todo o sistema financeiro (ENNIS; MALEK, 2005; WALL, 2010).

A combinação de ativos mais arriscados com uma maior proporção concentrada em instituições que são grandes demais para quebrar aumenta a probabilidade de instabilidade financeira. Em geral, um banco tende a se tornar maior e mais arriscado — ou seja, aumentar a probabilidade de sua falência — se o seus credores não segurados acreditarem que se

beneficiarão de uma cobertura TBTF. Adicionalmente, os custos fiscais de implementar políticas “Grande Demais para Quebrar” deturpam a alocação de recursos governamentais, ao redirecionarem receitas fiscais para recapitalizar instituições em dificuldade (WALL, 2010).

A terminologia TBTF algumas vezes pode ser enganosa. Enquanto a importância sistêmica de uma organização tende a ser intimamente relacionada com seu tamanho, este nem sempre é o caso. Estas políticas não se referem a tamanho do banco *per se*, mas ao impacto de seu colapso na estabilidade financeira e na economia real; ou seja, sua importância sistêmica. Por exemplo, um banco pode não ser propriamente grande, mas ainda ser percebido como TBTF porque desempenha uma atividade essencial no bom funcionamento de mercados financeiros e nos sistemas de pagamentos (ENNIS; MALEK, 2005; LIN, 2012).

Entretanto, estudar os custos e os benefícios de *bailouts* TBTF é difícil. Quebras de bancos grandes são eventos de baixa probabilidade. Como consequência, não há dados suficientes para identificar plenamente o padrão do comportamento (de banqueiros, *policy-makers* e credores) relacionado a esses eventos. Ou seja, exercícios simulados podem ser particularmente úteis para esse caso (ENNIS; MALEK, 2005).

7.2.2 Simulação

Apesar de políticas TBTF não se referirem exatamente a tamanho do banco — ainda que seja um dos fatores considerados —, considera-se para estas simulações que somente o tamanho de um banco contribui para sua classificação como tal. Consequentemente, quanto maior o tamanho do banco, maior será a probabilidade que obtenha, incondicionalmente, suporte governamental, seja em acesso a liquidez quando necessário e também resgates em caso de insolvência.

Este estudo de caso considera uma adaptação simplificada de Ennis e Malek (2005). Seja p a probabilidade que um banco seja salvo (*bailed out*) pelo governo em caso de falência ou iliquidez. Uma maneira simples de simular uma política TBTF é considerar a probabilidade de *bailout* p crescente linearmente no tamanho do banco, devido ao medo de que a bancarrota de instituições maiores irá perturbar gravemente todo o setor financeiro (ENNIS; MALEK, 2005). Neste exercício, a probabilidade p de resgate de uma instituição financeira será equivalente ao seu *market share*, medido como sua participação nos ativos totais. Esta probabilidade de resgate p refere-se tanto ao acesso à janela de desconto do Banco Central para problemas de liquidez quanto aos aportes governamentais em caso de insolvência; neste caso, o banco passa a agir aproximadamente como se estivesse sob o regime de responsabilidade limitada.

Dois cenários de simulações são realizados: para o primeiro cenário, supõe-se que

não há política TBTF em curso, ou seja, é um sistema bancário *laissez-faire*, sem qualquer intervenção governamental. Em seguida, simula-se a existência da política TBTF, mantendo todos os demais parâmetros idênticos. Em ambos os casos, a distribuição do tamanho dos bancos é retirada de uma distribuição log-normal. A Figura 3 mostra o diagrama deste estudo, com bancos de diferentes tamanhos ligados ao Banco Central, que resgatará, quando possível e necessário, instituições em dificuldade.

