UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ARTES, CIÊNCIAS E HUMANIDADES
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM DE SISTEMAS
COMPLEXOS

MARCELO VELOSO MACIEL

**Emergência de distribuições de posicionamentos ideológicos: uma abordagem
computacional**

São Paulo

2018

MARCELO VELOSO MACIEL

**Emergência de distribuições de posicionamentos ideológicos: uma abordagem
computacional**

Versão original

Dissertação apresentada à Escola de Artes, Ciências e Humanidades da Universidade de São Paulo para obtenção do título de Mestre em Ciências pelo Programa de Pós-graduação em Modelagem de Sistemas Complexos.

Área de concentração: Sistemas Complexos

Orientador: Prof. Dr. André Cavalcanti Rocha Martins

São Paulo

2018

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

CATALOGAÇÃO-NA-PUBLICAÇÃO

(Universidade de São Paulo. Escola de Artes, Ciências e Humanidades. Biblioteca)

CRB 8 - 4936

Maciel, Marcelo Veloso

Emergência de distribuições de posicionamentos ideológicos: uma abordagem computacional / Marcelo Veloso Maciel ; orientador André Cavalcanti Rocha Martins. – 2018.

87 f. : il.

Dissertação (Mestrado em Ciências) - Programa de Pós-Graduação em Modelagem de Sistemas Complexos, Escola de Artes, Ciências e Humanidades, Universidade de São Paulo.
Versão original.

1. Opinião pública - Simulação computacional. 2. Política. 3. Sistemas dinâmicos. I. Martins, André Cavalcanti Rocha, orient.
II. Título.

CDD 22.ed.– 303.38011

Dissertação de autoria de Marcelo Veloso Maciel, sob o título “**Emergência de distribuições de posicionamentos ideológicos: uma abordagem computacional**”, apresentada à Escola de Artes, Ciências e Humanidades da Universidade de São Paulo, para obtenção do título de Mestre em Ciências pelo Programa de Pós-graduação em Modelagem de Sistemas Complexos aprovada em _____ de _____ de _____ pela comissão julgadora constituída pelos doutores:

Prof. Dr. _____

Instituição: _____

Presidente

Prof. Dr. _____

Instituição: _____

Prof. Dr. _____

Instituição: _____

Prof. Dr. _____

Instituição: _____

À minha família.

“Imagination is the theorist’s means for understanding a world he can never “know” in an intimate way.”

(Sheldon Wolin)

“It is important for him who wants to discover not to confine himself to one chapter of science, but to keep in touch with various others.”

(Jaques Hadamard)

Resumo

MACIEL, Marcelo Veloso. **Emergência de distribuições de posicionamentos ideológicos**: uma abordagem computacional. 2018. 87 f. Dissertação (Mestrado em Ciências) – Escola de Artes, Ciências e Humanidades, Universidade de São Paulo, São Paulo, 2018.

As democracias estão fundamentadas na conexão entre atitudes dos cidadãos e políticas. Numa arena política onde agentes têm racionalidade limitada, a competição dos políticos e partidos pelo apoio e voto da população depende de como está distribuída a opinião pública. Contudo, modelos explícitos que gerem essas distribuições, ao invés de pressupô-las, ainda são escassos. O presente trabalho gera estas distribuições por meio de um modelo computacional baseado em agentes de influência social. Nele os agentes interagem em díades e tornam-se mais próximos dos outros agentes em alguma questão a depender da distância de seus posicionamentos ideológicos, da incerteza dos agentes e do quanto confiam na opinião do outro. Por meio da combinação de análise de sensibilidade, histogramas e séries temporais de medidas do sistema e gráficos de dispersão, encontramos que o quão incertos são os agentes, o número de questões subjacentes ao seu posicionamento e o quanto estão sujeitos a mudanças aleatórias de atitude (ruído) são determinantes importantes do formato da distribuição de atitudes populacional. Nossos resultados nos levam a questionamentos empíricos quanto à interação dos parâmetros do modelo e a plausibilidade das distribuições geradas por ele a serem respondidos por trabalhos futuros.

Palavras-chaves: Opinião Pública. Dinâmicas de Opinião. Modelo Baseado em Agentes. Política.

Abstract

MACIEL, Marcelo Veloso. **Emergence of distributions of ideological positioning: a computational approach**. 2018. 87 p. Dissertation (Master of Science) – School of Arts, Sciences and Humanities, University of São Paulo, São Paulo, 2018.

Democracies are based on the connection between citizens' attitudes and policies. In a political arena where agents are boundedly rational, the competition of politicians and parties for the support and vote of the population depends on how the public opinion is distributed. However, explicit models that generate, instead of presupposing, them are still rare. This work generates those distributions through a computational agent-based model of social influence. In it the agents interact in pairs and become more similar to the others in some issue conditional on their ideological positioning, their uncertainty and on how much they trust another agent's opinion. Through a combination of sensitivity analysis, histograms and time series of the system's measures and scatterplots, we find that how uncertain the agents are, the number of issues underneath their positioning and how much they're subject to random attitude change (noise) are important determinants of the shape of the population attitudinal distribution. Our results lead us to empirical questions regarding the model parameters interaction and the plausibility of the distributions generated by it which should be answered by future works.

Keywords: Public Opinion. Opinion Dynamics. Agent-Based Model. Politics.

Lista de figuras

Figura 1 – Funções de utilidade comuns em política	19
Figura 2 – Evidência de estabilidade ideológica	23
Figura 3 – Distribuição de posicionamento ideológico de respondentes em 20 países	25
Figura 4 – Espectro de abordagens no tocante à cognição dos agentes	32
Figura 5 – Distribuições Beta para 50 agentes	38
Figura 6 – Evolução dos pontos ideais dos agentes ao longo de duas realizações. Parametrização: $N = 500, p = 0.9, \rho = 1e - 5, n_issues = 1, p_intran =$ 0.0	42
Figura 7 – Distribuições com coberturas distintas	42
Figura 8 – Parametrização equivalente a Figura 6 (b), mas com $\rho = 0.001$	44
Figura 9 – Desvio padrão dos pontos ideais das populações para cada parametrização	46
Figura 10 – Gráfico de dispersão para 70.000 parametrizações.	47
Figura 11 – Índices de Sobol de sensibilidade	48
Figura 12 – Evolução dos pontos ideais dos agentes ao longo de duas realizações. Parametrização: $p_intran = 0.15, N = 500, p = 0.9, \rho = 1e -$ $5, n_issues = 1$	49
Figura 13 – Evolução dos pontos ideais dos agentes sob efeito de intransigentes nos extremos. Parametrização: $\sigma = 0.1, p_intran = 0.15, N = 500, p =$ $0.9, \rho = 1e - 5, n_issues = 1$	50
Figura 14 – Intransigentes com $\sigma = 0.01$. Parametrização global: $\sigma = 0.1, p_intran =$ $0.15, N = 500, p = 0.9, \rho = 1e - 5, n_issues = 1$	51
Figura 15 – Intransigentes com $\sigma = 0.01$. Parametrização global: $\sigma = 0.1, p_intran =$ $0.15, p = 0.9, \rho = 1e - 5, n_issues = 1$	52
Figura 16 – Número de pontos ideais finais para diferentes valores de σ . Parame- trização: $\rho = 1e - 5, p_intran = 0.0, p = 0.9, N = 500$	53
Figura 17 – Evolução dos pontos ideais quando há ruído e agentes intransigentes. Parametrização: $p_intran = 0.15, N = 500, p = 0.9, \rho = 0.05$	54
Figura 18 – Gráfico de dispersão e regressões polinomiais para 70.000 parametrizações.	87

Lista de tabelas

Tabela 1 – Número de Entrevistados (N) para 20 países do ESS 2002	70
Tabela 2 – Índices de Sobol e coeficientes de erro correspondentes para análise de sensibilidade com 70.000 parametrizações.	86
Tabela 3 – Índices de Sobol de segunda ordem (S2) para análise de sensibilidade com 70.000 parametrizações.	86

Lista de abreviaturas e siglas

ABM	<i>Agent-based model(s) or modeling</i>
OD	<i>Opinion Dynamics</i>
ESS	<i>European Social Survey</i>

Sumário

1	Introdução	12
2	Teoria Política Formal e distribuição de preferências	15
2.1	<i>Fundamentos da Teoria Política Formal</i>	15
2.2	<i>Teoria Política Espacial</i>	18
2.3	<i>Teoria Espacial e eleições</i>	20
3	Dinâmicas de Opinião	26
3.1	<i>Definição da área</i>	26
3.2	<i>Modelagem Baseada em Agentes e Dinâmicas de Opinião</i>	27
3.3	<i>Modelos canônicos</i>	29
3.4	<i>Regra de Atualização e processamento de informação</i>	32
4	Modelo	36
4.1	<i>Entidades e processos</i>	36
4.2	<i>Parâmetros-Chave</i>	40
4.3	<i>Inicialização e iteração</i>	40
4.4	<i>Metodologia de Análise</i>	41
4.5	<i>Resultados</i>	46
5	Conclusão	56
	Referências	58
	Apêndice A – Definições formais complementares	68
	Apêndice B – Dos dados	70
	Apêndice C – Da implementação	71
	Apêndice D – Gráficos e tabelas complementares	86

1 Introdução

Uma característica fundamental da democracia é a responsividade do governo às preferências, crenças e atitudes dos cidadãos (DAHL, 1989; BARTELS, 2003). Nas democracias modernas isso ocorre por meio de vários mecanismos de conexão entre os cidadãos e seus representantes (DAHL, 1989; SCHUMPETER, 2013). As democracias estão, desta forma, fundamentadas nonexo entre opinião pública e governo representativo. A natureza e origem da opinião pública é então central para a compreensão dos nossos sistemas políticos (BERELSON, 1952). Como argumentado por Downs (1999), a distribuição da opinião pública é de alta relevância para a compreensão do nexodemocrático na medida em que orienta o comportamento de políticos e partidos. Seguindo Downs, o pressuposto central deste trabalho é que não só a opinião pública importa, mas, mais especificamente, o seu formato também. A literatura em ciência política que busca explicar, por meio de modelos explícitos, o procedimento de surgimento e dinâmica de padrões de opinião ainda é escassa e desconectada dos trabalhos em Dinâmicas de Opinião, uma das principais áreas em Simulação Social (LORENZ, 2017; LAVER; SERGENTI, 2011; HAUKE; LORSCHIED; MEYER, 2017). Há assim espaço para a contribuição de trabalhos de caráter generativo, isto é, guiados pela seguinte pergunta: “Como pode a interação local entre agentes autônomos heterogêneos gerar a seguinte regularidade?” (EPSTEIN, 2006).

Pensar em termos generativos nos leva à busca dos microfundamentos das regularidades de interesse. Todas as interações sociais são, ao menos em parte, condicionadas pelas crenças e opiniões dos agentes. É plausível que haja tanto um fundamento genético-evolucionário para nossas crenças e orientações, quanto uma fundamentação em mecanismos relacionados a sistemas de herança e aprendizados sociais (JABLONKA; LAMB, 2014; FOWLER; SCHREIBER, 2008; FOWLER; DAWES, 2013). Um indivíduo, ao tomar uma decisão, não baseia-se unicamente na informação e crença averiguadas individualmente, mas também pode considerar as crenças de outros agentes conectados a ele socialmente e informacionalmente (GINTIS, 2016). Em política isso significa que as crenças dos agentes são uma combinação de sua crença “idiossincrática” e da combinação de mensagens/sinais que recebem dos seus pares e da mídia (BARABAS, 2004; RYAN, 2011). A “cognição em rede” (GINTIS, 2016) dos agentes e essas duas fontes de informação, pares e mídia ¹, for-

¹ O trabalho trata unicamente dos pares como fonte de informação. Modelar a influência da mídia é tema para trabalhos futuros.

necem assim os dois mecanismos mínimos para microfundamentar abordagens generativas para a opinião pública.

Tendo em vista esses dois mecanismos, este trabalho tem por objetivo geral explorar, por meio de um modelo baseado em agentes de influência social, a geração de distribuições de preferências ² análogas a distribuições empíricas. O fazemos por meio da adaptação do modelo de Martins (2009). Esse modelo em particular é escolhido por estar no meio do espectro entre modelos complicados e simples demais do ponto de vista cognitivo, além de sua influência bayesiana ser coerente com o *framework* do ator racional³. As modificações foram as seguintes: primeiramente, seguimos a recomendação metodológica de Macy e Tsvetkova (2015) e incluímos ruído na dinâmica do modelo; segundo, os posicionamentos dos agentes no espectro político são derivados dos posicionamentos deles em várias questões, o que é mais consistente com o fato de que alternativas preferidas por agentes em contextos de massa são derivadas das atitudes deles em diferentes questões⁴; ademais, adicionamos agentes intransigentes à população, o que é uma variante, possibilitada pelo modelo de Martins (2009), da verificação do papel de extremistas⁵ na dinâmica de opinião (DEFFUANT *et al.*, 2002; FLACHE *et al.*, 2017). O modelo foi analisado por meio da combinação de análise de sensibilidade, histogramas e séries temporais de medidas do sistema e gráficos de dispersão. Com isso buscamos verificar em que medida essas modificações levam a mudanças de comportamento em contraste ao modelo original e quais os efeitos dos atributos dos agentes e parâmetros do modelo sobre a opinião populacional, mais precisamente sobre a dispersão e cobertura das opiniões⁶.

Além da Introdução, o trabalho é estruturado da seguinte forma: no Capítulo 2 caracterizamos e justificamos o problema do trabalho. Para tal apresentamos os fundamentos do modelo do ator racional, como é adaptado para o contexto político por meio dos modelos “espaciais” de política e a aplicação desses modelos para representar a opinião pública. Examinamos a relação entre preferências e atitudes e qual o impacto disso para pensar os agentes em contextos macropolíticos. No Capítulo 3 definimos a área de

² A diferença entre crenças, preferências e opiniões será analisada nos capítulos 2 e 3.

³ Essas questões são tratadas no Capítulo 3.

⁴ Como discutido nos Capítulos 2 e 4.

⁵ Os extremistas são inseridos nos modelos com o intuito de investigar quais propriedades de agentes e de suas interações levam ao consenso, a populações isoladas ou polarizadas. Isso é tema constante de debate e reflexão política, em decorrência de sua conexão com a estabilidade/instabilidade de governos e seus efeitos sociais. Não por acaso é também um dos problemas de pesquisa centrais para a área de Dinâmicas de Opinião (FIORINA; ABRAMS; POPE, 2005; PULICK *et al.*, 2016; BRAMSON *et al.*, 2016).

⁶ Ambas medidas de polarização abordadas no Capítulo 4.

Dinâmicas de Opinião (OD), discorremos sobre o que são Modelos Baseados em Agentes e os elementos constituintes de um modelo de OD, fazemos uma revisão de literatura dos modelos canônicos da área, além de uma discussão sobre onde nossa abordagem está localizada dentre as várias formas de se modelar as atitudes de agentes. No Capítulo 4 apresentamos as entidades e processos do modelo, quais seus parâmetros, especificamos como é realizada a inicialização e o procedimento do modelo, em seguida discutimos a metodologia de análise e os resultados. Por fim na Conclusão recapitulamos o que foi feito e tratamos das limitações do trabalho.

2 Teoria Política Formal e distribuição de preferências

Como discutido na introdução, o nexso entre cidadãos e governo é a base dos sistemas democráticos. Dada a importância desse nexso não é surpresa que na Ciência Política exista uma grande gama de trabalhos e abordagens que buscam descrever, explicar e prevê-lo. A caracterização e justificativa para nosso problema de pesquisa parte de um diálogo com a Teoria Política Formal, a ser definida e discutida em seguida.

2.1 Fundamentos da Teoria Política Formal

Vamos definir Teoria Política Formal como: conjunto de modelos e hipóteses teóricas explicitamente definidos que buscam representar atividades e comportamentos relacionados à ação e escolha coletiva (OPPENHEIMER, 2012; CLARKE; PRIMO, 2012).

Nosso foco na literatura em teoria política formal é justificado pelo fato desta ser um corpo teórico construído por meio de modelos explícitos (EPSTEIN, 2008). Embora não seja a única forma de construir modelos explícitos, o uso de um sistema formal é uma forma de forçar o pesquisador a delimitar claramente qual o modelo está sendo utilizado para representar um determinado sistema ou processo gerador de dados (MORTON, 1999; SMALDINO, 2017).