Figura 3 – *Too big to fail*


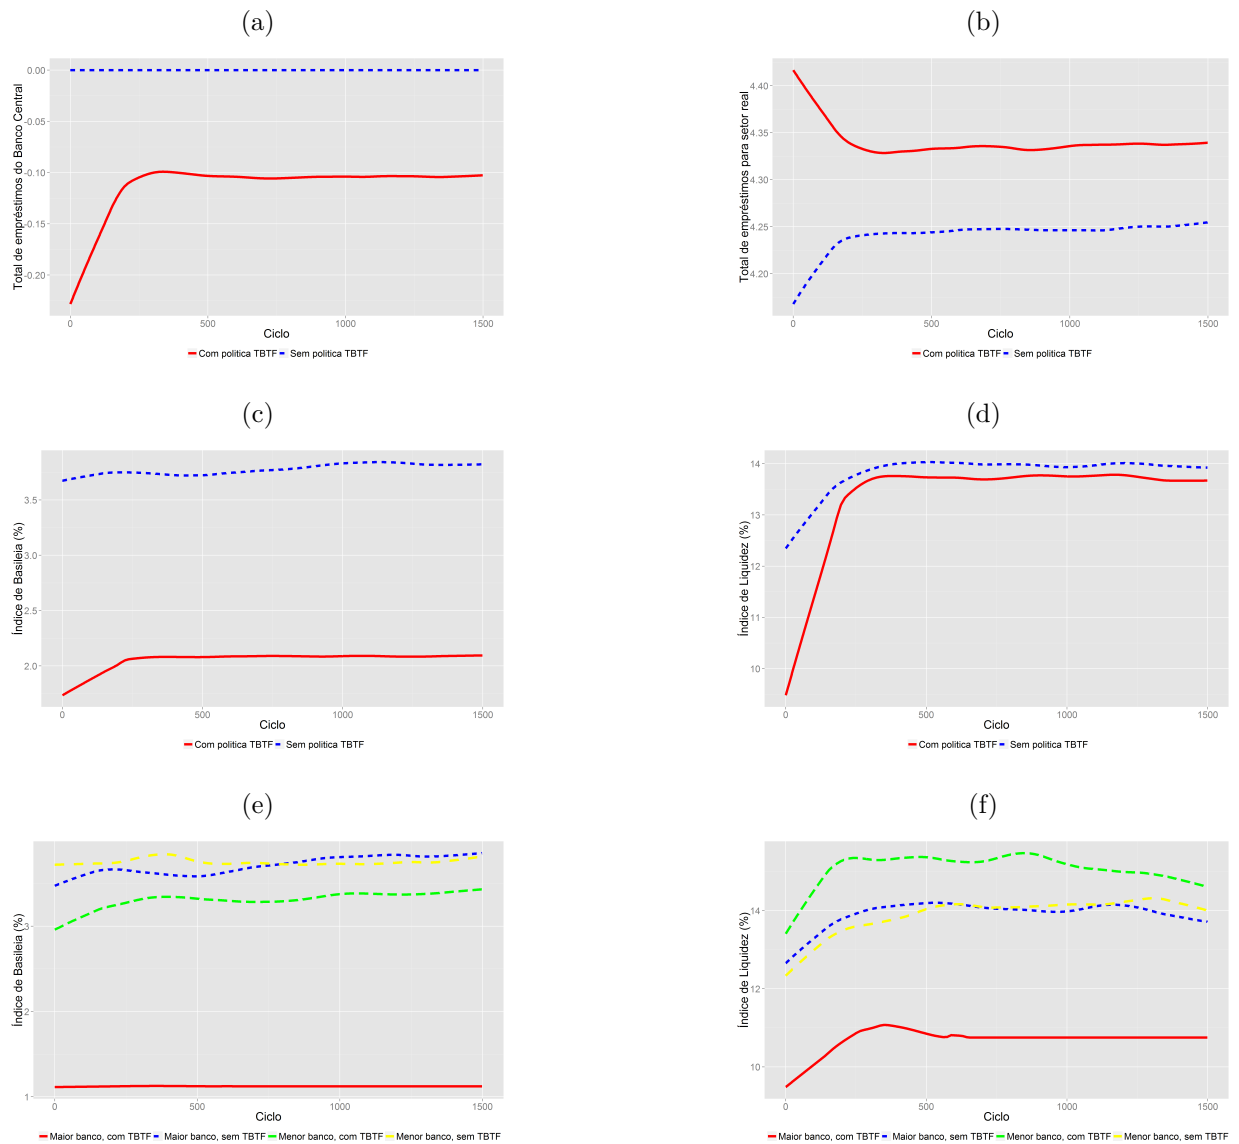


Diagrama da simulação, com bancos de variados tamanhos, ligados ao Banco Central

7.2.3 Resultados

A Figura 4 revela os resultados deste estudo de caso. Percebe-se que o aumento dos empréstimos para as firmas é compensado parcialmente pelo montante usado para resgates. O Índice de Basileia agregado diminui consideravelmente; ou seja, o sistema como um todo torna-se mais frágil. A vantagem obtida pelo maior banco nas simulações é evidente: enquanto as estratégias escolhidas pelos bancos pequenos são similares àsquelas resultantes na ausência de política TBTF, bancos grandes, ao maximizarem seu retorno, assumem estratégias mais arriscadas.

Figura 4 – Resultados - TBTF



Resultados para a simulação de política TBTF para um total de 100 repetições, retirando a média por ciclo e suavizando o resultado com LOWESS

7.3 Risco de crédito e requerimentos de capital

7.3.1 Introdução

Reguladores bancários sempre tiveram como foco as razões de capital das instituições bancárias. Esta ênfase levanta um número de questões inter-relacionadas. O foco em capital é uma forma eficiente para regular bancos? Qual a melhor maneira de estruturar regulações de capital? Como bancos respondem a diferentes tipos de regulações de capital? Quais são os custos e benefícios das diferentes maneiras dos bancos cumprirem as exigências? (WALL; PETERSON, 1996)

Compreender as respostas dos bancos às regulações de capital pode ser útil no desenho de normas que atinjam os objetivos dos reguladores bancários. Um deles tem sido reduzir o número de bancarrotas de instituições financeiras. O capital próprio de um banco provê um colchão para absorver perdas, que de outra maneira causariam sua ruína. Reguladores consideram prevenir a falência de bancos um objetivo importante pelo menos em parte devido à preocupação que bancos quebrados poderem afetar a estabilidade de outras instituições financeiras. (WALL; PETERSON, 1996)

Bancos podem não responder a normas se estas não são vinculantes (*binding*) ou se os custos de atendê-las são maiores que seus benefícios. Um banco pode aumentar sua razão de capital, medido usando padrões regulatórios, mas gerando um efeito ambíguo em algumas circunstâncias. Algumas teorias e evidências empíricas sugerem que bancos podem responder a exigências mais altas de razões de capital aumentando sua exposição ao risco (BERGER; HERRING; SZEGÖ, 1995; WALL; PETERSON, 1996).

A regulação de capital é motivada em parte pela preocupação de externalidades negativas que podem resultar de um *default* bancário que não são levados em conta em requerimento de capital feito pelo mercado. Um remédio regulatório óbvio seria requerer que bancos tenham tanto capital próprio que resulte em probabilidade de *default* negligenciável. De fato, se a proposição de Modigliani e Miller fosse aplicável aos bancos, esta seria uma solução sem custos. Mas se aumentar o requerimento mínimo de capital acima do exigido pelo mercado reduzir o valor do banco e aumentar o seu custo médio de financiamento, então requerimentos regulatórios mais altos podem impor custos sociais. Em mercado competitivos no longo prazo, custos de regulação de capital provavelmente são repassados aos clientes bancários, resultando em tamanho da indústria bancária e quantidade de intermediação reduzidos. Logo, regulação de capital envolve um *tradeoff* entre o custo social marginal de reduzir o risco de externalidades negativas devido a falências bancárias e o custo marginal social de diminuir a intermediação bancária (BERGER; HERRING; SZEGÖ, 1995).

Portanto, é um exercício relevante o estudo das interações estratégicas entre Banco Central — que objetiva simultaneamente a estabilidade e o bom funcionamento do sistema financeiro — e instituições financeiras maximizadoras de lucro.

7.3.2 Simulação

Para este exercício, há dois casos analisados: a simulação base que não considera o Banco Central exigindo níveis mínimos de capital e a situação em que ele age como supervisor e pune instituições que não atinjam o capital mínimo regulatório. Neste último caso, o Banco Central aprende ao buscar exigências que minimizem o número de falências bancárias, mas também levando em conta o montante de empréstimos para o setor real. Caso um banco fique abaixo deste mínimo exigido, ele será obrigado a enquadrar-se ou então

será liquidado pelo supervisor bancário. As preferências do BC são lexicográficas: ele prefere estritamente menos instituições insolventes; entre dois resultados com o mesmo número de bancos falidos, preferirá aquele que resultar em maior quantidade de empréstimos para economia. Obviamente é uma aproximação simplória, mas é suficientemente simples para capturar os efeitos da missão do supervisor e regulador do Sistema Financeiro.

Esta simulação é feita baseada no trabalho de [Gonzalez \(2012\)](#), cuja pesquisa utiliza reamostragem e simulações de Monte Carlo para estimar requerimentos de capital e avaliar a robustez de diversas abordagens de Basileia II para proteger o sistema financeiro de choques aleatórios, com foco em risco de crédito. Para simular adequadamente requerimentos de capital relacionados à risco de crédito, é mais adequado modelar individualmente todas as firmas. Desta forma, é possível capturar diversos efeitos, como diferentes classificações de risco, firmas relacionando-se com múltiplos bancos e agrupamento por setores, cujo comportamento é correlacionado.

Para manter a simplicidade, consideram-se duas categorias de crédito, varejo e atacado, com fatores de ponderação de risco, probabilidade de *default* e distribuições segundo [Gonzalez \(2012\)](#). As estratégias dos bancos consideram somente a proporção de seus ativos que são destinados a empréstimos e sua distribuição entre varejo e atacado é feita considerando o mesmo Portfólio do Sistema Financeiro Nacional representativo considerado. Assim, o número de parâmetros necessários para definir as estratégias permanece o mesmo. A [Figura 5](#) representa um diagrama simplificado deste caso de uso, com as ligações entre diversas firmas e os bancos. Assume-se que nenhum depositante busca sacar antecipadamente seus recursos; assim, questões de liquidez são desconsideradas e o foco torna-se simplesmente o risco de crédito.

7.3.3 Resultados

A [Figura 6](#) expõe as respostas para este estudo de caso. Nota-se que o BC é bem-sucedido na tarefa de minimizar o número de bancos insolventes, com o custo de menor quantidade de empréstimos para o setor real. Na ausência de requerimento de capital, bancos escolhem estratégias que envolvem mais riscos, significativamente abaixo do que seria exigido pelo Banco Central, quando ele age estrategicamente. Nota-se que os bancos mantêm um *buffer* acima do mínimo requerido, para absorver o efeito de choques negativos.

Figura 5 – Risco de crédito e requerimento de capital

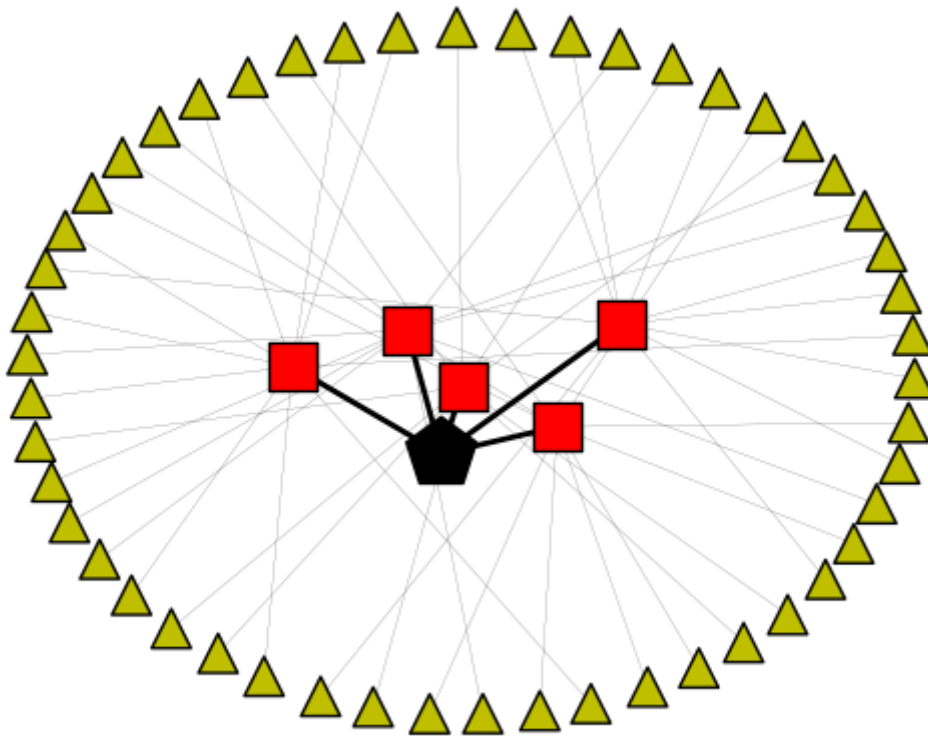


Diagrama da simulação de risco de crédito e requerimento de capital, com firmas representadas

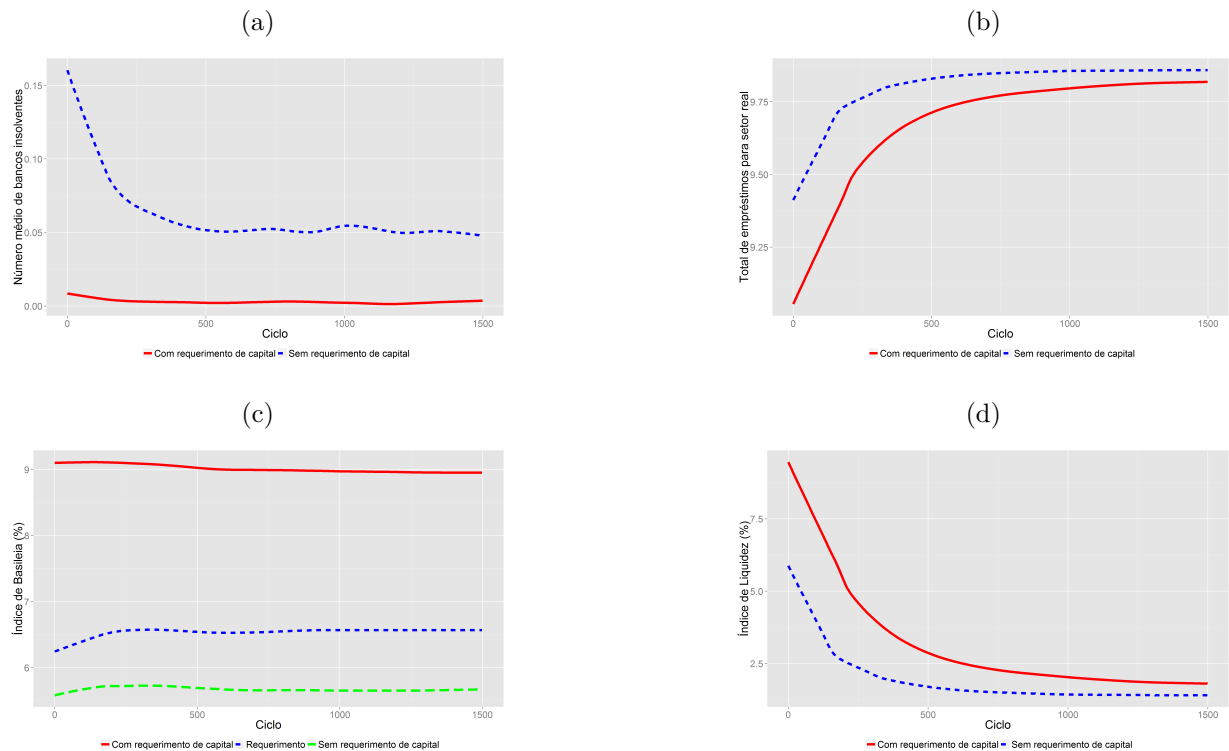
7.4 Seguro de depósitos e a disciplina de mercado

7.4.1 Introdução

Hoje, garantias de depósito são a regra, e não a exceção, nos sistemas bancários ao redor do mundo. Um programa de seguro de depósitos, cujos objetivos incluem proteger pequenos depositantes e evitar crises sistêmicas, pode afetar a disciplina de mercado. Se depositantes sabem que seus depósitos estão seguros e líquidos, eles não têm incentivos para sacar fundos dos seus bancos quando eles veem outras instituições financeiras quebrando. Consequentemente, seguros de depósitos podem reduzir — ou até mesmo eliminar — a probabilidade de corridas bancárias sistêmicas. Ao mesmo tempo, um sistema de seguro de depósitos crível reduz os incentivos de depositantes para monitorar bancos, diminuindo o grau de disciplina de mercado. Depositantes não segurados, que estão expostos aos riscos que bancos assumem, podem penalizar instituições financeiras mais arriscadas ao requererem maiores taxas de juros ou sacando seus depósitos (PERIA; SCHMUKLER, 2001; MCCOY, 2007; BARTH; LEE; PHUMIWASANA, 2013).