O estudo formal da ação e escolha coletiva teve como período de fundação moderno o período entre Black (1948) - marco no estudo da escolha coletiva - e Olson (1965) - marco para os estudos da ação coletiva. Contudo, *insights* típicos da literatura foram discutidos anteriormente por pensadores como Plínio, o Jovem (64-114 d.C.); Ramon Lull (1232-1315); David Hume; e John Stuart Mill (MCLEAN, 2015; HARDIN, 2013; ORDESHOOK, 1990). Embora não seja a única forma de se modelar formalmente fenômenos políticos, modelos de escolha racional são em larga medida os mais comuns (AUSTEN-SMITH; BANKS, 1998). De uma forma geral, os modelos da Teoria da Escolha Racional, em política, buscam representar fenômenos segundo alguma variante da seguinte equação, a Equação de Plott (MUNGER, 2015; OSTROM, 1986)¹:

¹ Essa “equação” é conceitual. $\oplus$ é usado como um operador abstrato não especificado (OSTROM, 1986).

$$\text{Preferences} \oplus \text{Beliefs} \oplus \text{Physical Possibilities} \oplus \text{Institutions} = \text{Outcomes}$$

Esses modelos podem ser divididos em duas variantes: *thin* ou *thick* (HECHTER; KANAZAWA, 1997; GREEN; SHAPIRO, 1996). Ambos os tipos de modelos são construídos com base nos pressupostos mínimos de um modelo de ator racional: preferências racionais e racionalidade bayesiana (GINTIS, 2016). A diferença entre os dois é que os modelos *thin* não fazem pressupostos substantivos sobre os valores e objetivos dos agentes. Neles os teóricos buscam modelar a combinação entre agentes e instituições da maneira mais geral possível. Já modelos *thick* adicionam um conjunto de pressupostos extras sobre objetivos, valores, incerteza, com o objetivo de representar fenômenos particulares como o comparecimento às urnas, a competição partidária, a escolha de candidatos pelo eleitorado, independência burocrática, o efeito fiscal de constituições, dentre outros (BENDOR *et al.*, 2011).

Todo modelo formal da escolha racional em política envolve os seguintes elementos primitivos: o conjunto N de agentes, o conjunto X de alternativas possíveis e para cada agente em N uma descrição de suas preferências em relação às alternativas em X (AUSTEN-SMITH; BANKS, 1998, p. 263).

A preferência é uma relação de comparação de valor na qual dois conceitos são fundamentais: o de melhor (preferência estrita), denotado por $\succ$, e o de igual em valor (indiferença), denotado por $\sim$.

A relação de preferência fraca $\succeq$ pode ser definida da seguinte forma:

$$x \succeq y \leftrightarrow x \succ y \text{ ou } x \sim y$$

A aplicação dessa definição de preferência no modelo do ator racional pressupõe que ela seja uma relação binária no conjunto de alternativas com as seguintes propriedades: completude, transitividade e independência das alternativas irrelevantes ² (GINTIS, 2016; BINMORE, 2008). Um pressuposto adicional é que existe uma alternativa preferida a todas as outras para cada agente, de forma que num ambiente sem restrição os atores escolhem essa alternativa (GINTIS, 2016). Esses pressupostos constituem o primeiro princípio do modelo do ator racional: os agentes possuem *preferências consistentes ou racionais*.

² Definidas no Apêndice A.

Uma conveniência analítica é representar relações de preferência por meio de funções de utilidade, que são funções que atribuem um número real para cada elemento do conjunto de alternativas (HANSSON; GRÜNE-YANOFF, 2012). A relação $\succeq$ é representada pela função $u: X \rightarrow \mathbb{R}$ se e somente se:

$$u(x) \geq u(y) \text{ se e somente se } x \succeq y$$

Por meio dessa representação, podemos dizer que os atores agem *como se* estivessem maximizando sua função de utilidade. Importante notar que funções de utilidade são um dispositivo matemático. Modelar agentes por meio de funções de utilidade não implica que eles sejam egoístas, instrumentais, utilitários, hedonistas ou que estejam “tentando maximizar sua utilidade” (GAUS, 2007).

O segundo princípio dos modelos de ator racional é a *racionalidade bayesiana* (GINTIS, 2016). Quando as alternativas são probabilísticas, primeiro pressupomos que os agentes têm um *modelo do mundo* (ACEMOGLU; OZDAGLAR, 2011): os agentes vão ter uma crença, representada por meio de uma função de distribuição de probabilidade, à qual vai atribuir uma probabilidade p para cada evento em X . O modelo da escolha racional pressupõe, então, que as crenças dos agentes são coerentes ou consistentes, o que equivale a dizer que estão em conformidade com os axiomas da probabilidade (JACKMAN, 2009). O primeiro elemento da racionalidade bayesiana é a consistência das crenças dos agentes com os axiomas da probabilidade. O outro elemento do princípio da racionalidade bayesiana é a *atualização bayesiana*: os agentes atualizam suas crenças segundo o Teorema de Bayes (GINTIS, 2016, p.104).

Sumarizando, os modelos de escolha racional na sua versão mais básica pressupõem agentes com preferências consistentes, o que implica que sejam transitivas, completas e independentes de alternativas irrelevantes. Caso o contexto de decisão seja incerto também pressupõem que os agentes têm uma crença em conformidade com os axiomas da probabilidade e as atualizam de acordo com o Teorema de Bayes.

2.2 Teoria Política Espacial

Dentre as várias formas de modelar política por meio do modelo do ator racional, a principal é o conjunto de modelos conhecido como Teoria Espacial (ou Geométrica³) de Política (HOUWELING; SNIDERMAN, 2005).

A Teoria Espacial de Política tem suas origens nos trabalhos canônicos de Duncan Black e Anthony Downs, e as bases matemáticas da teoria foram desenvolvidas por Otto Davis, Melvin Hinich e Peter Ordeshook (BLACK *et al.*, 1958; DOWNS, 1957; POOLE, 2005; MILLER, 2015). Tal teoria está fundamentada na ideia essencial que as alternativas, o posicionamento e as preferências dos agentes políticos podem ser representadas por meio de espaços geométricos. Captura a metáfora e noção da linguagem política diária de que a similaridade/diferença entre alternativas, posicionamentos e preferências políticas pode ser pensada por meio de relações de proximidade/distância, tal qual a noção de que partidos, pessoas ou propostas são de “extrema-esquerda”, “centristas” ou “de direita” (MUNGER, 2015). Suponhamos que João e Alice tenham preferências similares e que João e Eva tem preferências divergentes. Então podemos dizer que João é mais “próximo” de Alice devido ao fato de ele ser mais parecido com ela do que com Eva. O espaço político é então um espaço conceitual no qual a noção de similaridade é mapeada à de proximidade (LAVER, 2014).

Seguindo Humphreys e Laver (2010), podemos dividir os modelos geométricos em dois grupos. Eles podem ser *fracamente* ou *fortemente* espaciais. Os modelos fracamente espaciais só caracterizam as alternativas e as preferências segundo uma analogia geométrica. Já modelos fortemente espaciais envolvem uma teoria comportamental sobre como as pessoas pensam sobre política (LAVER, 2014).

Nos modelos fracamente espaciais o conjunto de alternativas X é pensado como um espaço, mais comumente como o subconjunto de um espaço Euclidiano de n dimensões (AUSTEN-SMITH; BANKS, 1998). Assumem também que agentes têm preferências consistentes sobre esse espaço. Não assume-se, contudo, que os agentes percebem as utilidades das alternativas em termos das distâncias relativas no espaço subjacente. Os

³ Vamos usar o termo geométrico de maneira intercambiável com espacial, pelo fato do último gerar a confusão com trabalhos relacionados ao papel do espaço geográfico em política (WARD; O’LOUGHLIN, 2002; POOLE, 2005).

agentes têm funções de utilidade abstratas, não especificadas (HUMPHREYS; LAVER, 2010)⁴.

Modelos fortemente espaciais, por outro lado, pressupõem que os agentes têm uma cognição geométrica. Isso significa que localizam as alternativas e sua alternativa preferida x_i , seu ponto ideal, num espaço cognitivo e ranqueiam as alternativas segundo uma medida de distância $d_i(., .)$. A função de utilidade dos agentes é a composição da função de distância e uma função de perda de forma que $u_i(y) = f_i(d_i(x_i, y))$ (HUMPHREYS; LAVER, 2010; LAVER, 2014). Se u_i é a função de utilidade de um agente então seu ponto preferido (ou ideal) é dado por (BINMORE, 2008)⁵:

$$x_i = \max_{x \in X} u_i(x)$$

O pressuposto mais comum é que a métrica seja Euclidiana: os agentes medem a distância entre dois pontos no espaço de alternativas usando o Teorema de Pitágoras (MUNGER, 2015). Ademais, assume-se, por conveniência analítica, funções com um único pico (o ponto ideal do agente) e simétricas. Funções de utilidade usualmente utilizadas na ciência política são a linear, a quadrática e a gaussiana, ilustradas na Figura 1:

Figura 1 – Funções de utilidade comuns em política

Fonte: Adaptado de Armstrong *et al.* (2014)

⁴ Humphreys e Laver (2010) indica o programa de pesquisa sobre o caos em decisões coletivas multidimensionais como exemplo de modelos fracamente espaciais.

⁵ O que faz com que eles ajam “como se” estivessem maximizando sua função de utilidade.

Desde o trabalho fundacional *The theory of committees and elections* (BLACK *et al.*, 1958), essa estrutura básica do modelo espacial é aplicada em dois tipos de fenômenos: votos em comitê e eleições de massa (MUNGER, 2015). Há, contudo, uma grande diferença entre essas duas situações de ação, e essa diferença motiva nosso problema.

2.3 Teoria Espacial e eleições

A diferença entre os dois contextos de ação é reconhecida desde as contribuições de Black e Downs. No geral, em votos de comitê, o número de agentes é pequeno; eles são bem informados e a decisão costuma ter alta implicação para eles. Já em eleições de massa existem muitos eleitores; a informação sobre as alternativas é ambígua e os efeitos da decisão são difusos (MUNGER, 2015).

Essa distinção tem por corolário uma maior conformidade do voto em comitês com os *pressupostos de similaridade* entre um modelo de ator racional e uma situação de interesse alvo. O primeiro pressuposto de similaridade refere-se a propriedades dos agentes alvo: as crenças e preferências deles são independentes (BINMORE, 2008). Os outros três lidam com o contexto de ação alvo: a situação de ação é simples, tanto em estrutura quanto informacionalmente; os agentes têm incentivo para agir e informar-se; e há tempo disponível para os agentes aprenderem (BINMORE, 2007; PAGE, 2008). Esses pressupostos referem-se à capacidade do analista imputar os pressupostos do modelo do ator racional a grupos de agentes em determinadas situações. Usar o modelo do ator racional não tem por implicação acreditar que os agentes agem racionalmente em toda situação, mas somente que podemos justificar as simplificações do modelo na situação de interesse da análise.

A aplicação do modelo racional ao contexto do comportamento eleitoral é, assim, não trivial por uma razão: a escala. Como argumenta Binmore (2008) a aplicação do modelo da decisão racional em *large worlds* é problemática, pois provavelmente estaremos violando algum dos pressupostos de similaridade apresentados.

Desde seu surgimento o programa de pesquisa “Downsiano” reconhece a distância entre a aplicação ideal, do ponto de vista preditivo, e o sistema alvo, eleições. Downs (1999) dedica uma grande porção do livro à incerteza e a problemas de incentivos, e a obra

inspirou uma ampla literatura sobre comparecimento às eleições, tomada de decisão do eleitor e competição partidária (BENDOR *et al.*, 2011).

Em relação à tomada de decisão do eleitor há uma tensão entre a literatura em teoria formal e a literatura em psicologia política: a primeira costuma pressupor que agentes têm ideologias bem definidas e são bem informados, ou têm alguma noção probabilística, sobre as alternativas partidárias, algo contestado veementemente pela segunda (BENDOR *et al.*, 2011, p.5). A falta de conhecimento sobre temas/questões e a instabilidade dos posicionamentos dos respondentes nos *surveys* é um dos resultados recorrentes nas literaturas em opinião pública e psicologia política desde suas fundações (BERELSON, 1952; CONVERSE, 2006; ZALLER; FELDMAN, 1992; KUKLINSKI *et al.*, 2000).

A instabilidade nas respostas a *surveys* e a suscetibilidade dos cidadãos a *framing effects*⁶ levam Bartels (2003) a contestar o uso da noção de preferência como base para o estudo do nexos democrático, pois cidadãos não teriam preferências consistentes, coerentes ou estáveis. Ele argumenta, contudo, que os eleitores têm posicionamentos que são melhor teorizados como *attitudes*⁷.

Embora seja possível contestar a validade externa dos questionários que buscam demonstrar a instabilidade de posicionamento dos cidadãos (DRUCKMAN; LEEPER, 2012) e a relevância dos *framing effects* para a aplicação modelo do ator racional (GINTIS, 2016, p. 107), Bartels levanta um ponto incontornável: o pressuposto de preferências racionais não é inócuo, em especial no contexto eleitoral.

O pressuposto de que agentes têm preferências racionais sobre todas questões políticas é exigente do ponto de vista cognitivo. Contudo, não é necessário. Para aplicar o modelo geométrico de política em um contexto macro não é necessário supor que cada questão (*issue*) vá definir uma dimensão no espaço de alternativas. O necessário é que os agentes tenham *algum* posicionamento nas questões e que exista uma interrelação entre a resposta do eleitor entre posicionamentos, de forma que possamos descrever as atitudes dos agentes em todas as questões segundo a correlação com alguma dimensão latente (POOLE, 2005; LAVER, 2014). Poole e Daniels (1985) demonstram que 80% dos votos no congresso americano podem ser explicados por uma única dimensão latente (liberal-conservador). Já

⁶ *Framing effects* são “situações nas quais formas alternativas de apresentar uma questão política levam a diferentes respostas do público” (BARTELS, 2003, p.56).

⁷ Ele define atitude como uma tendência psicológica que é expressa pela avaliação de uma entidade particular com algum grau de aprovação ou desaprovação (BARTELS, 2003, p.52).

Benoit, Laver *et al.* (2006) encontra que no máximo três dimensões são necessárias para capturar a informação relevante sobre os posicionamentos dos eleitores, em um banco de dados de 47 países.

A preferência dos agentes nessas dimensões é construída a partir do posicionamento, das atitudes, considerações, opiniões e crenças deles num agrupamento de questões. Isso significa que as preferências dos eleitores são extrínsecas. Preferências intrínsecas são preferências irreduzíveis. Independem de mudanças do ambiente ou de alguma razão em particular. O agente i simplesmente prefere x a y . Já preferências extrínsecas dependem de um julgamento, uma crença, de que uma alternativa, é, em algum sentido, melhor que a outra. Preferências extrínsecas têm razões subjacentes e, portanto, possivelmente mudam quando ocorrem mudanças no ambiente (LIU, 2010; BINMORE, 2008).

Preferências extrínsecas violam o pressuposto de que as preferências e crenças dos agentes são independentes, o que complica a análise da situação de ação por meio do modelo do ator racional, dado que não podemos pressupor que elas são estáveis. No contexto da economia do bem-estar, por exemplo, Kenneth Binmore argumenta que os modelos do ator racional supõem preferências intrínsecas, na medida que “não ajudaria muito [...] introduzir uma reforma que todos aprovam se ela mudar o ambiente de uma forma que reverta as preferências de todos ” (BINMORE, 2008, p.6).

Como as preferências no contexto macro necessariamente são construídas a partir de posicionamentos num conjunto de questões, por definição, elas são extrínsecas. Logo, são, potencialmente, sensíveis a mudanças no ambiente. Tendo em vista tanto a complexidade informacional do contexto, quanto os baixos incentivos à busca de informação, isso vai significar que os agentes serão *incertos quanto às suas preferências*. Essa incerteza em relação às preferências e o baixo custo percebido da mudança permitem que modelos de dinâmicas de opinião possam ser usados para representar seu processo de formação e cristalização⁸. Convergimos assim para um argumento análogo ao da escola de Michigan de opinião pública: o direcionamento político, ou ideologia, do agente é resultado, ou construído, a partir de um “campo de atitudes” ou sistema de crenças, que no Capítulo 4 chamaremos de perfil ideológico, o qual por sua vez é explicável por meio da socialização do agente, a interação de suas atitudes com as atitudes dos pares (FIGUEIREDO, 2008).

⁸ Seria não controverso afirmar que poderíamos usar modelos de dinâmicas de opinião para modelar as mudanças de crenças dos agentes. O que estamos argumentando, contudo, é que é possível utilizá-los para modelar o surgimento de preferências ou ao menos de alternativas ou pontos preferidos.