Há um conflito de interesse inerente entre depositantes e acionistas de um banco. Na

Figura 6 – Resultados - Risco de crédito e requerimento de capital



Resultados para a simulação de risco de crédito e exigências de capital para um total de 100 repetições, retirando a média por ciclo e suavizando o resultado com LOWESS

ausência de regulações que distorcem incentivos, depositantes, que recebem retornos fixos, preferem firmas que maximizem a probabilidade de que esses retornos fixos sejam pagos. Já acionistas, que são interessados residuais, preferem investir em firmas que persigam estratégias de investimentos mais arriscados que maximizem o retorno total final, de acordo com sua tolerância ao risco (MACEY; GARRETT, 1988).

Caso depositantes tenham acesso a um seguro de depósitos — e acreditem que ele funciona —, eles não terão incentivos a iniciar uma corrida bancária. Ao aumentar a confiança dos depositantes, seguros de depósitos tem o potencial de contribuir para um sistema bancário mais estável. Entretanto, esses seguros também afetam a disciplina de mercado, pois os depositantes terão pouco ou nenhum incentivo para monitorar e policiar as atividades de seus bancos, que terão a possibilidade de assumir mais riscos do seria possível na presença de disciplina dos depositantes. Em outras palavras, é possível que um programa de seguro desse gênero seja a causa de uma crise bancária (BARTH; LEE; PHUMIWASANA, 2013). De fato, pesquisas empíricas mostram que a disciplina de mercado é gravemente erodida em países com alguns desenhos de seguro de depósitos, por exemplo, com alto limite de cobertura e com fundos fornecidos pelo governo (KAUFMAN, 1996; MCCOY, 2007; BARTH; LEE; PHUMIWASANA, 2013).

A disciplina de mercado pode ser benéfica de diversas formas. Este tipo de disciplina

pode reduzir incentivos de risco moral, que certas formas de garantias governamentais criam. Também, a disciplina de mercado pode aumentar a eficiência do setor bancário, pressionando bancos relativamente ineficientes a se tornarem mais eficientes ou a saírem do mercado. Além disso, o custo social de supervisão bancária pode ser reduzido se reguladores cederem maior controle para forças de mercado capazes de distinguir entre bons e maus bancos. Logo, depósitos que podem ser retirados sob demanda servem como uma maneira de restringir o comportamento de bancos (BENSTON, 1993; PERIA; SCHMUKLER, 2001).

Por ser um tema de interesse — e para explorar a flexibilidade de modelos baseados em agentes —, esta simulação analisa os efeitos da presença de um fundo garantidor de depósitos, com depositantes e bancos aprendendo simultaneamente.

7.4.2 Simulação

Para esta simulação, consideram-se a restrição de serviço sequencial, como feito por Diamond e Dybvig (1983), em que os bancos atendem pedidos de retirada de depósitos em ordem de chegada, sem ter conhecimento prévio de quantos depositantes ao todo solicitarão saques. O intuito desta restrição de serviço sequencial é dotar o modelo de um aspecto de tempo contínuo — em que depositantes sacam em tempos aleatórios distintos —, apesar de sua estrutura fundamental ser de tempo discreto. Assim, em cada ciclo de simulação, a ordem em que os depositantes tomam a decisão de sacar ou manter seus depósitos é randomizada. Como diferentes depositantes não possuem necessariamente a mesma tolerância a risco, o resultado final é dependente de caminho (*path dependent*). Ao sacar seus fundos de um banco, o depositante diminui a liquidez deste, fato que é observado pelo próximo depositante a tomar a sua decisão.

Este modelo assume que o fundo garantidor de depósitos protege todos os depositantes independente do montante, não há prêmios de seguro, o fundo garantidor não tem incentivos nem capacidade de monitorar riscos e que os depositantes são capazes de observar perfeitamente os bancos. O modelo é simulado usando os parâmetros constantes na descrição do arcabouço, sendo que duas situações são simuladas: com e sem fundo garantidor. A Figura 7 ilustra os agentes considerados nesta simulação, com suas interconexões.

7.4.3 Resultados

A Figura 8 ilustra os resultados para este exercício. A rede de segurança — o seguro de depósitos, concebido para reforçar a segurança e a solidez do sistema financeiro — consegue praticamente eliminar as corridas bancárias e aumenta o bem-estar dos depositantes. Em contrapartida, reduz os requerimentos de capital pelo mercado, isolando os bancos das

Figura 7 – Seguro de depósitos




Diagrama simplificado da simulação, com depositantes, bancos e fundo garantir de depósitos

reações de quantidades dos depositantes segurados, permitindo que instituições financeiras assumam estratégias mais arriscadas — aumentando o número esperado de insolvências. Ou seja, conforme a literatura citada indica, o desenho dos mecanismos de seguro devem assegurar que os benefícios advindos destes programas não sejam compensados pelos seus custos associados.


7.5 Mercado interbancário, garantias e contágio

7.5.1 Introdução

Um elemento crucial na missão de um Banco Central é prevenir que uma ou poucas instituições financeiras em dificuldades causem perturbações generalizadas nos mercados financeiros e afetem significativamente outros bancos.

Uma falha repentina de uma grande instituição financeira pode reduzir a disposição dos demais participantes em participar no mercado, quando sabe-se que um integrante importante está em apuros e poderá ser, em breve, forçado a liquidar uma posição

Figura 8 – Resultados - Seguro de depósitos



Resultados para a simulação de fundo garantidor de depósitos para um total de 100 repetições, retirando a média por ciclo e suavizando o resultado com LOWESS

grande. Embora essa abordagem cautelosa possa ser apropriada quando vista a partir da perspectiva de uma instituição individual, uma retirada generalizada pode prejudicar importantes fontes de liquidez para os outros agentes. Este tipo de risco sistêmico é o risco de algum choque financeiro impedir que um conjunto de mercados e instituições funcione eficientemente (FURFINE, 2003).

Um outro tipo de risco sistêmico é o risco do colapso de um banco ser transmitido para outras instituições devido a vínculos financeiros. Trabalhos recentes sobre esse tipo de risco sistêmico tem sido estimulados pela percepção de que o aumento dramático no uso de instrumentos financeiros bastante complicados aumentou a possibilidade deste tipo de evento (FURFINE, 2003).

Entretanto, uma rede de bancos possui características de um sistema complexo, pois situações de equilíbrio dependem da forma como as relações entre os bancos foram construídas e da organização do mercado em que atuam, dificultando o uso de modelos com agentes representativos para avaliar o impacto de medidas de mitigação de risco sistêmico (BARROSO, 2011). Portanto, modelos baseados em agentes podem ser uma ferramenta útil para o estudo deste tema. Neste exercício, analisa-se o efeito de uma medida de prevenção de contágios: a câmara de pagamentos.

7.5.2 Simulação

Para esta simulação, há três cenários considerados: ausência de mercado interbancário, presença de mercado interbancário com e sem o uso de garantias. Considera-se os mesmos procedimentos e configurações de câmara de pagamentos com depósitos de garantias descritos por Barroso (2011). Neste ambiente, todos os bancos que desejam captar recursos no mercado interbancário devem depositar garantias na câmara, cujo total recolhido é o montante necessário para garantir o pagamento do participante com maior saldo devedor.

7.5.3 Resultados

A Figura 10 mostra os resultados para este exercício. Primeiramente, convém ressaltar os efeitos do mercado interbancário. Percebe-se que ele diminui o número de insolvências, em relação ao cenário em que não há empréstimos entre bancos, ao permitir que excessos de ativos líquidos sejam redistribuídos, reduzindo o impacto de choques de liquidez. O número de insolvências resultantes para o caso da existência de garantias é menor, implicando que a câmara de pagamentos possa ser uma ferramenta útil para mitigação de risco sistêmico.

Figura 9 – Câmara de pagamentos


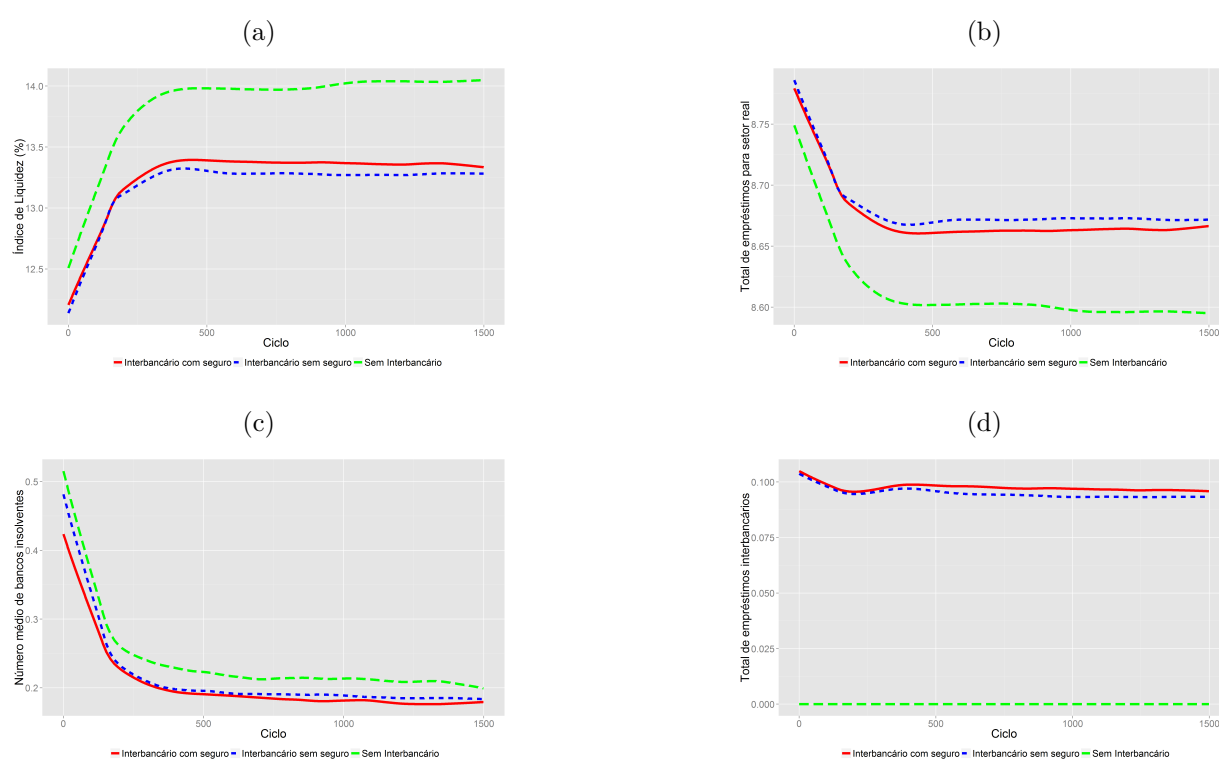


Diagrama da simulação com câmara de pagamentos

Figura 10 – Resultados - Interbancário



Resultados para a simulação de mercado interbancário com uso de garantias para um total de 100 repetições, retirando a média por ciclo e suavizando o resultado com LOWESS

Conclusão

Este trabalho traz uma contribuição científica e tecnológica ao descrever a construção e o uso de um arcabouço para o setor bancário, fundamentado no paradigma baseado em agentes, no qual diversos modelos podem ser implementados e simulados. Apesar de usarem somente protótipos conceituais, não calibrados com dados reais, os exemplos apresentados demonstram que o arcabouço construído pode ser utilizado satisfatoriamente para situações distintas. Devido à complexidade inerente dos problemas destacados, o arcabouço e os exemplos descritos neste projeto são muito simples para serem úteis no mundo real e devem ser vistos como etapas intermediárias para modelos mais profundos, um empreendimento muito ambicioso para o curto prazo. Por isso, esta ferramenta foi construída com o objetivo de facilitar futuras extensões, conforme a ideia de laboratório computacional proposta por [Tsfatsion \(2002\)](#).

A partir dos exemplos analisados, considerando as premissas adotadas, é possível concluir que: o Banco Central, no seu papel de prestador de última instância, aumenta a estabilidade do sistema financeiro, apesar de causar a redução dos índices de liquidez das instituições bancárias; bancos deveriam ter exigências de capital de acordo com sua importância sistêmica; o Banco Central, atuando como supervisor bancário, diminui a ocorrência de falências bancárias decorrentes de choques de solvência, embora provoque a diminuição da oferta de crédito; reguladores e supervisores bancários devem desempenhar o papel outrora desempenhado por depositantes na presença de um fundo garantidor de depósitos; e, finalmente, câmaras de pagamento com uso de garantias são eficazes em diminuir o contágio no mercado interbancário, no caso de falência de um de seus participantes.

Apesar da simplicidade, o trabalho representa o desenvolvimento de uma nova ferramenta analítica e computacional usada para situações onde são consideradas — simultaneamente — a heterogeneidade, adaptação, racionalidade limitada e uma análise explícita de processos descentralizados de mercado. Nos exemplos apresentados, ocorre *feedback* entre características agregadas do ambiente econômico sob análise e os agentes individuais que compõem esse ambiente, fenômeno típico de sistemas complexos. As diferentes possibilidades de configuração da ferramenta foram exploradas individualmente, por motivos de simplicidade, mas também seria possível simular cenários onde todas as características do setor banco descritas são consideradas, permitindo estudos mais próximos da realidade — notoriamente difíceis de ser explorados analiticamente. Da habilidade para explorar uma ampla gama de fenômenos envolvendo aprendizagem e adaptação, associada com o rigor imposto por uma linguagem de computação, resulta uma poderosa técnica de modelagem, que ainda é pouco explorada. De forma resumida, cabe agora descrever os

pontos que serão objetos de trabalhos futuros.