No Capítulo 3 discutimos a literatura em dinâmicas de opinião, o que nós dá o arcabouço para modelar esse processo.

As preferências ideológicas dos cidadãos não são estáticas. Isso não significa, contudo, que estas necessariamente serão altamente instáveis. Como as preferências são construídas a partir de um conjunto de posicionamentos e crenças em várias questões, é de se esperar que elas sejam mais estáveis do que o posicionamento dos atores em cada questão específica (DRUCKMAN; LEEPER, 2012). Do ponto de vista macro, é de se esperar, desta forma, que a distribuição de preferências dos eleitores seja consistente. A Figura 2 mostra o autopoicionamento político, numa escala de 0 a 10 (esquerda-direita), de respondentes, cuja frequência de resposta é dada no eixo vertical,⁹ em seis edições do *European Social Survey*¹⁰, condiz¹¹ com essa expectativa:

Figura 2 – Evidência de estabilidade ideológica

Fonte: Marcelo Veloso Maciel, 2018. Dados do *European Social Survey*.

A escala do fenômeno eleitoral também afeta uma segunda categoria de agentes: os partidos. Estes também estão posicionados no espaço de alternativas X e competem pelos votos dos eleitores. Para os partidos, X é um espaço de plataformas. Para competirem

⁹ A cada edição uma nova amostra é selecionada.

¹⁰ Cujas página oficial é : <http://www.europeansocialsurvey.org/>

¹¹ Para questões metodológicas em relação a esses dados ver o Apêndice B.

têm de ser capazes de determinar qual o percentual de votos das posições nesse espaço. A literatura reconhece que talvez os partidos não sejam capazes de fazê-lo, adicionando a possibilidade de que eles sejam incertos quanto às preferências políticas dos eleitores (GLAZER; GROFMAN; OWEN, 1989; GROFMAN, 2004).

Como argumenta Page (2008) essa estratégia de modelagem consiste em ignorar a dificuldade da tomada de decisão e a complexidade do ambiente em que os agentes estão situados, para, assim, modelá-los como otimizadores sob incerteza. Para a competição política espacial com dimensão $n > 1$, argumentam Laver e Sergenti (2011), agir de maneira ótima é, contudo, impossível. Isto porque a competição política espacial é um caso particular de modelos de tesselação dinâmica. Eles argumentam que a competição política espacial pode ser pensada como um Jogo de Voronoi, onde n jogadores têm p pontos para inserir num espaço n -dimensional. Cada jogador insere um ponto em sequência buscando controlar o conjunto de regiões com o maior volume. No caso $n = 1$ esse jogo tem solução analítica, assim como nos modelos de competição espacial. Nos casos $n > 1$, contudo, não existe um sistema de equações que o resolva analiticamente nem há um limiar superior no tempo necessário para resolvê-lo computacionalmente (LAVER; SERGENTI, 2011, p.24).

A implicação metodológica e comportamental desse resultado é que somos levados a modelar os partidos necessariamente agindo segundo heurísticas e se movimentando no *electoral landspace* de forma adaptativa (KOLLMAN; MILLER; PAGE, 1998; MARCHI, 1999). Isso abre a possibilidade teórica de que os partidos fiquem presos em picos locais. Do ponto de vista empírico, Lorenz (2017) e Flache *et al.* (2017) apontam os seguintes fatos estilizados sobre as distribuições de autoposicionamento ideológico, ilustradas na Figura 3: há um pico central dominante; há uma tendência para a existência de *clusters* não centrais, mas não extremos; e há uma tendência a picos nos extremos¹².

¹² Para as distribuições de posicionamentos ideológicos de todos os anos do *European Social Survey* ver (https://github.com/marcelovmaciel/Projeto/blob/master/data-analysis/02-loadall_ess.ipynb).

Figura 3 – Distribuição de posicionamento ideológico de respondentes em 20 países

Dado que as eleições são o principal mecanismo de conexão entre cidadãos e governo nas democracias liberais (DAHL, 1989) e uma vez que a sobrevivência dos partidos na competição eleitoral depende da sua capacidade de captar o voto dos eleitores, podemos concluir que o formato da distribuição das preferências dos eleitores é central para o estudo do nexa democrático.

Temos, desta forma, duas diretrizes para o estudo. Do ponto de vista micro, podemos modelar os pontos ideais dos agentes segundo um modelo de dinâmicas de opinião. Esse é o nosso ponto de partida. Do ponto de vista macro, aspiramos que nossos modelos consigam gerar distribuições que sejam plausíveis do ponto de vista empírico, dado que o formato delas importa. Esse é o nosso ponto de referência.

3 Dinâmicas de Opinião

Nesse capítulo fazemos uma revisão bibliográfica da área de Dinâmicas de Opinião. Definimos a área, o que são modelos baseados em agente e quais os constituintes típicos de um modelo de OD. Depois apresentamos modelos que inspiraram uma gama de modificações e extensões. Na seção seguinte discutimos algumas questões teóricas referentes à atualização da opinião dos agentes e concluímos o capítulo com uma discussão de nossa abordagem.

3.1 Definição da área

OD é uma área que pode ser definida a partir de 3 elementos. Primeiramente, sistemas alvo, fenômenos de interesse, em comum delimitados pela pergunta central: quais elementos determinam se um grupo de agentes chega ao consenso sobre algo, ou ao invés disso persistem em discórdia? (CASTELLANO, 2012)¹. Segundo, um conjunto de modelos que partilham elementos constitutivos, particularmente fazendo uso da técnica da Modelagem Baseada em Agentes (ABM), e, em alguma medida, de *insights* e técnicas da Física Estatística (GALAM, 1990). Terceiro, uma comunidade de pesquisadores que partilham do interesse no objeto, fazem uso de referenciais e técnicas compartilhadas e se reconhecem como membros dessa comunidade.

Na área há a aceitação de um significado amplo e abstrato de opinião como uma característica de um agente que pode ser mudada com pouco custo (CASTELLANO, 2012, p.312). Isso permite com que os pesquisadores visem sistemas alvos tais como voto, ciência, cultura, difusão de tarifas, dentre outros (KOWALSKA-PYZALSKA *et al.*, 2013; MARTINS, 2015; AXELROD, 1997; GALAM, 1990). Essa gama de aplicações está relacionada com a base disciplinar dos pesquisadores, envolvendo pessoas de áreas como Física, Sociologia, Ciência Política, Economia, Psicologia Social, dentre outras, o que nos permite considerar a área como um subgrupo da Sociofísica (GALAM; GEFEN; SHAPIR, 1982; GALAM, 2012).

¹ Essa pode ser pensada como a pergunta *fundacional* da área (FLACHE *et al.*, 2017).

3.2 Modelagem Baseada em Agentes e Dinâmicas de Opinião

ABMs podem ser definidos como modelos que envolvem agentes discretos nos quais estes seus atributos e possivelmente um ambiente são definidos algoritmicamente (SAYAMA, 2015)². Segundo Marchi e Page (2014), num ABM existem três noções primitivas: os *atributos*, os *estados* e as *configurações*. Os atributos dos agentes são o conjunto de propriedades que cada agente i tem. Os estados dos agentes são os valores de seus atributos num determinado tempo t . Já as configurações são as coleções de todos os estados dos agentes num modelo. Outros conceitos importantes em ABM, particularmente para sua análise, são os de execução, repetição e iteração. Uma iteração é a aplicação dos procedimentos do modelo, após a sua inicialização. O número de iterações de uma repetição da simulação define o seu “comprimento”. Uma repetição é a execução do modelo sob uma semente aleatória. Por fim a execução (*run*) do modelo é quando o rodamos para um conjunto fixo de parâmetros de *input*, para uma parametrização (LAVER; SERGENTI, 2011). A análise de ABMs costuma envolver a repetição de diferentes execuções (diferentes parametrizações) sob um número t de iterações³

ABM é uma técnica flexível: podemos construir modelos metafóricos com objetivo de auxiliar o desenvolvimento de intuição segundo a elucidação de princípios; ou de alta-fidelidade, com dezenas de atributos e um ambiente incluindo casas, escolas, sistemas de transporte, entre outros, com o objetivo de avaliar contrafactuais próximos a determinados casos concretos (MARCHI; PAGE, 2014; EPSTEIN, 2006).

Segundo Sayama (2015, p.430-1), ABMs têm as seguintes propriedades típicas:

- agentes podem ter estados internos;
- agentes podem ser espacialmente localizados;
- agentes podem perceber e interagir com o ambiente;
- agentes podem interagir segundo regras pré-definidas;
- agentes podem ser capazes de aprender e adaptar-se;
- agentes podem interagir com outros agentes;
- AMBs muitas vezes não têm supervisores/controladores centrais;
- ABMs podem produzir comportamentos coletivos não triviais.

² ABMs costumam ser implementados como simulações num computador, embora existam modelos baseados em agentes que historicamente não tenham sido diretamente em computadores, como os modelos de Schelling e de Sakoda (HEGSELMANN, 2017).

³ Como isso é feito no presente trabalho é discutido no Capítulo 4.

Tendo em vista essas propriedades, ABMs são particularmente úteis para o estudo de sistemas complexos (WILENSKY; RAND, 2015), tendo em vista sua capacidade de incluir redes e espaço; seu potencial de ligar múltiplos domínios e de incluir uma maior heterogeneidade de agentes; além de seu foco na robustez de resultados (MARCHI; PAGE, 2014; WILENSKY; RAND, 2015). ABMs são assim capazes de conectar como propriedades macro surgem, emergem, a partir das regras de interação e atributos dados a unidades discretas, os agentes (NORTH; MACAL, 2007). Essas propriedades são ditas emergentes à medida que caracterizam o sistema e não seus componentes. O conceito, modernamente, é relativo tanto ao quadro conceitual quanto às expectativas dos pesquisadores sobre quais propriedades sistêmicas poderíamos deduzir a partir das propriedades das partes (EPSTEIN, 2006). Propriedades emergentes são aquelas que resultam da interação entre as partes do sistema, mas que não seriam a priori dedutíveis unicamente das propriedades delas. Em sistemas onde há emergência a conexão entre as propriedades sistêmicas e das partes é feita pela compreensão do papel da *interação* entre as partes. Em sua forma mais simples, propriedades emergentes condicionam indiretamente o comportamento dos agentes. Se os agentes tiverem consciência dessa propriedade sistêmica temos, portanto, um *feedback* direto, ao invés de indireto, entre agentes e propriedades sistêmicas, o que Squazzoni (2008) chama de emergência de segunda ordem. No nosso trabalho lidamos somente com *feedbacks* indiretos, ou emergência de primeira ordem. Além disso, tendo em vista sua flexibilidade, modelos baseados em agentes são úteis quando sistemas ou situações de ação são complicados demais para serem modelados por meio de modelos matemáticos tradicionais (KOLLMAN; MILLER; PAGE, 2003). Não por acaso, ABMs são amplamente usados em OD (CASTELLANO, 2012; FLACHE *et al.*, 2017).

Que elementos constituem os modelos de OD? Podemos delimitar um modelo de dinâmicas de opinião da seguinte forma: agentes conectados possuem opiniões como variáveis e interagem segundo regras que explicam a mudança ou manutenção das opiniões individuais sob efeito da interação com outros agentes ou outras fontes (como a mídia) (SÎRBU *et al.*, 2017). Os agentes num modelo em OD têm então uma *opinião*, uma *estrutura de interação* e uma *regra de atualização* de sua opinião.

A opinião dos agentes pode ser representada como uma variável ou conjunto de variáveis, que por sua vez podem ser discretas ou contínuas. Já a estrutura de interação consiste no conjunto de agentes cujas ações e propriedades podem afetar a opinião de um agente i (PAGE, 2008).

Podemos dividir a estrutura de interação numa *topologia* de interação e numa *regra de interação*. A topologia de interação define quais agentes estão conectados com i , e podem, potencialmente, afetá-lo. A regra de interação define como i interage com os agentes desse conjunto (seus “vizinhos”). Em OD as regras de interação definem qual a relação que o agente i tem com seus vizinhos: se interage com um vizinho por vez, uma interação em díade, ou com algum subconjunto de seus vizinhos, uma interação em grupo. Por fim, a regra de atualização define sob qual regra a opinião do agente i muda do tempo t para o tempo $t + 1$. Importante notar que diferenciamos a regra de interação da regra de atualização. A primeira define como o agente interage com os vizinhos. Já a segunda está relacionada como essa interação muda o estado do agente, no caso sua opinião. É possível que uma mesma regra de interação seja combinada com diferentes regras de atualização.

3.3 Modelos canônicos

Adaptações do Modelo de Ising são os modelos mais fundamentais na área. O modelo de Ising é um modelo paradigmático da Mecânica Estatística, usado para representar o processo de magnetização de materiais⁴. Nestas adaptações, variáveis discretas, *spins*, com valores $s = \pm 1$, estão localizadas num grafo e têm uma tendência a alinhar-se com seus vizinhos. Se a maioria tem $s = +1$, o spin muda seu valor para $+1$; se a maioria tem $s = -1$, o spin muda seu valor para -1 ; se houver empate, o spin muda seu valor com probabilidade $\frac{1}{2}$ (CASTELLANO, 2012; SOLÉ, 2011). No contexto de OD é o seguinte: o spin é um agente; sua opinião pode ter os valores $+1$ ou -1 ; um agente interage com todos seus vizinhos por passo de tempo; ele assume a opinião da maioria deles.

Um modelo parecido com o anterior é o *Voter* (HOLLEY; LIGGETT, 1975). Neste cada agente tem uma opinião binária ± 1 ; e a cada passo um agente é selecionado aleatoriamente e assume a opinião de algum de seus vizinhos. Difere do modelo anterior, portanto, na regra de interação (díade ao invés do grupo inteiro) e de atualização (assume o valor do vizinho ao invés da maioria deles).

Nos modelos inspirados em Ising e no modelo “Voter” a direção de influência é dos vizinhos para o agente enquanto nos dois modelos seguintes ela é dos agentes para

⁴ O modelo de Ising é um modelo paradigmático de sistemas com muitas partes interagindo levando a uma transição de fase, a uma mudança de comportamento qualitativo do sistema. Sendo assim, é aplicado em vários contextos além da sua concepção original, como mercados financeiros, sistemas ecológicos e dinâmicas de opinião (SOLÉ, 2011)

os vizinhos (STAUFFER, 2003). No modelo da Regra de Maioria a interação é: a cada unidade de tempo, um grupo de tamanho r é selecionado aleatoriamente e todos os agentes mudam sua opinião para a opinião da maioria do grupo (GALAM, 1990; GALAM, 2012). O tamanho r pode ser fixo ou ser tirado de alguma distribuição a cada passo. Se r for par podem ocorrer empates nos grupos, de forma que ou o grupo escolhe uma das opiniões com probabilidade $\frac{1}{2}$, ou introduz-se um viés e, toda vez que houver empate, o grupo muda para uma das opiniões (GALAM, 2012; GALAM, 1986). O modelo Sznajd também é bastante discutido na literatura (SZNAJD-WERON; SZNAJD, 2000; SÎRBU *et al.*, 2017; CASTELLANO, 2012). Em sua versão original, e mais simples, os agentes estão localizados em uma grade unidimensional. A cada passo, um par ij de vizinhos é selecionado e, se sua opinião for igual, os outros vizinhos de i e j mudam a opinião para a opinião de convergência⁵.

Todos os modelos até agora representaram opiniões como uma variável que pode tomar valores binários. Além disso a regra de atualização dos modelos pressupõe uma interação assimilativa: indivíduos conectados por meio de uma relação estrutural influenciam uns aos outros em direção à diminuição da diferença de suas opiniões (FLACHE *et al.*, 2017). O modelo de Axelrod (1997) difere em ambos os aspectos. Cada agente tem por opinião um vetor F de componentes $(\sigma_1, \dots, \sigma_f)$ (KLEMM, 2003). Esses σ podem tomar valores inteiros de 0 a 9. Os componentes são as características culturais dos agentes e seus possíveis valores são seus traços culturais (GOMES, 2014). O modelo considera interação entre pares de vizinhos, os quais interagem da seguinte forma: o agente i sorteia algum dentre os seus f componentes. Se o vizinho, j , tiver o mesmo traço nesse componente eles interagem. Isso faz com que eles interajam com uma probabilidade proporcional ao número de traços que têm em comum. Por exemplo, se i tem uma opinião igual a 82330 e seu vizinho j tem uma opinião 67730, eles têm 40% de chance de interagirem. Se eles interagirem, i troca um dos traços em que difere por um dos traços de j (AXELROD, 1997). Nesse modelo pessoas similares têm uma probabilidade maior de interagirem do que pessoas distintas, mas, uma vez que a interação ocorre, elas ficam mais parecidas. Sendo assim, o modelo de Axelrod pode ser considerado um modelo de assimilação enviesada: só

⁵ No original existe uma segunda regra: Se eles discordarem, i adota a opinião do outro vizinho, e j faz o mesmo. Contudo, isso muda o comportamento do modelo e a literatura costuma suprimir essa segunda regra na descrição do modelo (CASTELLANO, 2012; STAUFFER, 2003).

indivíduos suficientemente similares podem influenciar uns aos outros na redução de suas diferenças⁶ (FLACHE *et al.*, 2017).