Evidentemente, apesar de experimentos computacionais proverem uma abordagem versátil para o estudo de sistemas complexos, requer-se um entendimento de suas características mais relevantes para que seja possível obter conclusões válidas para o mundo real. As limitações mais perceptíveis para o presente modelo são a questão da granularidade do tempo e da sincronização de atualização; essas limitações podem comprometer a capacidade do modelo em descrever o mundo real, pois em sistemas sociais e naturais raramente há um relógio global que faça com que os elementos do sistemas atualizem seus estados simultaneamente. A maioria dos sistemas reais são assíncronos por natureza (HUBERMAN; GLANCE, 1993; BORRILL; TESFATSION, 2011). Contudo, este projeto apoia-se em modelos baseados em Diamond e Dybvig (1983) comumente adotados na literatura, nos quais a granularidade do tempo é limitada por construção.

Conforme apontado por Huberman e Glance (1993), para que uma simulação em computador usada para emular partes do mundo real em que não há um relógio global (*global clock*) para sincronizar os elementos do sistema, são necessários procedimentos que assegurem que as atualizações dos agentes sejam feita de forma contínua e assíncrona, isto é, os intervalos de tempo considerados devem ser pequenos o suficiente para que no máximo um único agente seja escolhido para interagir com demais elementos da simulação, enquanto todo o estado do restante do sistema é mantido constante. Esta descrição contrasta com simulações síncronas, naquela em que todos os agentes agem ou são atualizados simultaneamente. Para concretizar essa extensão, será necessário primeiramente considerar um modelo que seja multiperíodo. Com isso, será possível também considerar o atraso na propagação de informação dentro do sistema.

O modelo de aprendizagem por EWA ainda precisa de extensões para que seja usado com generalidade, como é feito neste trabalho, além de estudos para verificar sua aplicabilidade ao setor bancário, particularmente se a faixa de valores possíveis para os parâmetros seria suficiente para capturar diferentes nuances de aprendizagem, especialmente para o caso de bancos e firmas, que são mais sofisticados. Será necessário, no mínimo, aplicar a extensão descrita por Camerer, Ho e Chong (2002), para modelar adequadamente agentes com maior sofisticação de aprendizagem, considerando suas previsões para o comportamento dos demais agentes.

Além desses dois pontos críticos, tempo granular e aprendizagem, há diversas outras possibilidades de extensões: o protótipo poderia ser enriquecido com características realistas como conglomerados bancários, diferentes classes de ativos — inclusive fora do balanço —, formação endógena de preços, operações compromissadas, colateral e margens de avaliação (*haircuts*), como em Gai, Haldane e Kapadia (2011), para citar algumas. Há outras dimensões de heterogeneidade das instituições financeiras que podem ser exploradas, como as destacadas por Cajueiro e Tabak (2008): a origem (nacional,

estrangeiro), controle (público, privado) e setor (varejo, crédito, tesouraria), fatores que definem o papel, estratégia e performance. O estudo da formação da rede interbancária também poderia ser aprofundado, usando, por exemplo, ideias apresentadas por [Cajueiro \(2005\)](#), que apresenta fundamentos para a formação de diversos tipos de redes complexas considerando os benefícios e os custos para geração de uma conexão entre agentes.

Finalmente, todos os códigos-fonte usados estão disponíveis sob demanda, através do e-mail joaquim.vasconcellos@gmail.com, para que todos os resultados apresentados possam ser replicados.

Referências

- ALLEN, F.; GALE, D. Optimal financial crises. *The Journal of Finance*, Wiley Online Library, v. 53, n. 4, p. 1245–1284, 1998. Citado na página 47.
- ALLEN, F.; GALE, D. Financial contagion. *Journal of political economy*, JSTOR, v. 108, n. 1, p. 1–33, 2000. Citado na página 47.
- ARTHUR, W. B. Complexity and the economy. *science*, American Association for the Advancement of Science, v. 284, n. 5411, p. 107–109, 1999. Citado 3 vezes nas páginas 17, 23 e 26.
- ARTHUR, W. B. Complexity economics: A different framework for economic thought. 2013. Citado 2 vezes nas páginas 17 e 23.
- ARTHUR, W. B.; DURLAUF, S. N.; LANE, D. A. *The economy as an evolving complex system II*. [S.l.]: Addison-Wesley Reading, 1997. Citado na página 24.
- AXELROD, R.; TEFATSION, L. Appendix aa guide for newcomers to agent-based modeling in the social sciences. *Handbook of computational economics*, Elsevier, v. 2, p. 1647–1659, 2006. Citado 3 vezes nas páginas 31, 34 e 35.
- AXTELL, R. Why agents?: on the varied motivations for agent computing in the social sciences. Center on Social and Economic Dynamics, 2000. Citado 6 vezes nas páginas 31, 33, 36, 39, 55 e 56.
- BAGEHOT, W. *Lombard Street: a description of the money market*. [S.l.]: C. Kegan Paul, 1878. Citado na página 63.
- BARROSO, R. V. Modelo dinâmico computacional de rede de bancos. 2011. Citado 5 vezes nas páginas 40, 43, 47, 58 e 77.
- BARROSO, R. V. *Avaliação de Políticas Regulatórias e de Estrutura do Mercado Financeiro em um Modelo Dinâmico de Sistema Bancário com Aprendizado*. Tese (Doutorado) — Universidade de Brasília, 2014. Citado 2 vezes nas páginas 43 e 47.
- BARTH, J. R.; LEE, C.; PHUMIWASANA, T. Deposit insurance schemes. In: *Encyclopedia of Finance*. [S.l.]: Springer, 2013. p. 207–212. Citado 2 vezes nas páginas 72 e 73.
- BENSTON, G. J. Market discipline: the role of uninsured depositors and other market participants. In: FEDERAL RESERVE BANK OF BOSTON. *Conference Series;[Proceedings]*. [S.l.], 1993. p. 65–95. Citado na página 74.
- BERGER, A. N.; HERRING, R. J.; SZEGÖ, G. P. The role of capital in financial institutions. *Journal of Banking & Finance*, Elsevier, v. 19, n. 3, p. 393–430, 1995. Citado 2 vezes nas páginas 63 e 70.
- BORRILL, P. L.; TEFATSION, L. 11 agent-based modeling: the right mathematics for the social sciences? *The Elgar Companion to Recent Economic Methodology*, Edward Elgar Publishing, p. 228, 2011. Citado 13 vezes nas páginas 17, 18, 25, 26, 27, 29, 30, 31, 32, 35, 37, 56 e 82.

- BROWN, D. Agent-based models. *The Earth's Changing Land*, 2006. Citado 4 vezes nas páginas 18, 29, 31 e 32.
- CAJUEIRO, D. O. Agent preferences and the topology of networks. *Physical Review E*, APS, v. 72, n. 4, p. 047104, 2005. Citado na página 83.
- CAJUEIRO, D. O.; TABAK, B. M. The role of banks in the brazilian interbank market: Does bank type matter? *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 387, n. 27, p. 6825–6836, 2008. Citado na página 82.
- CAMERER, C.; HO, T. H. Experience-weighted attraction learning in normal form games. *Econometrica*, Wiley Online Library, v. 67, n. 4, p. 827–874, 1999. Citado 3 vezes nas páginas 39, 40 e 58.
- CAMERER, C. F.; HO, T.-H.; CHONG, J.-K. Sophisticated experience-weighted attraction learning and strategic teaching in repeated games. *Journal of Economic Theory*, Elsevier, v. 104, n. 1, p. 137–188, 2002. Citado na página 82.
- CHAKRABARTI, R. Just another day in the inter-bank foreign exchange market. *Journal of Financial Economics*, Elsevier, v. 56, n. 1, p. 29–64, 2000. Citado 2 vezes nas páginas 23 e 43.
- CHEN, S.-H. Computational intelligence in economics and finance: Carrying on the legacy of herbert simon. *Information Sciences*, Elsevier, v. 170, n. 1, p. 121–131, 2005. Citado 2 vezes nas páginas 17 e 18.
- CLEVELAND, W. S. Lowess: A program for smoothing scatterplots by robust locally weighted regression. *American Statistician*, JSTOR, p. 54–54, 1981. Citado na página 59.
- COLANDER, D. et al. Beyond dsge models: toward an empirically based macroeconomics. *The American Economic Review*, JSTOR, v. 98, n. 2, p. 236–240, 2008. Citado 2 vezes nas páginas 17 e 35.
- DARLEY, V. Emergent phenomena and complexity. In: *Artificial Life IV*. [S.l.: s.n.], 1994. p. 411–416. Citado na página 24.
- DAVIS, J. P.; EISENHARDT, K. M.; BINGHAM, C. B. Developing theory through simulation methods. *Academy of Management Review*, Academy of Management, v. 32, n. 2, p. 480–499, 2007. Citado 3 vezes nas páginas 34, 37 e 38.
- DIAMOND, D. W.; DYBVIK, P. H. Bank runs, deposit insurance, and liquidity. *The journal of political economy*, JSTOR, p. 401–419, 1983. Citado 4 vezes nas páginas 47, 57, 74 e 82.
- DURLAUF, S. N. What should policymakers know about economic complexity? *Washington Quarterly*, Taylor & Francis, v. 21, n. 1, p. 155–165, 1998. Citado 3 vezes nas páginas 25, 30 e 35.
- ENNIS, H.; MALEK, H. S. Bank risk of failure and the too-big-to-fail policy. *FRB Richmond Economic Quarterly*, v. 91, n. 2, p. 21–44, 2005. Citado 3 vezes nas páginas 65, 66 e 67.

- EPSTEIN, J. M. Agent-based computational models and generative social science. *Generative Social Science: Studies in Agent-Based Computational Modeling*, p. 4–46, 1999. Citado 7 vezes nas páginas 17, 29, 30, 31, 35, 36 e 38.
- FARMER, J. D.; FOLEY, D. The economy needs agent-based modelling. *Nature*, Nature Publishing Group, v. 460, n. 7256, p. 685–686, 2009. Citado na página 48.
- FARMER, J. D. et al. A complex systems approach to constructing better models for managing financial markets and the economy. *The European Physical Journal Special Topics*, Springer, v. 214, n. 1, p. 295–324, 2012. Citado 5 vezes nas páginas 17, 23, 29, 36 e 39.
- FOSTER, J. From simplistic to complex systems in economics. *Cambridge Journal of Economics*, CPES, v. 29, n. 6, p. 873–892, 2005. Citado na página 17.
- FOSTER, J. Why is economics not a complex systems science? *Journal of Economic Issues*, JSTOR, v. 40, n. 4, p. 1069–1091, 2006. Citado na página 17.
- FREIXAS, X.; PARIGI, B.; ROCHET, J.-C. The lender of last resort: A 21st century approach. ECB Working paper, 2003. Citado na página 63.
- FURFINE, C. H. Interbank exposures: Quantifying the risk of contagion. *Journal of Money, Credit & Banking (Ohio State University Press)*, v. 35, n. 1, 2003. Citado na página 76.
- GAFFEO, E. et al. Adaptive microfoundations for emergent macroeconomics. *Eastern Economic Journal*, Nature Publishing Group, v. 34, n. 4, p. 441–463, 2008. Citado 8 vezes nas páginas 18, 24, 26, 29, 30, 35, 39 e 40.
- GAI, P.; HALDANE, A.; KAPADIA, S. Complexity, concentration and contagion. *Journal of Monetary Economics*, Elsevier, v. 58, n. 5, p. 453–470, 2011. Citado na página 82.
- GALÁN, J. M. et al. Errors and artefacts in agent-based modelling. *Journal of Artificial Societies and Social Simulation*, v. 12, n. 1, p. 1, 2009. Citado 8 vezes nas páginas 17, 26, 29, 30, 35, 36, 37 e 38.
- GEORG, C.-P. The effect of the interbank network structure on contagion and common shocks. *Journal of Banking & Finance*, Elsevier, 2013. Citado na página 43.
- GONZALEZ, R. B. *Uma avaliação do capital regulatório no sistema bancário*. Tese (Doutorado) — Universidade de São Paulo, 2012. Citado na página 71.
- GUALDI, S. et al. Tipping points in macroeconomic agent-based models. *arXiv preprint arXiv:1307.5319*, 2013. Citado na página 36.
- HELBING, D.; KIRMAN, A. Rethinking economics using complexity theory. *Real-World Economics Review*, v. 64, p. 23–52, 2013. Citado 3 vezes nas páginas 23, 24 e 25.
- HOLLAND, J. H.; MILLER, J. H. Artificial adaptive agents in economic theory. *The American Economic Review*, JSTOR, v. 81, n. 2, p. 365–370, 1991. Citado 4 vezes nas páginas 17, 18, 24 e 25.
- HOOG, S. van der; DEISSEBERG, C.; TEGLIO, A. Modelling requirements for eurace. *EURACE Report D*, v. 2, 2007. Citado 3 vezes nas páginas 33, 34 e 43.