Um outro modelo de assimilação enviesada é o Modelo de Deffuant-Weisbuch (DEFFUANT *et al.*, 2000). Nele cada agente i tem opinião inicial $o_i \in [0, 1]$. Dois agentes são escolhidos aleatoriamente, e i é influenciado por j se $|o_i - o_j| < \epsilon$. Se isso ocorrer suas opiniões se aproximam de acordo com um parâmetro $0 < \mu \leq 0.5$, de forma que: $o_{i,t+1} = o_{it} + \mu(o_{jt} - o_{it})$ e $o_{j,t+1} = o_{jt} + \mu(o_{it} - o_{jt})$. Esse modelo é particularmente relevante para o presente trabalho por duas razões: a opinião é contínua, assim como a representação das “utilidades” dos agentes em Teoria Política Espacial⁷; e ϵ pode ser interpretado como parte da regra de atualização, o que faz modelo os agentes tenham viés de confirmação (FLACHE *et al.*, 2017).

Quando ϵ é interpretado como parte da regra de interação, temos o princípio da homofilia: padrões estruturais de interação social levam pessoas a ter maior probabilidade de interagirem com pessoas similares a elas (MCPHERSON; SMITH-LOVIN; COOK, 2001). Quando ϵ é interpretado como parte da regra de atualização, temos o fenômeno do *viés de confirmação*: a tendência das pessoas de dar maior peso a informações que confirmem suas crenças anteriores (NICKERSON, 1998).

Huckfeldt, Ikeda e Pappi (2005) argumenta que indivíduos escolhem redes de discussão com razões distintas às políticas (como interesses profissionais e hobbies) e acabam interagindo com indivíduos cujas filiações partidárias são distintas. Desta forma, o papel da homofilia em política é atenuado. Já o vies partidário dos cidadãos, o viés de confirmação no tocante a questões políticas, é um resultado estabelecido na literatura em opinião pública e psicologia política, e imprescindível para a modelagem generativa de opinião pública (BARTELS, 2002; FLYNN; NYHAN; REIFLER, 2017; LODGE; TABER, 2013).

⁶ Um terceiro tipo de modelo elencado por Flache *et al.* (2017), além dos modelos de influência social assimilativa e modelos com influência enviesada, são os modelos de influência repulsiva: quando agentes são muito distintos em opinião, a interação pode levá-los a um aumento dessa diferença, tornam-se mais distantes.

⁷ Na verdade, ligar a literatura de OD com funções de utilidade em economia e com a noção geométrica de política é a justificativa dada por Deffuant *et al.* (2000) para considerar opiniões como contínuas.

3.4 Regra de Atualização e processamento de informação

Como lembra Dirk Helbing, não existe uma única forma de modelar agentes interagindo em sistemas sociais complexos (HELBING, 2010). Os modelos clássicos em OD têm uma abordagem que Helbing chama de fisicalista: abstraem as interações sociais ao ponto de serem estudadas como um modelo de “partículas”. Em OD essa abordagem é refletida na forma como se modela a regra de atualização: abstrai-se o processamento de informação, a cognição dos agentes. Isso, como frisa Helbing, não é uma falha dos modelos. Paul Ormerod defende que o *null model* em sistemas sociais complexos deveria ser o de um *zero intelligence actor*, pois a complexidade dos sistemas nos permitiria modelar os agentes como se fossem átomos (ORMEROD, 2008; BENTLEY; ORMEROD, 2012).

Não obstante, um conjunto de trabalhos em OD tem buscado abrir a “caixa-preta” da cognição dos agentes e tratam a atualização de opinião como resultado de um processamento de informação explicitamente modelado (FLACHE *et al.*, 2017; JAGER, 2017). O modelo Polias de Brousmiche *et al.* (2016), o modelo Innomind de Schröder e Wolf (2017) e o modelo Lodge-Taber (KIM; TABER; LODGE, 2010; KIM, 2011) de processamento dual e raciocínio motivado são exemplos dessa tendência.

Se pensarmos num espectro possível de abordagens para a cognição dos agentes, ilustrado na Figura 4, esses modelos estão posicionados no extremo oposto aos modelos fisicalistas. Enquanto os modelos fisicalistas abstraem totalmente o que se passa na cabeça dos agentes, os modelos (neuro)cognitivos buscam representar a arquitetura cognitiva que alicerça as atitudes e crenças deles (KIM; TABER; LODGE, 2010).

Figura 4 – Espectro de abordagens no tocante à cognição dos agentes

Fonte: Marcelo Veloso Maciel, 2018.

Modelos cognitivamente “densos” permitem que analisemos como processos de influência social estão microfundamentados em processos mentais subjacentes e são um fronte dentre os trabalhos que buscam aumentar o realismo das simulações sociais (JAGER, 2017; EPSTEIN, 2014; CONTE; ANDRIGHETTO; CAMPENNL, 2013). Contudo, como

ressalta Jonathan Bendor, à medida que a Ciência Política busca modelar macrofenômenos, ela “deve ser mais implacável em relação aos micropressupostos do que microcampos relacionados (como ciência cognitiva)” (BENDOR, 2010, p.45). Quanto mais complicados nossos modelos menor controle temos sobre o elemento responsável pelos resultados e mais dados precisamos para a sua calibração e validação (MARCHI, 2005; BENDOR, 2010). Como argumentado por Zaller (1992), a estratégia metodológica para modelar a opinião pública, um fenômeno social de larga escala, envolve incorporar no modelo somente os aspectos do processamento de informação que têm relevância para a compreensão das dinâmicas do fenômeno, ao invés de buscar desenvolver modelos que cheguem o mais próximo o possível dos detalhes da mente humana⁸.

Martins (2012) apresenta um *framework* para modelar Dinâmicas de Opinião que é cognitivamente mais “denso” que os modelos fisicalistas, mas sem buscar modelar as bases neurocognitivas de processamento de informação. O *framework* está fundamentado no uso da inferência bayesiana como base da regra de atualização dos agentes. Embora seja bem documentado que as pessoas não seguem fielmente o princípio da racionalidade bayesiana apresentado no primeiro capítulo, um conjunto de trabalhos em psicologia e ciência cognitiva vem, nos últimos anos, defendendo a possibilidade de que sejamos “bayesianos imperfeitos” (GRIFFITHS; TENENBAUM, 2006; FUJIKAWA, 2007; BAKER *et al.*, 2017; GINTIS, 2016). Usar um framework bayesiano é, desta forma, uma aproximação e permite a construção de modelos de dinâmicas de opinião de uma forma fundamentada num princípio comum, algo particularmente relevante numa área em que há a proliferação de modelos *ad-hoc* (FLACHE *et al.*, 2017; JAGER, 2017).

Martins (2012, p.214) oferece o seguinte passo a passo para a construção de um modelo de dinâmicas de opinião com base num *framework* bayesiano:

1. Identificar uma questão sob debate e chamá-la de x . x pode ser discreto ou contínuo.
2. Cada agente i tem uma opinião subjetiva sobre x e essa opinião é representada pela distribuição de probabilidade $f_i(x)$.
3. Ocorre comunicação: a comunicação é a declaração de um valor A_j pelo agente j de tal forma que $A_j[f]$ é um funcional de $f_j(x)$.
4. Os agentes tem que ter em sua mente uma relação entre o verdadeiro valor de x , x^* , e o valor declarado A_j . Isso é dado pela distribuição de probabilidade $P(A_j|x^*)$.

⁸ No contexto da análise institucional um argumento equivalente é feito por Ostrom (1990).

Essa verossimilhança mensura a chance que um vizinho j comunique A_j dado que x^* seja o valor correto.

5. Dado o *prior* $f_i(x)$ a opinião posterior $f_i(x|A_j)$ é dada por $A_i[f_i(x|A_j)]$ que é a nova opinião de i .

A aplicação desse *framework* no caso de opiniões contínuas incorpora o mecanismo de viés de confirmação presente no modelo Deffuant-Weisbuch, encontra resultados qualitativamente semelhantes e ainda tem resultados adicionais (MARTINS, 2009). Dado que o modelo representa a atualização de uma variável contínua, incorpora viés de confirmação e fundamenta a regra de atualização num *framework* bayesiano de processamento de informação ele será a base do nosso trabalho.

Nele os agentes interagem num grafo completo e a regra de interação é uma diáde interagindo a cada passo de tempo. A opinião inicial dos agentes é dada por uma probabilidade subjetiva:

$$f_i(\theta) = \frac{1}{\sqrt{2\pi}\sigma_i} e^{-\frac{(\theta-o_i)^2}{2\sigma_i^2}} \quad (1)$$

Onde $o_i = E_i[\theta]$, de forma que E_i é o valor esperado que o agente associa a θ . Para incluir viés de confirmação na regra de atualização, Martins (2009) introduz uma probabilidade p que o outro agente saiba algo sobre θ , que tenha uma opinião plausível e que vale a pena ser levada em conta; e vai ter uma chance $1 - p$ que o outro agente não tenha informação sobre θ de forma que a verossimilhança de j estar correto é dado por $f(o_j|\theta) = pN(\theta, \sigma_j^2) + (1 - p)U(0, 1)$.

Temos então que a distribuição da nova opinião é dada por uma mistura de duas normais com médias diferentes, que é proporcional à multiplicação da verossimilhança e a distribuição a priori normal de i :

$$f(\theta|o_j) \propto p e^{-\left(\frac{1}{2\sigma_i^2}\right)[(\theta-o_i)^2+(o_j-\theta)^2]} + (1 - p) e^{-\frac{(o_i-o_j)^2}{(2\sigma_i^2)}} \quad (2)$$

Se calcularmos o $E_i(\theta)$ da expressão anterior temos a nova opinião:

$$o_i(t+1) = p \frac{o_i(t) + o_j(t)}{2} + (1 - p^*)o_i(t) \quad (3)$$

Onde:

$$p^* = \frac{p \frac{1}{\sqrt{2\pi}\sigma_i} e^{\left(-\frac{o_i(t)-o_j(t)}{2\sigma_i^2}\right)^2}}{p \frac{1}{\sqrt{2\pi}\sigma_i} e^{\left(-\frac{o_i(t)-o_j(t)}{2\sigma_i^2}\right)^2} + (1-p)} \quad (4)$$

Importante notar que, embora o modelo use a Regra de Bayes para derivar como o agente atualiza sua opinião, nele o agente não é perfeitamente racional. A regra de bayes foi usada para criar uma regra de atualização plausível, mas a verossimilhança de um agente perfeitamente racional envolveria considerar toda a informação possivelmente relevante, por exemplo, se j tem um interesse estratégico em declarar um determinado o_j ou como o_j é resultado da interação de j com outros agentes. Ademais, suponha que i e j interagem num tempo t_a e depois num tempo t_b . Um agente perfeitamente racional corrigiria pela repetição da interação (ACEMOGLU; OZDAGLAR, 2011), já no modelo de Martins (2009) o agente age segundo a heurística dada pela Equação 2.4. Nele, portanto, os agentes são “imperfeitamente” bayesianos. Com essa regra de atualização, o modelo já recupera os resultados dos modelos de confiança limitada. Contudo, também é possível considerar o caso em que a incerteza dos agentes é atualizada:

$$\sigma_i^2(t+1) = \sigma_i^2(t)\left(1 - \frac{p^*}{2}\right) + p^*(1-p^*)\left(\frac{o_i(t) - o_j(t)}{2}\right)^2 \quad (5)$$

Como demonstra Martins (2009) essa equação faz com que os agentes fiquem mais certos de suas opiniões. Isso é relevante do ponto de vista da modelagem generativa de opinião pública. Kuklinski *et al.* (2000) encontram que um grande percentual, em média 60%, dos respondentes em um *survey* por telefone, sobre questões factuais da agenda política americana da época, são confiantes em suas crenças. Ademais, encontram uma correlação entre confiança e partidarismo. É interessante, portanto, incorporar não só a dinâmica da opinião dos agentes, mas também o papel da incerteza quanto às crenças nessa dinâmica ⁹.

⁹ Para um trabalho em OD que lida com incerteza, mas de maneira “fiscalista” ver Deffuant *et al.* (2002).

4 Modelo

4.1 Entidades e processos

Dado o que foi discutido nos Capítulos 1 e 2, o trabalho está fundamentado no diálogo entre a Teoria Política Espacial e a área de Dinâmicas de Opinião. Não temos por propósito um modelo que seja preditivo, mas que capture microfundamentos relevantes, como viés de confirmação e confiança nas crenças e gere distribuições de preferência plausíveis, no sentido delimitado no Capítulo 1. O trabalho propõe, portanto, um modelo que contribua para uma agenda que busque abrir a caixa-preta do processo de socialização que leva a cristalização de direcionamentos, ou posicionamentos, ideológicos.

Como discutido no Capítulo 1, a teoria geométrica de política modela as preferências dos agentes como relações em um espaço contínuo de alternativas. Essas preferências, em ambientes macro são construídas por meio da agregação das atitudes, crenças, posicionamentos, ou simplesmente opiniões dos agentes em diferentes questões (*issues*). As preferências dos agentes numa dimensão são, assim, o sumário de um perfil ideológico do agente sobre questões. Pretendemos gerar a distribuição de pontos ideais, as posições preferidas pelos agentes no espaço de alternativas, mas não precisamos especificar qual a função de utilidade centrada nestes pontos, já que não é interesse do trabalho modelar a tomada de decisão que os pressuporia, por exemplo, a escolha de um candidato. É possível atribuir diferentes funções de utilidade aos agentes, mas o pressuposto modal é que a função vai ter um máximo e será simétrica (EGUIA, 2013; CARROLL *et al.*, 2013). Como não é um modelo de tomada de decisão, mas, sim, um modelo de surgimento de posicionamentos ideológicos, não é necessário adicionar mais um elemento, funções de utilidade, que simplesmente alargaria o espaço de parâmetros e não seria utilizado na simulação. Não obstante, modelos futuros que busquem ligar, por exemplo, a distribuição de preferências com a escolha de candidatos/partidos poderiam fazer essa atribuição.

Pensar os agentes como tendo pontos ideais derivados de posicionamentos em questões tem por base dois fundamentos. O primeiro é que esse elemento a mais, em comparativo aos modelos de Deffuant *et al.* (2000) e de Martins (2012), nos permite ser mais condizentes com a literatura discutida no Capítulo 1 em contraposição à equiparação do ponto ideal a uma opinião. Essa equiparação passaria por cima da distinção entre crenças e preferências (LIST; PUPPE, 2009). Entretanto, em certos contextos, em particular

nos macro-políticos, é possível abdicar da separação estrita entre esses dois conceitos e pensar a possibilidade de que alternativas sejam elencadas com base em “atitudes” prévias (BINMORE, 2008; LAVER, 2014). Os pontos ideais dos agentes vão mudar ao longo da simulação, mas isso ocorre devido à mudança nas suas atitudes. É uma mudança assim indireta e condizente com a noção de que a ideologia do agente é um atributo extrínseco. O segundo fundamento é que essa modificação tem por implicação a capacidade de adicionar outros elementos à dinâmica do modelo.