- HUBERMAN, B. A.; GLANCE, N. S. Evolutionary games and computer simulations. *Proceedings of the National Academy of Sciences*, National Acad Sciences, v. 90, n. 16, p. 7716–7718, 1993. Citado 2 vezes nas páginas 17 e 82.
- ISASI, P. et al. Applied computational intelligence for finance and economics. *Computational Intelligence*, Wiley Online Library, v. 23, n. 2, p. 111–116, 2007. Citado na página 17.
- KAUFMAN, G. G. Bank failures, systemic risk, and bank regulation. *Cato J.*, HeinOnline, v. 16, p. 17, 1996. Citado na página 73.
- KIRMAN, A. Learning in agent based models. 2010. Citado 2 vezes nas páginas 17 e 43.
- KIRMAN, A. P. Whom or what does the representative individual represent? *The Journal of Economic Perspectives*, JSTOR, v. 6, n. 2, p. 117–136, 1992. Citado na página 24.
- LADLEY, D. Zero intelligence in economics and finance. *Knowledge Engineering Review*, Cambridge University Press, The Edinburgh Building, Cambridge CB 2 2 RU United Kingdom, v. 27, n. 2, p. 273, 2012. Citado na página 58.
- LIN, T. Too big to fail, too blind to see. *Too Blind to See (April, 16 2012)*, v. 80, 2012. Citado 2 vezes nas páginas 65 e 67.
- MACEY, J. R.; GARRETT, E. H. Market discipline by depositors: A summary of the theoretical and empirical arguments. *Yale J. on Reg.*, HeinOnline, v. 5, p. 215, 1988. Citado na página 73.
- MARKOSE, S. M. Computability and evolutionary complexity: Markets as complex adaptive systems (cas)*. *The Economic Journal*, Wiley Online Library, v. 115, n. 504, p. F159–F192, 2005. Citado 2 vezes nas páginas 24 e 27.
- MARKS, R. E. Validating simulation models: a general framework and four applied examples. *Computational Economics*, Springer, v. 30, n. 3, p. 265–290, 2007. Citado 2 vezes nas páginas 34 e 36.
- MARKS, R. E. Analysis and synthesis: multi-agent systems in the social sciences. *Knowledge Engineering Review*, Cambridge University Press, The Edinburgh Building, Cambridge CB 2 2 RU United Kingdom, v. 27, n. 2, p. 123–136, 2012. Citado na página 27.
- MCCOY, P. A. *The moral hazard implications of deposit insurance: Theory and evidence*. 2007. Citado 2 vezes nas páginas 72 e 73.
- MIDGLEY, D.; MARKS, R.; KUNCHAMWAR, D. Building and assurance of agent-based models: An example and challenge to the field. *Journal of Business Research*, Elsevier, v. 60, n. 8, p. 884–893, 2007. Citado 3 vezes nas páginas 30, 37 e 38.
- MONTAGNA, M.; KOK, C. *Multi-layered interbank model for assessing systemic risk*. [S.l.], 2013. Citado na página 43.
- OBSTFELD, M. Lender of last resort and global liquidity. World Bank, 2009. Citado na página 63.

- PAGE, S. E. On incentives and updating in agent based models. *Computational Economics*, Springer, v. 10, n. 1, p. 67–87, 1997. Citado 2 vezes nas páginas 39 e 57.
- PERIA, M. S. M.; SCHMUKLER, S. L. Do depositors punish banks for bad behavior? market discipline, deposit insurance, and banking crises. *The Journal of Finance*, Wiley Online Library, v. 56, n. 3, p. 1029–1051, 2001. Citado 2 vezes nas páginas 72 e 74.
- PHAN, D. *Agent-based computational economics and cognitive economics*. [S.l.]: Citeseer, 2003. Citado na página 55.
- POUGET, S. Adaptive traders and the design of financial markets. *The Journal of Finance*, Wiley Online Library, v. 62, n. 6, p. 2835–2863, 2007. Citado 4 vezes nas páginas 39, 40, 43 e 58.
- RAILSBACK, S. F.; LYTIMEN, S. L.; JACKSON, S. K. Agent-based simulation platforms: Review and development recommendations. *Simulation*, Sage Publications, v. 82, n. 9, p. 609–623, 2006. Citado na página 18.
- REPULLO, R. Liquidity, risk-taking and the lender of last resort. CEPR Discussion Paper, 2005. Citado na página 64.
- RICHIARDI, M. et al. A common protocol for agent-based social simulation. *Journal of Artificial Societies and Social Simulation*, v. 9, n. 1, 2006. Citado 5 vezes nas páginas 35, 36, 38, 47 e 55.
- RICHIARDI, M. G. Agent-based computational economics: a short introduction. *The Knowledge Engineering Review*, Cambridge Univ Press, v. 27, n. 02, p. 137–149, 2012. Citado 2 vezes nas páginas 31 e 35.
- ROPELLA, G. E.; RAILSBACK, S. F.; JACKSON, S. K. Software engineering considerations for individual-based models. *Natural resource modeling*, Wiley Online Library, v. 15, n. 1, p. 5–22, 2002. Citado 2 vezes nas páginas 55 e 56.
- SIMON, H. A. The architecture of complexity. *Proceedings of the American philosophical society*, JSTOR, v. 106, n. 6, p. 467–482, 1962. Citado 2 vezes nas páginas 24 e 39.
- SIMON, H. A. Satisficing. *The new Palgrave: a dictionary of economics*, Macmillan Press London, v. 4, p. 243–245, 1987. Citado na página 39.
- SOLOW, R. M. On the lender of last resort. *Financial Crisis. Theory, History and Policy*, p. 237–248, 1982. Citado na página 63.
- SOUZA, S. R. S. d. Análise da estabilidade financeira e contágio em redes heterogêneas de bancos e firmas usando um modelo baseado em agentes. 2012. Citado na página 43.
- TEMZELIDES, T. Evolution, coordination, and banking panics. *Journal of Monetary Economics*, Elsevier, v. 40, n. 1, p. 163–183, 1997. Citado na página 47.
- TESFATSION, L. Agent-based computational economics: Growing economies from the bottom up. *Artificial life*, MIT Press, v. 8, n. 1, p. 55–82, 2002. Citado 5 vezes nas páginas 18, 27, 39, 47 e 81.
- TESFATSION, L. Agent-based computational economics: modeling economies as complex adaptive systems. *Information Sciences*, Elsevier, v. 149, n. 4, p. 262–268, 2003. Citado 2 vezes nas páginas 30 e 34.

WALL, L. Too big to fail: No simple solutions. *Notes from the Vault*, 2010. Citado 2 vezes nas páginas 66 e 67.

WALL, L. D.; PETERSON, P. Banks' responses to binding regulatory capital requirements. *Economic Review, Federal Reserve Bank of Atlanta*, v. 81, 1996. Citado 2 vezes nas páginas 69 e 70.

WIKIPEDIA. *Comparison of agent-based modeling software* — *Wikipedia, The Free Encyclopedia*. 2014. [Online; accessed 18-February-2014]. Disponível em: <http://en.wikipedia.org/w/index.php?title=Comparison_of_agent-based_modeling_software&oldid=590721593>. Citado na página 55.

WIKIPEDIA. *Object-oriented programming* — *Wikipedia, The Free Encyclopedia*. 2014. [Online; accessed 18-February-2014]. Disponível em: <http://en.wikipedia.org/w/index.php?title=Object-oriented_programming&oldid=595599010>. Citado na página 33.

WOLFRAM, S. *A new kind of science*. [S.l.]: Wolfram media Champaign, 2002. Citado na página 26.