Sendo assim, cada agente na nossa população vai ter por atributo um perfil ideológico¹ I , onde $I_i = (f_i(\theta_1), \dots, f_i(\theta_n))$. Os elementos de I são as crenças dos agentes em cada questão. Seguindo Martins (2012), vamos pressupor que os agentes têm uma probabilidade subjetiva sobre cada questão θ , um valor esperado da opinião $o_i = E_i[\theta]$ e incerteza $\sigma_i^2 = E[\sigma^2] - E_i[\theta]^2$ associados. O ponto ideal x do agente vai ser a média aritmética ($x_i = \frac{1}{n} \sum_{k=1}^n o_k$) das opiniões dele em I . Os pontos ideais são implementados, portanto, como opiniões médias. Do ponto de vista da implementação o atributo I é reduzido a um conjunto de pares $I_i = ((o_{i,1}, \sigma_{i,1}^2), \dots, (o_{i,n}, \sigma_{i,n}^2))$, sendo σ^2 global, o mesmo para todo i . Logo, $\sigma_i = \sigma$. Consideraremos também uma proporção de agentes nos quais uma das questões tem σ próximo a zero². Se seguirmos Deffuant *et al.* (2000) e usarmos uma distribuição uniforme ($U[0,1]$) para gerar os posicionamentos dos agentes na condição inicial quanto mais vezes fizermos o sorteio dos o_i (quanto maior o número de questões), pela Lei dos Grandes Números, mais centrada a média aritmética vai ser do valor esperado da distribuição (0.5). Isso significa que já na condição inicial os agentes seriam de centro. Para que isso não ocorra associamos para cada agente uma distribuição Beta, com α s e β s entre 1.1 e 100.

Do ponto de vista da implementação, dividimos os intervalos de valores $[1.1, 100]$, para α e β , em N valores igualmente espaçados, onde N é o número de agentes da população, criando uma lista do tamanho da população de duplas (α, β) . Ou seja, temos duas listas, uma com valores de α entre 1.1 e 100 e outra com valores de β entre 1.1 e 100. Dividimos igualmente os intervalos de acordo com o tamanho da população. Por exemplo, se a população tem 10 agentes, então os valores de α e β são $[1.1, 12.0889, 23.0778, 34.0667, 45.0556, 56.0444, 67.0333, 78.0222, 89.0111, 100.0]$. Misturamos as listas para que os agentes

¹ Nisso o modelo aproxima-se do modelo de Axelrod (1997), no qual os agentes tem por atributo um conjunto de traços.

² Agentes “intransigentes” ou “inflexíveis” serão discutidos mais à frente.

tenham α_i e β_i distintos, e coletamos pares numa terceira lista. Um formato possível para essa lista é [(1.1, 56.0444), (23.0778, 34.0667), (45.0556, 100.0), (78.0222, 67.0333), (89.0111, 23.0778), (67.0333, 12.0889), (100.0, 78.0222), (56.0444, 1.1), (34.0667, 89.0111), (12.0889, 45.0556)]. O primeiro agente da população vai então ter uma distribuição Beta com parâmetros $\alpha, \beta = (1.1, 56.0444)$, o segundo com $\alpha, \beta = (23.0778, 34.0667)$ e assim em diante.

Destas distribuições sorteamos os valores de o_i iniciais para cada questão, de forma que os os de cada agente sejam correlacionados e as distribuições são centradas em diferentes pontos do espaço, como ilustrado na Figura 5:

Figura 5 – Distribuições Beta para 50 agentes

Fonte: Marcelo Veloso Maciel, 2018.

A cada iteração da simulação um dos agentes vai ser escolhido e vai interagir com um de seus vizinhos, a princípio num grafo completo imposto exogenamente (estabelecemos na condição inicial quais os vizinhos). Quanto à implementação, criamos um grafo de tamanho igual ao tamanho da população e fazemos com que cada agente dela tenha como um de seus atributos um conjunto de vizinhos igual ao de um vértice do grafo. A interação é em diádes, assíncrona (os agentes atualizam seus atributos em momentos distintos) e sequencial (um agente atualiza por vez) (WILENSKY; RAND, 2015). A dependência

dos resultados em relação ao número de agentes e de crenças vai ser explorada. Estamos interessados nas alterações a longo prazo (em termos de iterações) da configuração dos x sob diferentes combinações de parâmetros, tendo em vista as interações dos agentes (ACEMOGLU; OZDAGLAR, 2011).

Quando os agentes interagem, o agente i atualiza sua opinião em alguma³ questão segundo as equações (3) e (4), apresentadas no Capítulo 3. A questão a ser “debatida” vai ser definida por meio de um sorteio sem viés. Se o agente tem uma lista indexada l de opiniões sortecemos um índice que determina qual a questão de debate. Nesse sorteio cada índice tem igual probabilidade de ser selecionado. Dado que os agentes agora têm um conjunto de opiniões, é plausível considerar que um conjunto de agentes tenha determinadas opiniões em que eles tenham maior certeza, identificação ou centralidade para o seu perfil ideológico. Sendo assim, na condição inicial, alguma proporção de agentes tem uma questão no seu perfil I cujos σ associados são aproximadamente zero. Com isso buscamos analisar o papel de agentes “inflexíveis” na dinâmica populacional. A proporção de agentes intransigentes ou inflexíveis é, assim, um parâmetro da simulação.

Os agentes também vão reconsiderar suas opiniões e certezas sobre as questões segundo um ruído. Do ponto de vista teórico, estamos considerando a possibilidade de fatores não relacionados à influência social levarem o agente a mudar seu posicionamento sobre questões (FLACHE *et al.*, 2017; LORENZ, 2017). Do ponto de vista metodológico, Macy e Tsvetkova (2015) argumentam que pequenas perturbações no comportamento local dos agentes podem levar a mudanças drásticas nas propriedades sistêmicas. Consideram que adicionar ruído pode eliminar equilíbrios frágeis, o que reduz o conjunto de resultados e tornando-os mais previsíveis; e, embora aumente a heterogeneidade local, isso pode acabar facilitando interações sociais que reduzem a diversidade global (MACY; TSVETKOVA, 2015, p.323). A nova opinião $o(t + 1)$ é igual a $o(t) + r$, em que r é retirado de uma distribuição normal de média 0 e desvio padrão ρ , um parâmetro da simulação. No caso em que o agente é intransigente na questão ele não será sujeito ao efeito do ruído ⁴

³ Uma outra implicação possível, a ser adicionada em trabalhos futuros, é considerar um viés nessa seleção, o que representaria saliência no sentido dado por Zaller e Feldman (1992): a qual questão os agentes estão dando atenção, qual questão está mais acessível na memória deles.

⁴ Uma outra opção seria que agentes intransigentes sejam *menos* afetados pelo ruído. Optamos pela mais simples.

4.2 Parâmetros-Chave

Os parâmetros-chave para configuração e inicialização do modelo, cujos valores seguem Martins (2008), Deffuant *et al.* (2000) e Lorenz (2017), são:

- A população de $500 < N < 5000$ agentes;
- O número de questões $1 \leq n_{\text{issues}} \leq 10$;
- As incertezas $0.01 \leq \sigma_i \leq 0.5$;
 - Agentes intransigentes vão ter uma de suas opiniões com incerteza próxima a zero ($1e - 20$);
- O parâmetro de confiança $0.1 \leq p \leq 0.99$;
- A proporção de agentes intransigentes $0.0 \leq (p_{\text{intran}}) \leq 0.1$;
- O parâmetro de reconsideração $0.0 < \rho \leq 0.1$, onde ρ é o desvio padrão de uma Normal de média 0:
 - Isso significa que o ruído, r , é sorteado a partir de uma normal $N(0, \rho)$, de forma que $o(t+1) = o(t) + r$;
 - * Se $o(t) + r > 1$ então $o(t+1) = 1$;
 - * Se $o(t) + r < 0$ então $o(t+1) = 0$.

4.3 Inicialização e iteração

A inicialização da simulação depende dos parâmetros-chave apresentados. Na condição inicial temos uma população de N agentes que tem por atributos um conjunto de pares $I_i = ((o_{i,1}, \sigma_{i,1}^2), \dots, (o_{i,n}, \sigma_{i,n}^2))$, no qual o número de questões, n , é uma variável global, cada o é retirado de uma distribuição Beta(α, β), onde cada agente tem um α e um β próprio, com valores⁵ entre 1.1 e 100.

Voltando aos atributos dos agentes, o σ^2 é uma variável global de forma que $\sigma_i^2 = \sigma^2$; têm também por atributo um posicionamento ideológico, ou ponto ideal, $x_i = \frac{1}{n} \sum_{k=1}^n o_{i,k}$; e um conjunto de vizinhos, que depende de qual a rede os agentes estão. Uma determinada proporção de agentes vai ter um *único* $\sigma_i = (1e - 20) \approx 0.0$. Quantos agentes são

⁵ Parâmetros com valores ≤ 1 ou geram distribuições de formato uniforme, quando $\alpha = \beta = 1.0$, ou com formato de U. Quanto ao limiar superior, o valor de 100 permite que tenhamos agentes com distribuições centralizadas em ambos os extremos, dado que a média μ é dada por $\frac{\alpha}{\alpha+\beta}$, de forma que a média mínima é 0.011.

intransigentes em *uma* questão é dado por p_{intran} . Em qual questão serão intransigentes é aleatório, sorteado de seus perfis ideológicos (I).

Uma iteração da simulação, a passagem de t para $t + 1$, é dada pela aplicação de dois procedimentos: a atualização da opinião via influência social e a atualização aleatória. O procedimento de influência social é o seguinte: sorteamos um agente i da população. Então sorteamos um de seus vizinhos, agente j . Sorteamos uma das questões $k \in (1, \dots, n)$ de forma que temos os $(o_{i,k}, o_{j,k})$ e $(\sigma_{i,k}^2, \sigma_{j,k}^2)$ correspondentes à questão. Então o agente i atualiza $o_{i,k}$ segundo as equações (3) e (4). Essa regra é uma característica global da simulação, o que significa que a cada repetição todos os agentes atualizam suas crenças segundo a mesma regra. Ademais, temos o ruído. A cada iteração temos os efeitos da influência social e do ruído. Novamente escolhemos um agente da população. Sorteamos uma questão de forma que temos o e σ^2 correspondentes. Se o agente é intransigente naquela questão então ele não muda de opinião. Sorteamos um r retirado de uma distribuição normal $N(0, \rho)$ e atualizamos o de forma que $o(t + 1) = o(t) + r$. Os x_i , os objetos de interesse de análise, são atualizados sempre que ocorrerem mudanças nas crenças dos agentes.

4.4 Metodologia de Análise

Dentre as diversas formas de analisar um ABM, a análise de sensibilidade global se destaca como uma forma de ter uma compreensão ampla, geral, do comportamento do modelo (NORTH; MACAL, 2007). O primeiro passo da análise envolve, então, ter uma compreensão geral do comportamento do modelo para então passarmos para regiões particulares do espaço de parâmetros.

No entanto, o alto custo computacional de varrer esse espaço de parâmetros faz com que só seja possível realizarmos uma análise global, na maioria dos casos, se seguirmos métodos formais da literatura de análise de sensibilidade (RAILSBACK; GRIMM, 2012). Esses métodos trazem o benefício de determinar como selecionar subconjuntos de todas as combinações de parâmetros, reduzindo o número de realizações necessárias da simulação e de trazerem formas sistemáticas de interpretar os resultados (RAILSBACK; GRIMM, 2012).

Figura 6 – Evolução dos pontos ideais dos agentes ao longo de duas realizações. Parametrização: $N = 500, p = 0.9, \rho = 1e - 5, n_issues = 1, p_intran = 0.0$

Fonte: Marcelo Veloso Maciel, 2018.

Antes de discutirmos métodos de amostragem e análise, é necessário estabelecer uma medida do sistema para que possamos analisá-lo (RAILSBACK; GRIMM, 2012). Escolhemos o desvio padrão dos pontos ideais após 1.000.000 iterações como output para análise⁶, dado que nos diz o quão concentrados/dispersos são os pontos ideais da população e é uma medida usual de polarização⁷ (BRAMSON *et al.*, 2016). Uma outra opção de medida do sistema seria o número de opiniões finais distintas após as iterações, o que nos daria uma medida de “cobertura” do sistema: uma maior cobertura equivale a um número maior de posicionamentos distintos (BRAMSON *et al.*, 2016). Na Figura 7 a distribuição (b) tem maior cobertura dado que uma maior quantidade de espaço é preenchido.

Figura 7 – Distribuições com coberturas distintas

Fonte: Bramson *et al.* (2016)

Usar cobertura como medida não nos indica o quão diferentes são os valores ou se estão no centro ou extremos, mas captura a variedade de atributos (BRAMSON *et al.*, 2016, p.85). Contudo, teríamos que estabelecer um N base, pois de outra forma esse

⁶ Testamos diversas parametrizações com $n_issues = 1$ e observamos que, a partir de 50.000 iterações, a implementação replica os resultados de Martins (2009).

⁷ Bramson *et al.* (2016) discute e compara 9 diferentes medidas de polarização de atitudes.

parâmetro explica quase que totalmente o valor do *output* a ser analisado pela análise de sensibilidade.

No primeiro gráfico da Figura 6 temos um desvio padrão próximo a zero, e um único posicionamento ideológico final. Já no segundo gráfico precisaríamos arredondar os pontos ideais finais, entre 1 e 6 casas decimais para chegarmos à conclusão de que existem cerca de 6 pontos de convergência. Se não arredondássemos o resultado final, teríamos uma medida próxima de 500 pontos ideais e que não nos informaria a respeito da cobertura do sistema. Já o desvio padrão nos indica a dispersão dos pontos ideais, pois tem valor de aproximadamente 0.24, próximo ao da condição inicial. Um outro problema do uso do número final de pontos ideais ao fim de uma realização é que a medida não é robusta a ruídos ou proporções de agentes intransigentes diferentes de 0. Quando há ruído ou agentes intransigentes o número final de pontos ideais não informa muito sobre a dinâmica do sistema. Na Figura 8 teremos um comportamento qualitativamente similar ao da Figura 6 (b), do ponto de vista qualitativo seriam 6 opiniões médias com oscilações ao redor delas, mas quantitativamente o número de opiniões finais distintas é próximo de 500. Uma opção para tentar capturar em medidas essa oscilação ao redor de 6 opiniões médias seria medirmos o número de pontos ideais finais com valores arredondados. Arredondar demais faz com que perdamos a comparabilidade com a condição inicial, que passa a não ter mais 500 pontos ideais. No caso da Figura 8, usar o número de pontos ideais distintos como medida nos informa que há grande cobertura no sistema, mas passaria despercebido o fato de que ao fim o comportamento é bastante similar ao caso com ruído nulo. O desvio padrão não nos informa sobre a existência dos *clusters*, mas ao menos mantêm a consistência nos casos com e sem ruído.

Figura 8 – Parametrização equivalente a Figura 6 (b), mas com $\rho = 0.001$.

Fonte: Marcelo Veloso Maciel, 2018.

Quanto à amostragem uma estratégia comum são as parametrizações de Monte Carlo: sortear valores de parâmetros usados para as realizações das simulações a partir de distribuições uniformes nos intervalos de valores dos parâmetros (LAVER; SERGENTI, 2011). O problema dessa estratégia é que o espaço de parâmetros não é coberto igualmente, havendo a possibilidade de pontos de acumulação ou espaços vazios (PEREDA; SANTOS; GALÁN, 2017).

Saltelli *et al.* (2008) argumenta que, para manter uma dispersão equitativa dos pontos no espaço de parâmetros, é necessário um algoritmo que envie a seleção de novos pontos para mantê-los afastados dos pontos já presentes. O pacote de Python SaLib⁸, o qual usamos, implementa *samplers* que garantem essa dispersão equitativa por meio da geração de amostras sorteadas de sequências quasi-aleatórias de baixa discrepância (HERMAN; USHER, 2017).⁹

O tamanho amostral e o número de parametrizações não independem do método de análise, dado que incorrem em custos computacionais distintos (SALTELLI, 2002). Seguimos Jaxa-Rozen, Kwakkel *et al.* (2018) e Brookes *et al.* (2015) em usar o esquema de

⁸ Fazemos uso da interoperabilidade entre a linguagem Julia e Python, por meio do pacote PyCall (JOHNSON, 2018).

⁹ Se pensarmos os parâmetros geometricamente podemos pensar num “espaço” de parâmetros que queremos preencher de maneira equitativa. A discrepância de uma sequência de pontos é a diferença absoluta máxima de um conjunto de regiões, no espaço de parâmetros, entre a fração de pontos e a fração de área. Por exemplo, se tivermos um quadrado unitário com 20 pontos, e o dividirmos em 16 quadrados menores de tamanho $\frac{1}{6}$ e distribuirmos os pontos de forma equitativa os quadrados deveriam ter 1 ou 2 pontos. Se um dos quadrados tiver 5 pontos, contudo, a discrepância será de ao menos $\frac{5}{20} - \frac{1}{16} = \frac{3}{16}$ (SALTELLI *et al.*, 2008, p.83). Para a implementação do “sampler” ver (http://salib.readthedocs.io/en/latest/_modules/SALib/sample/saltelli.html).

Saltelli (2002) para o cálculo de índices de sensibilidade global. Fazendo uso de sequências quase-aleatórias, ele consiste em gerar $n * (2d + 2)$ parametrizações, onde n é o tamanho amostral e d é o número de parâmetros. Segundo Saltelli (2002, p.284) esse número de parametrizações nos permite calcular índices de Sobol de primeira e segunda ordem e índices totais, discutidos no parágrafo seguinte. No nosso caso $d = 6$, teremos como parâmetros: N (população), número de questões (codificado como `n_issues`), p , σ , a proporção de agentes intransigentes (codificado como `p_intran`), e ρ . Quanto maior o tamanho da amostra menor os coeficientes de erro para os índices. Para garantir um coeficiente de erro baixo no cálculo subsequente dos índices de sensibilidade, especificamos um tamanho amostral base n de 5000, de forma que rodamos 70.000 parametrizações. Nos limitamos a esse número de parametrizações pelo custo computacional de simular tantas parametrizações: aproximadamente 60 horas¹⁰. Os baixos valores dos coeficientes de erro nos confirmam que amostras maiores não seriam necessárias.

Para a análise, seguimos Broeke, Voorn e Ligtenberg (2016) e combinamos histogramas da medida do sistema, gráficos de dispersão e índices de sensibilidade. Os índices de sensibilidade utilizados são os índices de Sobol, particularmente índices de Sobol de primeira ordem e totais (SALTELLI *et al.*, 2008). Os índices de Sobol decompõem o impacto dos parâmetros na variância do *output* de interesse. Os índices de primeira ordem incluem contribuições lineares e não-lineares dos parâmetros, mas não efeitos interativos (BROEKE; VOORN; LIGTENBERG, 2016). Dois fatores interagem quando o seu efeito conjunto sobre o *output* não pode ser expresso como a soma de seus efeitos individuais¹¹. Já índices totais incluem todos os efeitos de ordem maior decorrentes das interações entre os parâmetros. Digamos que temos um modelo com 3 fatores. O efeito total, S_{T1} do primeiro fator X_1 é dado pela soma dos termos da equação $S_{T1} = S_1 + S_{12} + S_{13} + S_{123}$, onde $S_i = \frac{V[E(Y|X_i)]}{V(Y)}$, S_{12} é o impacto na variância de Y , o *output*, da interação entre X_1 e X_2 , sendo portanto o efeito conjunto de X_1 e X_2 menos os efeitos de primeira ordem para esses fatores: $S_{ij} = \frac{V[E(Y|X_i, X_j)] - V[E(Y|X_i)] - V[E(Y|X_j)]}{V(Y)}$; a mesma lógica é aplicada aos outros termos¹². O índice total informa características não aditivas de um modelo, de forma que, para um fator X_j , uma diferença significativa entre S_{Tj} , seu efeito total, e S_j , seu efeito individual, aponta para um efeito interativo desse fator com outros fatores. Num modelo

¹⁰ Numa máquina: Intel(R) Core(TM) i7-6500U CPU @ 2.50GHz, com 15.4GiB de RAM.

¹¹ Essa é a definição usual de efeito interativo no contexto da análise multivariada de dados (HAIR *et al.*, 2009).

¹² Para maiores detalhes do cálculo dos índices ver Saltelli *et al.* (2008, p.159-167).

puramente aditivo a soma dos índices de primeira ordem $\sum_{i=1}^k S_i$ é igual a 1, isto é, nesse caso o *output* seria totalmente explicado pela soma dos efeitos individuais (SALTELLI *et al.*, 2008). Num modelo em que $S_i = 1$ e todos os outros $S_{ij} = 0$, teríamos um modelo explicado por um único fator. Se $S_1 = 0$ então esse fator não explica em nada a variância do *output*. O usual, contudo, é que o modelo seja explicado parcialmente por certos fatores e parcialmente pela interação deles.

4.5 Resultados

Rodamos, então, 70.000 parametrizações por 1.000.000 de iterações tendo por Y , o *output* de interesse, o desvio padrão dos pontos ideais da população (Y_{std}) após as iterações. São seis os parâmetros de *input*: o número de agentes (N), o número de questões (n_{issues}), o parâmetro de confiança (p), a incerteza (σ), o ruído ρ , e a proporção de agentes intransigentes (p_{intran}) nos limiares apresentados na seção Parâmetros-Chave.

Como uma primeira aproximação do comportamento geral do modelo, a Figura 9 apresenta a dispersão dos pontos ideais na condição inicial e ao fim das simulações para cada parametrização.

Figura 9 – Desvio padrão dos pontos ideais das populações para cada parametrização

Fonte: Marcelo Veloso Maciel, 2018.

A Figura 9 nos leva a interpretar que a aplicação iterativa do procedimento do modelo deixa a distribuição de opiniões menos dispersa, com uma maior concentração das parametrizações em *outputs* de baixa dispersão (entre 0.0 e 0.1). Isso condiz com as regras de atualização (assimilativa, mas na qual agentes distantes têm pouco impacto na opinião uns dos outros) e com o fato dos agentes terem por vizinhos todos os outros

agentes. Ao interagirem ou ficam mais parecidos, ou não são influenciados. O modelo tem assim uma forte tendência assimilativa, ao menos num grafo completo. Todavia, a figura não nos informa qual parâmetro é responsável por isso, ou quais os valores de concentração (centrais ou extremos).

A primeira pergunta pode começar a ser respondida por meio de gráficos de dispersão. A partir da Figura 10 podemos inferir que há uma relação negativa entre os parâmetros n_issues , p , σ e a dispersão dos pontos ideais ($Ystd$). A relação entre p e σ é explicada pelo fato de agentes que “confiam” mais na opinião dos outros agentes e são mais incertos vão convergir mais rápido para a mesma opinião.

Figura 10 – Gráfico de dispersão para 70.000 parametrizações.

Fonte: Marcelo Veloso Maciel, 2018.

O parâmetro ρ , o ruído, por sua vez, tem uma relação positiva com a dispersão do sistema. Interessante notar, contudo, que o tamanho da população parece não ter relação com o desvio padrão dos pontos ideais da população.

A intensidade dos parâmetros na variância da medida do sistema (Y_{std}) fica mais clara na Figura 11:

Figura 11 – Índices de Sobol de sensibilidade

Fonte: Marcelo Veloso Maciel, 2018.

Como mostra a Figura 11 o parâmetro N não tem impacto sobre a variância de Y_{std} , de forma que podemos tratá-lo como uma constante para análises subsequentes. A figura mostra que a maior parte da variância na dispersão dos pontos ideais pode ser explicada pelos parâmetros σ , com $S1 = 0.4621$ e $ST = 0.5761$, e n_issues e ρ , que juntos têm um $S1 = 0.32$. As somas dos $S1$ e ST são iguais a 0.847 e 1.202, respectivamente, o que implica numa contribuição de 0.3552, que podemos considerar grande, de efeitos interativos. Desses efeitos de interação entre parâmetros 0.227 são devido a interações maiores do que de segunda ordem. Dentre as de segunda ordem a maior interação é entre os parâmetros σ e ρ . Ademais, os coeficientes de erro são pequenos¹³ tendo em vista que a

¹³ Para os valores precisos ver as tabelas dos coeficientes $S1$, $S2$ e ST no Apêndice C.

análise foi feita a partir de uma amostra grande, 70.000 parametrizações, selecionadas por meio do método de Saltelli.

Um resultado contraintuitivo é o baixo valor de impacto do parâmetro p_{intran} . A comparação entre as figuras 6 e 12 sugere que esse resultado seja um artefato da medida Y_{std} .

Figura 12 – Evolução dos pontos ideais dos agentes ao longo de duas realizações. Parametrização: $p_{intran} = 0.15$, $N = 500$, $p = 0.9$, $\rho = 1e - 5$, $n_{issues} = 1$

Fonte: Marcelo Veloso Maciel, 2018.

Enquanto na, Figura 6 (a), o sistema converge para um único valor, na figura 12 a população oscila no espaço ao redor desse valor. As figuras 6 e 12 (b) exibem uma diferença equivalente de comportamento. O parâmetro parece assim ter impacto sobre a dinâmica, particularmente sobre a cobertura¹⁴. Quais agentes são intransigentes é aleatório, mas, como eles não mudam de opinião em um determinado tema, é de se esperar que acabem por atrair os outros agentes para sua posição. Para testar a intuição de que os agentes intransigentes enviassem a dinâmica para a posição deles, testamos a mesma parametrização que a figura 12 (a), mas com os 15% intransigentes localizados entre os valores maiores que 0.8 ou menores que 0.2 no espectro ideológico. A figura 13 demonstra que a atração para onde existem mais agentes intransigentes realmente ocorre¹⁵.

¹⁴ Definida da seção Metodologia de Análise.

¹⁵ Com a figura 13 replicamos o comportamento do modelo de Deffuant *et al.* (2002).

Figura 13 – Evolução dos pontos ideais dos agentes sob efeito de intransigentes nos extremos. Parametrização: $\sigma = 0.1$, $p_{intran} = 0.15$, $N = 500$, $p = 0.9$, $\rho = 1e - 5$, $n_{issues} = 1$

Fonte: Marcelo Veloso Maciel, 2018.

Um caso interessante a ser considerado é quando existem agentes intransigentes na população, mas a intransigência deles não é absoluta, o valor de σ não é tão baixo. Testamos o efeito de intransigentes com $\sigma = 0.01$ tanto distribuídos ao longo do espaço ideológico quanto somente nos extremos. No caso de agentes intransigentes extremistas, temos um comportamento semelhante ao da Figura 13, a convergência de grande parte da população para um dos extremos. O que difere é que o *cluster* maior agora converge para um único valor, enquanto com intransigentes absolutos ele oscila dentro de um dos extremos.

Figura 14 – Intransigentes com $\sigma = 0.01$. Parametrização global: $\sigma = 0.1$, $p_{intran} = 0.15$, $N = 500$, $p = 0.9$, $\rho = 1e - 5$, $n_issues = 1$

(a) Intransigentes ideologicamente distribuídos. (b) Intransigentes localizados nos extremos.

Fonte: Marcelo Veloso Maciel, 2018.

Curiosamente, quando os agentes intransigentes estão localizados ao longo do espaço e não são absolutamente intransigentes, temos um comportamento totalmente distinto. Ao invés de haver a manutenção da tendência central dada pelo σ global igual a 0.1, como demonstrado na figura 12, ocorre uma convergência da maioria da população para um dos extremos, sem precisarmos estabelecer previamente que todos os intransigentes vão estar nos extremos. Nesse caso, da figura 14 (a), o *cluster maior* vai “varrendo” um dos lados do espaço sendo atraído pelos intransigentes desse lado até um dos extremos. Esse comportamento sistêmico, contudo, depende tanto do tamanho da população quanto do número de iterações. Como demonstrado na Figura 15, quanto menor o tamanho da população menos iterações são necessárias para que a maioria da população seja atraída para um dos extremos. Dessa forma esse caso especial, no qual os intransigentes não são completamente intransigentes, difere do comportamento geral do modelo com agentes totalmente intransigentes, no qual o tamanho da população não parece ter efeito sobre a dinâmica.

Figura 15 – Intransigentes com $\sigma = 0.01$. Parametrização global: $\sigma = 0.1$, $p_{intran} = 0.15$, $p = 0.9$, $\rho = 1e - 5$, $n_{issues} = 1$

Fonte: Marcelo Veloso Maciel, 2018.

Como nem o desvio padrão nem o número de pontos ideais finais, discutidos anteriormente, nos dão medidas quantitativas desses impactos, passamos a uma análise gráfica de certas combinações de parâmetros típicas. Os gráficos de dispersão nos indicam¹⁶ possíveis restrições aos limiares dos parâmetros.

Dado o pequeno impacto de N e p , vamos mantê-los constantes, com valores de 500 e 0.9 respectivamente. Um conjunto de parametrizações não abarcado pela análise de sensibilidade global é quando $p_{intran} = 0.0$, $\rho \approx 0$. Nesse caso, se tivermos como base $N = 500$, é possível usar o número de pontos ideais finais como medida do sistema, de forma que podemos analisar o papel tanto de σ quanto de n_{issues} num sistema sem ruído e sem intransigentes. Testamos 100 realizações para cada parametrização e representamos o resultado, o número de pontos ideais finais após 1.000.000 de iterações, por meio de diagramas de caixa.

¹⁶ Regressões polinomiais de terceira ordem foram usadas para auxiliar essa análise. Estão no Apêndice D.

Figura 16 – Número de pontos ideais finais para diferentes valores de σ . Parametrização: $\rho = 1e - 5, p_{intran} = 0.0, p = 0.9, N = 500$

Fonte: Marcelo Veloso Maciel, 2018.

Como mostra a Figura 16, quanto maior o valor de σ menor a cobertura da configuração final. Um resultado que aparenta ser contrário ao da análise anterior é que quanto maior o número de questões *maior* a cobertura final, enquanto que a análise anterior demonstrou uma relação negativa entre número de questões e dispersão. Isso só é verdade pelo fato dos parâmetros ρ e p_{intran} serem nulos ou aproximadamente nulos. Nesse caso aumentar o número de questões faz com que sejam necessárias mais interações entre os agentes para que eles se aproximem ideologicamente, já que, pelo procedimento da simulação, eles só atualizam uma opinião por vez. Portanto, aumentar o número de questões contribui para uma maior dispersão e cobertura de posicionamento ideológicos.

Contudo, a partir do momento que a proporção de agentes intransigentes e o ruído são não nulos, o número de questões passa a ter o efeito contrário. Como demonstrado na Figura 17, quando $n_issues = 1$, o sistema passa a ter sua configuração facilmente controlada por aqueles parâmetros. Como só há uma única questão, os agentes quando sofrem o efeito do ruído passeiam pelo espectro todo. Já quando interagem com agentes intransigentes têm seu ponto ideal atraído bem mais em direção a opinião deles, em contraposição ao caso em que seu ponto ideal é derivado de várias opiniões, pois, mesmo que o agente mude, aleatoriamente ou sob o efeito da interação com um agente intransigente, uma de suas opiniões o ponto ideal é estabilizado pelo posicionamento dele em outras questões. O número de questões serve então para controlar o efeito dos agentes intransigentes

e do ruído, e tornar mais robusto o efeito de concentração ditado por σ , o parâmetro de maior impacto.

Figura 17 – Evolução dos pontos ideais quando há ruído e agentes intransigentes. Parametrização: $p_{intran} = 0.15$, $N = 500$, $p = 0.9$, $\rho = 0.05$

Fonte: Marcelo Veloso Maciel, 2018.

À guisa de conclusão, o modelo pode ser pensado como uma extensão do modelo de Martins (2009), adicionando agentes com opiniões em mais de uma questão, o ruído e os agentes intransigentes inseridos numa população de agentes normais (uma população com dois tipos de agentes ao invés de um único). Desta forma, quando $n_issues = 1$, $p_{intran} = 0$ e $\rho \approx 0.0$, o modelo tem o mesmo comportamento do modelo de inspiração bayesiana de Martins (2009), que por sua vez recupera um comportamento qualitativo similar ao modelo canônico de Deffuant *et al.* (2000). Nosso modelo recupera também, de duas formas distintas, a convergência da maioria da população a um dos extremos encontrada por Deffuant *et al.* (2002) por meio tanto de intransigentes nos extremos, quanto de agentes não totalmente intransigentes distribuídos ao longo do espectro político.

Um comportamento novo encontrado usando o modelo é a importância da interação entre o ruído e o número de questões. Um maior número de questões torna o comportamento do sistema menos suscetível a grandes oscilações causadas pelo aumento do ruído, enquanto que em um modelo com uma única questão os agentes oscilam totalmente no espectro. Como argumentado por Flache *et al.* (2017), modelos de dinâmicas de opinião levam naturalmente a questionamentos empíricos sobre os microfundamentos comportamentais. Uma implicação observável é pensarmos a relação entre “sofisticação” de posicionamento de indivíduos e a consistência deles frente a argumentos e evidências fortes em determinadas questões. Do ponto de vista empírico, será verdade que aumentar o número de questões que os indivíduos reconhecem como balizando um posicionamento faz com que a população seja mais estável frente a perturbações nas crenças? Ou isso é um artefato da simulação?

Do ponto de vista conceitual, o uso de um modelo de inspiração bayesiana nos permite conectar a área de dinâmicas de opinião com o quadro conceitual dos modelos de utilidade esperada na ciência política, por meio do relaxamento da separação típica entre preferência e crença, como discutido nos Capítulos 2 e 3. Embora o modelo suscite a necessidade de validação empírica tanto de padrões sistêmicos quanto de fundamentos comportamentais, ele pode ser integrado a modelos futuros de comportamento eleitoral e competição partidária.

5 Conclusão

O trabalho teve por objetivo estudar a geração de distribuições de posicionamentos ideológicos em uma sociedade artificial, por meio da técnica da modelagem baseada em agentes. Com isso buscou conectar o *background* conceitual usual da Ciência Política no tocante à modelagem formal de política com a literatura em Dinâmicas de Opinião. Esse exercício ilustrou a importância de pensar o posicionamento político como resultante de acomodações em diversas questões. Particularmente, pensar o posicionamento político como composto de opiniões em várias questões apontou para o papel do número de questões para tornar mais robusto o efeito de interações assimilativas, enviesadas, ao impacto do ruído e de agentes intransigentes.

Contudo, o trabalho pode ser pensado como um único passo num processo de iterados esforços, teóricos e empíricos, que nos levem a melhor compreensão do fenômeno (WILENSKY; RAND, 2015). Sendo assim, possui várias limitações cujas resoluções fogem ao seu escopo. A primeira limitação do trabalho é que não busca modelar o papel da mídia na formação da opinião dos agentes. A mídia pode ser considerada uma das principais fontes de influência social, mas investigar como modelar seu efeito envolve compreender outros tipos de mecanismo.

Outra questão importante é referente à regra de interação. Muitos resultados em influência social, por exemplo os de influência social repulsiva, são na verdade encontrados em interações em grupo (BRAMSON *et al.*, 2017). Compreender a diferença da interação entre pares e em grupo, quais as regras de interação e atualização subjacentes, como traduzir isso em *schedules* em simulações e qual o impacto sistêmico disso é algo a ser explorado.

A terceira, e talvez principal, restrição do trabalho é a falta de calibração e validação empírica do modelo. Flache *et al.* (2017) argumenta que uma das principais limitações da literatura em OD é a falta de preocupação com o confronto rigoroso com dados. Dentre os diversos testes possíveis elencados por eles, consideramos que seria especialmente interessante testar as macropredições do modelo com dados de *surveys* (como o ESS). O teste com dados do ESS estavam no planejamento original do trabalho, mas o desenvolvimento e a análise do modelo acabaram por nos levar a modificar as atividades pré-estabelecidas no cronograma.

Uma deficiência relacionada à anterior é que não testamos diferentes topologias de interação entre os agentes. O modelo foi testado unicamente num grafo completo, mas um dos principais resultados da área de dinâmicas de opinião é exatamente a importância da topologia para explicar propriedades macroscópicas (BALL, 2002). Calibrar a topologia com dados, por sua vez, é um desafio metodológico.

Uma limitação mais geral em OD é a apontada por Acemoglu e Ozdaglar (2011): a literatura costuma focar em propriedades de longo prazo da dinâmica de opiniões. Muitos fenômenos sociais não são capturados por esse limite de longo prazo e uma fronteira para a área é quais regras de interação e atualização melhor caracterizam processos de médio e curto prazo.

Por fim, o modelo teve por *rationale* limitações nos modelos de tomada de decisão eleitoral e competição partidária. Uma das fronteiras de pesquisa em ABM é exatamente a construção de modelos multi-nível por meio do acoplamento de sub-modelos parcialmente autônomos (HJORTH *et al.*, 2016; HEAD *et al.*, 2015). Um prospecto animador, portanto, é a possibilidade de criar narrativas computacionais que liguem as áreas de opinião pública, comportamento eleitoral e competição partidária, de forma que possamos investigar *feedbacks* entre os diferentes níveis de ação.

Referências

- ACEMOGLU, D.; OZDAGLAR, A. Opinion dynamics and learning in social networks. *Dynamic Games and Applications*, Springer, v. 1, n. 1, p. 3–49, 2011. Citado 4 vezes nas páginas 17, 35, 39 e 57.
- ARMSTRONG, D. A.; BAKKER, R.; CARROLL, R.; HARE, C.; POOLE, K. T.; ROSENTHAL, H. *et al. Analyzing spatial models of choice and judgment with R*. [S.l.]: CRC Press, 2014. Citado na página 19.
- AUSTEN-SMITH, D.; BANKS, J. S. Social choice theory, game theory, and positive political theory. *Annual Review of Political Science*, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 1, n. 1, p. 259–287, 1998. Citado 3 vezes nas páginas 15, 16 e 18.
- AXELROD, R. The dissemination of culture a model with local convergence and global polarization. *Journal of conflict resolution*, Sage Publications, v. 41, n. 2, p. 203–226, 1997. Citado 3 vezes nas páginas 26, 30 e 37.
- BAKER, C. L.; JARA-ETTINGER, J.; SAXE, R.; TENENBAUM, J. B. Rational quantitative attribution of beliefs, desires and percepts in human mentalizing. *Nature Human Behaviour*, Nature Publishing Group, v. 1, p. 0064, 2017. Citado na página 33.
- BALL, P. The physical modelling of society: a historical perspective. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 314, n. 1-4, p. 1–14, 2002. Citado na página 57.
- BARABAS, J. How deliberation affects policy opinions. *American Political Science Review*, Cambridge University Press, v. 98, n. 4, p. 687–701, 2004. Citado na página 12.
- BARTELS, L. M. Beyond the running tally: Partisan bias in political perceptions. *Political Behavior*, Springer, v. 24, n. 2, p. 117–150, 2002. Citado na página 31.
- BARTELS, L. M. Democracy with attitudes. *Electoral democracy*, University of Michigan Press Ann Arbor, p. 48–82, 2003. Citado 2 vezes nas páginas 12 e 21.
- BENDOR, J.; DIERMEIER, D.; SIEGEL, D. A.; TING, M. M. *A behavioral theory of elections*. [S.l.]: Princeton University Press, 2011. Citado 2 vezes nas páginas 16 e 21.
- BENDOR, J. B. *Bounded rationality and politics*. [S.l.]: Univ of California Press, 2010. v. 6. Citado na página 33.
- BENOIT, K.; LAVER, M. *et al. Party policy in modern democracies*. [S.l.]: Routledge, 2006. Citado na página 22.
- BENTLEY, A.; ORMEROD, P. Agents, intelligence, and social atoms. 2012. Disponível em: (<http://www.paulormerod.com/wp-content/uploads/2012/06/agents.pdf>). Citado na página 32.
- BERELSON, B. Democratic theory and public opinion. *Public Opinion Quarterly*, JSTOR, p. 313–330, 1952. Citado 2 vezes nas páginas 12 e 21.

BINMORE, K. *Does game theory work? The bargaining challenge*. [S.l.]: Mit Press, 2007. Citado na página 20.

BINMORE, K. *Rational decisions*. [S.l.]: Princeton University Press, 2008. Citado 6 vezes nas páginas 16, 19, 20, 22, 37 e 68.

BLACK, D. On the rationale of group decision-making. *Journal of political economy*, The University of Chicago Press, v. 56, n. 1, p. 23–34, 1948. Citado na página 15.

BLACK, D.; NEWING, R. A.; MCLEAN, I.; MCMILLAN, A.; MONROE, B. L. *The theory of committees and elections*. [S.l.]: Springer, 1958. Citado 2 vezes nas páginas 18 e 20.

BRAMSON, A.; GRIM, P.; SINGER, D. J.; FISHER, S.; BERGER, W.; SACK, G.; FLOCKEN, C. Disambiguation of social polarization concepts and measures. *The Journal of Mathematical Sociology*, Taylor & Francis, v. 40, n. 2, p. 80–111, 2016. Citado 2 vezes nas páginas 13 e 42.

BRAMSON, A.; GRIM, P.; SINGER, D. J.; BERGER, W. J.; SACK, G.; FISHER, S.; FLOCKEN, C.; HOLMAN, B. Understanding polarization: meanings, measures, and model evaluation. *Philosophy of Science*, University of Chicago Press Chicago, IL, v. 84, n. 1, p. 115–159, 2017. Citado na página 56.

BRIGGS, R. Normative theories of rational choice: Expected utility. In: ZALTA, E. N. (Ed.). *The Stanford Encyclopedia of Philosophy*. Spring 2017. [S.l.]: Metaphysics Research Lab, Stanford University, 2017. Citado 2 vezes nas páginas 68 e 69.

BROEKE, G. T.; VOORN, G. V.; LIGTENBERG, A. Which sensitivity analysis method should i use for my agent-based model? *Journal of Artificial Societies and Social Simulation*, v. 19, n. 1, p. 5, 2016. Citado na página 45.

BROOKES, V. J.; JORDAN, D.; DAVIS, S.; WARD, M. P.; HELLER, J. Saltelli global sensitivity analysis and simulation modelling to identify intervention strategies to reduce the prevalence of escherichia coli o157 contaminated beef carcasses. *PloS one*, Public Library of Science, v. 10, n. 12, p. e0146016, 2015. Citado na página 44.

BROUSMICHE, K.-L.; KANT, J.-D.; SABOURET, N.; PRENOT-GUINARD, F. From beliefs to attitudes: Polias, a model of attitude dynamics based on cognitive modeling and field data. *Journal of Artificial Societies and Social Simulation*, v. 19, n. 4, p. 2, 2016. Citado na página 32.

CARROLL, R.; LEWIS, J. B.; LO, J.; POOLE, K. T.; ROSENTHAL, H. The structure of utility in spatial models of voting. *American Journal of Political Science*, Wiley Online Library, v. 57, n. 4, p. 1008–1028, 2013. Citado na página 36.

CASTELLANO, C. Social influence and the dynamics of opinions: the approach of statistical physics. *Managerial and Decision Economics*, Wiley Online Library, v. 33, n. 5-6, p. 311–321, 2012. Citado 4 vezes nas páginas 26, 28, 29 e 30.

CLARKE, K. A.; PRIMO, D. M. *A model discipline: Political science and the logic of representations*. [S.l.]: Oxford University Press, 2012. Citado na página 15.

CONTE, R.; ANDRIGHETTO, G.; CAMPENNL, M. *Minding norms: Mechanisms and dynamics of social order in agent societies*. [S.l.]: Oxford University Press, 2013. Citado na página 32.

CONVERSE, P. E. The nature of belief systems in mass publics (1964). *Critical review*, Taylor & Francis, v. 18, n. 1-3, p. 1–74, 2006. Citado na página 21.

DAHL, R. A. *Democracy and its Critics*. [S.l.]: Yale University Press, 1989. Citado 2 vezes nas páginas 12 e 25.

DEFFUANT, G.; AMBLARD, F.; WEISBUCH, G.; FAURE, T. How can extremism prevail? a study based on the relative agreement interaction model. *Journal of artificial societies and social simulation*, v. 5, n. 4, 2002. Citado 4 vezes nas páginas 13, 35, 49 e 54.

DEFFUANT, G.; NEAU, D.; AMBLARD, F.; WEISBUCH, G. Mixing beliefs among interacting agents. *Advances in Complex Systems*, World Scientific, v. 3, n. 01n04, p. 87–98, 2000. Citado 5 vezes nas páginas 31, 36, 37, 40 e 54.

DOWNS, A. An economic theory of political action in a democracy. *Journal of Political Economy*, The University of Chicago Press, v. 65, n. 2, p. 135–150, 1957. Citado na página 18.

DOWNS, A. *Uma teoria econômica da democracia. trad. de sandra guardini teixeira Vasconcelos. são Paulo*. [S.l.]: Edusp, 1999. Citado 2 vezes nas páginas 12 e 20.

DRUCKMAN, J. N.; LEEPER, T. J. Is public opinion stable? resolving the micro/macro disconnect in studies of public opinion. *Daedalus*, MIT Press, v. 141, n. 4, p. 50–68, 2012. Citado 2 vezes nas páginas 21 e 23.

EGUIA, J. X. On the spatial representation of preference profiles. *Economic Theory*, Springer, v. 52, n. 1, p. 103–128, 2013. Citado na página 36.

EPSTEIN, J. M. *Generative social science: Studies in agent-based computational modeling*. [S.l.]: Princeton University Press, 2006. Citado 3 vezes nas páginas 12, 27 e 28.

EPSTEIN, J. M. Why model? *Journal of Artificial Societies and Social Simulation*, v. 11, n. 4, p. 12, 2008. Citado na página 15.

EPSTEIN, J. M. *Agent_Zero: Toward neurocognitive foundations for generative social science*. [S.l.]: Princeton University Press, 2014. Citado na página 32.

FIGUEIREDO, M. F. *A decisão do voto-democracia e racionalidade*. [S.l.]: Editora UFMG, 2008. Citado na página 22.

FIORINA, M. P.; ABRAMS, S. J.; POPE, J. *Culture war?: The myth of a polarized America*. [S.l.]: Pearson Longman New York, 2005. Citado na página 13.

FLACHE, A.; MÄS, M.; FELICIANI, T.; CHATTOE-BROWN, E.; DEFFUANT, G.; HUET, S.; LORENZ, J. Models of social influence: Towards the next frontiers. *Journal of Artificial Societies and Social Simulation*, v. 20, n. 4, p. 2, 2017. ISSN 1460-7425. Disponível em: <http://jasss.soc.surrey.ac.uk/20/4/2.html>. Citado 11 vezes nas páginas 13, 24, 26, 28, 30, 31, 32, 33, 39, 55 e 56.

- FLYNN, D.; NYHAN, B.; REIFLER, J. The nature and origins of misperceptions: Understanding false and unsupported beliefs about politics. *Political Psychology*, Wiley Online Library, v. 38, n. S1, p. 127–150, 2017. Citado na página 31.
- FOWLER, J. H.; DAWES, C. T. In defense of genopolitics. *American Political Science Review*, Cambridge University Press, v. 107, n. 2, p. 362–374, 2013. Citado na página 12.
- FOWLER, J. H.; SCHREIBER, D. Biology, politics, and the emerging science of human nature. *Science*, American Association for the Advancement of Science, v. 322, n. 5903, p. 912–914, 2008. Citado na página 12.
- FUJIKAWA, T. Perfect bayesian vs. imperfect bayesian in small decision making problems. *Behaviormetrika*, The Behaviormetric Society of Japan, v. 34, n. 1, p. 27–44, 2007. Citado na página 33.
- GALAM, S. Majority rule, hierarchical structures, and democratic totalitarianism: A statistical approach. *Journal of Mathematical Psychology*, Elsevier, v. 30, n. 4, p. 426–434, 1986. Citado na página 30.
- GALAM, S. Social paradoxes of majority rule voting and renormalization group. *Journal of Statistical Physics*, Springer, v. 61, n. 3-4, p. 943–951, 1990. Citado 2 vezes nas páginas 26 e 30.
- GALAM, S. *Sociophysics: a physicist's modeling of psycho-political phenomena*. [S.l.]: Springer Science & Business Media, 2012. Citado 2 vezes nas páginas 26 e 30.
- GALAM, S.; GEFEN, Y.; SHAPIR, Y. Sociophysics: A new approach of sociological collective behaviour. i. mean-behaviour description of a strike. *Journal of Mathematical Sociology*, Taylor & Francis, v. 9, n. 1, p. 1–13, 1982. Citado na página 26.
- GAUS, G. *On philosophy, politics, and economics*. [S.l.]: Nelson Education, 2007. Citado na página 17.
- GINTIS, H. *Individuality and Entanglement: The Moral and Material Bases of Social Life*. [S.l.]: Princeton University Press, 2016. Citado 6 vezes nas páginas 12, 16, 17, 21, 33 e 68.
- GLAZER, A.; GROFMAN, B.; OWEN, G. A model of candidate convergence under uncertainty about voter preferences. *Mathematical and Computer Modelling*, Elsevier, v. 12, n. 4-5, p. 471–478, 1989. Citado na página 24.
- GOMES, M. P. S. *Desacordo e Convergência em Redes de Difusão de Opinião Política: um experimento computacional a partir de Mutz, Huckfeldt e Axelrod*. Tese (Doutorado) — Universidade Federal de Minas Gerais, 2014. Citado na página 30.
- GREEN, D.; SHAPIRO, I. *Pathologies of rational choice theory: A critique of applications in political science*. [S.l.]: Yale University Press, 1996. Citado na página 16.
- GRIFFITHS, T. L.; TENENBAUM, J. B. Optimal predictions in everyday cognition. *Psychological science*, SAGE Publications Sage CA: Los Angeles, CA, v. 17, n. 9, p. 767–773, 2006. Citado na página 33.
- GROFMAN, B. Downs and two-party convergence. *Annu. Rev. Polit. Sci.*, Annual Reviews, v. 7, p. 25–46, 2004. Citado na página 24.

HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. *Análise multivariada de dados*. [S.l.]: Bookman Editora, 2009. Citado na página 45.

HANSSON, S. O.; GRÜNE-YANOFF, T. Preferences. In: ZALTA, E. N. (Ed.). *The Stanford Encyclopedia of Philosophy*. Winter 2012. [S.l.]: Metaphysics Research Lab, Stanford University, 2012. Citado 2 vezes nas páginas 17 e 68.

HARDIN, R. The free rider problem. In: ZALTA, E. N. (Ed.). *The Stanford Encyclopedia of Philosophy*. Spring 2013. [S.l.]: Metaphysics Research Lab, Stanford University, 2013. Citado na página 15.

HAUKE, J.; LORSCHIED, I.; MEYER, M. Recent development of social simulation as reflected in jasss between 2008 and 2014: A citation and co-citation analysis. *Journal of artificial societies and social simulation*, JASSS, v. 20, n. 1, 2017. Citado na página 12.

HEAD, B.; HJORTH, A.; BRADY, C.; WILENSKY, U. Evolving agent cognition with netlogo levelspace. In: IEEE. *Winter Simulation Conference (WSC), 2015*. [S.l.], 2015. p. 3122–3123. Citado na página 57.

HECHTER, M.; KANAZAWA, S. Sociological rational choice theory. *Annual review of sociology*, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 23, n. 1, p. 191–214, 1997. Citado na página 16.

HEGSELMANN, R. Thomas c. schelling and james m. sakoda: The intellectual, technical, and social history of a model. *Journal of Artificial Societies and Social Simulation*, JASSS, v. 20, n. 3, 2017. Citado na página 27.

HELBING, D. Pluralistic modeling of complex systems. 2010. Citado na página 32.

HERMAN, J.; USHER, W. Salib: an open-source python library for sensitivity analysis. *The Journal of Open Source Software*, v. 2, n. 9, 2017. Citado na página 44.

HJORTH, A.; BRADY, C.; HEAD, B.; WILENSKY, U. Turtles all the way down: Presenting levelspace, a netlogo extension for reasoning about complex connectedness. In: *Construction in Action, Conference Proceedings (Dra), Published by Suksapattana Foundation*. [S.l.: s.n.], 2016. v. 126, p. 1–5. Citado na página 57.

HOLLEY, R. A.; LIGGETT, T. M. Ergodic theorems for weakly interacting infinite systems and the voter model. *The annals of probability*, JSTOR, p. 643–663, 1975. Citado na página 29.

HOUWELING, R. P. V.; SNIDERMAN, P. M. The political logic of a downsian space. *Institute of Governmental Studies*, 2005. Citado na página 18.

HUCKFELDT, R.; IKEDA, K.; PAPPI, F. U. Patterns of disagreement in democratic politics: Comparing germany, japan, and the united states. *American Journal of Political Science*, Wiley Online Library, v. 49, n. 3, p. 497–514, 2005. Citado na página 31.

HUMPHREYS, M.; LAVER, M. Spatial models, cognitive metrics, and majority rule equilibria. *British Journal of Political Science*, Cambridge University Press, v. 40, n. 1, p. 11–30, 2010. Citado 2 vezes nas páginas 18 e 19.

JABLONKA, E.; LAMB, M. J. *Evolution in four dimensions, revised edition: Genetic, epigenetic, behavioral, and symbolic variation in the history of life*. [S.l.]: MIT press, 2014. Citado na página 12.

JACKMAN, S. *Bayesian analysis for the social sciences*. [S.l.]: John Wiley & Sons, 2009. v. 846. Citado na página 17.

JAGER, W. Enhancing the realism of simulation (eros): On implementing and developing psychological theory in social simulation. *Journal of Artificial Societies and Social Simulation*, v. 20, n. 3, p. 14, 2017. ISSN 1460-7425. Disponível em: <http://jasss.soc.surrey.ac.uk/20/3/14.html>. Citado 2 vezes nas páginas 32 e 33.

JAXA-ROZEN, M.; KWAKKEL, J. H. *et al.* Pynetlogo: Linking netlogo with python. *Journal of Artificial Societies and Social Simulation*, *Journal of Artificial Societies and Social Simulation*, v. 21, n. 2, p. 4, 2018. Citado na página 44.

JEHLE, G. A. *Advanced microeconomic theory*. [S.l.]: Pearson Education India, 2001. Citado 2 vezes nas páginas 68 e 69.

JOHNSON, S. G. *Calling Python functions from the Julia language*. [S.l.]: GitHub, 2018. <https://github.com/JuliaPy/PyCall.jl>. Citado na página 44.

KIM, S.-y. A model of political judgment: An agent-based simulation of candidate evaluation. *Journal of Artificial Societies and Social Simulation*, v. 14, n. 2, p. 3, 2011. Citado na página 32.

KIM, S.-y.; TABER, C. S.; LODGE, M. A computational model of the citizen as motivated reasoner: Modeling the dynamics of the 2000 presidential election. *Political Behavior*, Springer, v. 32, n. 1, p. 1–28, 2010. Citado na página 32.

KLEMM, K. Role of dimensionality in axelrod's model for the dissemination of culture. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 327, n. 1-2, p. 1–5, 2003. Citado na página 30.

KOLLMAN, K.; MILLER, J. H.; PAGE, S. E. Political parties and electoral landscapes. *British Journal of Political Science*, Cambridge University Press, v. 28, n. 1, p. 139–158, 1998. Citado na página 24.

KOLLMAN, K.; MILLER, J. H.; PAGE, S. E. *Computational models in political economy*. [S.l.]: MIT Press, 2003. Citado na página 28.

KOWALSKA-PYZALSKA, A.; MACIEJOWSKA, K.; SZNAJD-WERON, K.; WERON, R. *et al.* *Going green: Agent-based modeling of the diffusion of dynamic electricity tariffs*. [S.l.], 2013. Citado na página 26.

KUKLINSKI, J. H.; QUIRK, P. J.; JERIT, J.; SCHWIEDER, D.; RICH, R. F. Misinformation and the currency of democratic citizenship. *The Journal of Politics*, University of Texas Press, v. 62, n. 3, p. 790–816, 2000. Citado 2 vezes nas páginas 21 e 35.

LAVER, M. Measuring policy positions in political space. *Annual Review of Political Science*, Annual Reviews, v. 17, p. 207–223, 2014. Citado 5 vezes nas páginas 18, 19, 21, 37 e 70.

- LAVER, M.; SERGENTI, E. *Party competition: An agent-based model*. [S.l.]: Princeton University Press, 2011. Citado 4 vezes nas páginas 12, 24, 27 e 44.
- LIST, C.; PUPPE, C. Judgment aggregation: A survey. 2009. Citado na página 36.
- LIU, F. Von wright's "the logic of preference" revisited. *Synthese*, Springer, v. 175, n. 1, p. 69–88, 2010. Citado na página 22.
- LODGE, M.; TABER, C. S. *The rationalizing voter*. [S.l.]: Cambridge University Press, 2013. Citado na página 31.
- LORENZ, J. Modeling the evolution of ideological landscapes through opinion dynamics. In: *Advances in Social Simulation 2015*. [S.l.]: Springer, 2017. p. 255–266. Citado 4 vezes nas páginas 12, 24, 39 e 40.
- MACY, M.; TSVETKOVA, M. The signal importance of noise. *Sociological Methods & Research*, SAGE Publications Sage CA: Los Angeles, CA, v. 44, n. 2, p. 306–328, 2015. Citado 2 vezes nas páginas 13 e 39.
- MARCHI, S. D. Adaptive models and electoral instability. *Journal of Theoretical Politics*, Sage Publications 6 Bonhill Street, London EC2A 4PU, UK, v. 11, n. 3, p. 393–419, 1999. Citado na página 24.
- MARCHI, S. D.; PAGE, S. E. Agent-based models. *Annual Review of Political Science*, Annual Reviews, v. 17, p. 1–20, 2014. Citado 2 vezes nas páginas 27 e 28.
- MARCHI, S. de. *Computational and Mathematical Modeling in the Social Sciences*. Cambridge University Press, 2005. ISBN 9781139446860. Disponível em: <https://books.google.com.br/books?id=fPhvoKufiogC>. Citado na página 33.
- MARTINS, A. C. Continuous opinions and discrete actions in opinion dynamics problems. *International Journal of Modern Physics C*, World Scientific, v. 19, n. 04, p. 617–624, 2008. Citado na página 40.
- MARTINS, A. C. Bayesian updating rules in continuous opinion dynamics models. *Journal of Statistical Mechanics: Theory and Experiment*, IOP Publishing, v. 2009, n. 02, p. P02017, 2009. Citado 5 vezes nas páginas 13, 34, 35, 42 e 54.
- MARTINS, A. C. Bayesian updating as basis for opinion dynamics models. 2012. Citado 3 vezes nas páginas 33, 36 e 37.
- MARTINS, A. C. Thou shalt not take sides: Cognition, logic and the need for changing how we believe. *arXiv preprint arXiv:1508.05169*, 2015. Citado na página 26.
- MCLEAN, I. The strange history of social choice, and the contribution of the public choice society to its fifth revival. *Public Choice*, Springer, v. 163, n. 1-2, p. 153–165, 2015. Citado na página 15.
- MCPHERSON, M.; SMITH-LOVIN, L.; COOK, J. M. Birds of a feather: Homophily in social networks. *Annual review of sociology*, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 27, n. 1, p. 415–444, 2001. Citado na página 31.

MILLER, N. R. The spatial model of social choice and voting. In: HECKELMAN, J. C.; MILLER, N. R. (Ed.). *Handbook of social choice and voting*. [S.l.]: Edward Elagar, Cheltenham, 2015. p. 163–181. Citado na página 18.

MORTON, R. B. *Methods and models: A guide to the empirical analysis of formal models in political science*. [S.l.]: Cambridge University Press, 1999. Citado na página 15.

MUNGER, M. C. *Choosing in groups: Analytical politics revisited*. [S.l.]: Cambridge University Press, 2015. Citado 4 vezes nas páginas 15, 18, 19 e 20.

NICKERSON, R. S. Confirmation bias: A ubiquitous phenomenon in many guises. *Review of general psychology*, US: Educational Publishing Foundation, v. 2, p. 175, 1998. Citado na página 31.

NORTH, M. J.; MACAL, C. M. *Managing business complexity: discovering strategic solutions with agent-based modeling and simulation*. [S.l.]: Oxford University Press, 2007. Citado 2 vezes nas páginas 28 e 41.

OLSON, M. The logic of collective action: Public goods and the theory of groups. Harvard University Press, 1965. Citado na página 15.

OPPENHEIMER, J. *Principles of politics: a rational choice theory guide to politics and social justice*. [S.l.]: Cambridge University Press, 2012. Citado na página 15.

ORDESHOOK, P. C. The emerging discipline of political economy. In: *Perspectives on positive political economy*. [S.l.]: Cambridge University Press, Cambridge, 1990. p. 9–30. Citado na página 15.

ORMEROD, P. What can agents know? the feasibility of advanced cognition in social and economic systems. In: *Proceedings of the AISB 2008 Convention on Communication, Interaction and Social Intelligence*. [s.n.], 2008. v. 6, p. 17–20. Disponível em: https://www.researchgate.net/publication/253193513-What_can_Agents_Know_The_Feasibility_of_Advanced_Cognition_in_Social_and_Economic_Systems. Citado na página 32.

OSTROM, E. An agenda for the study of institutions. *Public choice*, Springer, v. 48, n. 1, p. 3–25, 1986. Citado na página 15.

OSTROM, E. *Governing the commons: the evolution of institutions for collective action*. [S.l.]: Cambridge University Press,, 1990. Citado na página 33.

PAGE, S. E. Uncertainty, difficulty, and complexity. *Journal of Theoretical Politics*, v. 20, n. 2, p. 115–149, 2008. Disponível em: <https://doi.org/10.1177/0951629807085815>. Citado 3 vezes nas páginas 20, 24 e 28.

PEREDA, M.; SANTOS, J. I.; GALÁN, J. M. A brief introduction to the use of machine learning techniques in the analysis of agent-based models. In: *Advances in Management Engineering*. [S.l.]: Springer, 2017. p. 179–186. Citado na página 44.

POOLE, K. T. *Spatial models of parliamentary voting*. [S.l.]: Cambridge University Press, 2005. Citado 2 vezes nas páginas 18 e 21.

POOLE, K. T.; DANIELS, R. S. Ideology, party, and voting in the us congress, 1959–1980. *American Political Science Review*, Cambridge University Press, v. 79, n. 2, p. 373–399, 1985. Citado na página 21.

PULICK, E.; KORTH, P.; GRIM, P.; JUNG, J. Modeling interaction effects in polarization: Individual media influence and the impact of town meetings. *Journal of Artificial Societies and Social Simulation*, v. 19, n. 2, p. 1, 2016. ISSN 1460-7425. Disponível em: <http://jasss.soc.surrey.ac.uk/19/2/1.html>. Citado na página 13.

RAILSBACK, S. F.; GRIMM, V. *Agent-based and individual-based modeling: a practical introduction*. [S.l.]: Princeton university press, 2012. Citado 2 vezes nas páginas 41 e 42.

RYAN, J. B. Social networks as a shortcut to correct voting. *American Journal of Political Science*, Wiley Online Library, v. 55, n. 4, p. 753–766, 2011. Citado na página 12.

SALTELLI, A. Making best use of model evaluations to compute sensitivity indices. *Computer physics communications*, Elsevier, v. 145, n. 2, p. 280–297, 2002. Citado 2 vezes nas páginas 44 e 45.

SALTELLI, A.; RATTO, M.; ANDRES, T.; CAMPOLONGO, F.; CARIBONI, J.; GATELLI, D.; SAISANA, M.; TARANTOLA, S. *Global sensitivity analysis: the primer*. [S.l.]: John Wiley & Sons, 2008. Citado 3 vezes nas páginas 44, 45 e 46.

SAYAMA, H. *Introduction to the modeling and analysis of complex systems*. [S.l.]: Open SUNY Textbooks, 2015. Citado na página 27.

SCHRÖDER, T.; WOLF, I. Modeling multi-level mechanisms of environmental attitudes and behaviours: The example of carsharing in berlin. *Journal of Environmental Psychology*, Elsevier, v. 52, p. 136–148, 2017. Citado na página 32.

SCHUMPETER, J. A. *Capitalism, socialism and democracy*. [S.l.]: Routledge, 2013. Citado na página 12.

SÎRBU, A.; LORETO, V.; SERVEDIO, V. D.; TRIA, F. Opinion dynamics: models, extensions and external effects. In: *Participatory Sensing, Opinions and Collective Awareness*. [S.l.]: Springer, 2017. p. 363–401. Citado 2 vezes nas páginas 28 e 30.

SMALDINO, P. E. Models are stupid, and we need more of them. In: VALLACHER, R. R.; READ, S. J.; NOWAK, A. (Ed.). *Computational Social Psychology*. [S.l.]: Routledge, 2017. p. 311–331. Citado na página 15.

SOLÉ, R. V. *Phase transitions*. [S.l.]: Princeton University Press, 2011. Citado na página 29.

SQUAZZONI, F. The micro-macro link in social simulation. *Sociologica*, Società editrice il Mulino, v. 2, n. 1, p. 0–0, 2008. Citado na página 28.

STAUFFER, D. How to convince others? monte carlo simulations of the sznajd model. In: AIP. *AIP Conference Proceedings*. [S.l.], 2003. v. 690, n. 1, p. 147–155. Citado na página 30.

SZNAJD-WERON, K.; SZNAJD, J. Opinion evolution in closed community. *International Journal of Modern Physics C*, World Scientific, v. 11, n. 06, p. 1157–1165, 2000. Citado na página 30.

WARD, M. D.; O'LOUGHLIN, J. Spatial processes and political methodology: Introduction to the special issue. *Political Analysis*, Cambridge University Press, v. 10, n. 3, p. 211–216, 2002. Citado na página 18.

WILENSKY, U.; RAND, W. *An introduction to agent-based modeling: modeling natural, social, and engineered complex systems with NetLogo*. [S.l.]: MIT Press, 2015. Citado 3 vezes nas páginas 28, 38 e 56.

ZALLER, J. *The nature and origins of mass opinion*. [S.l.]: Cambridge university press, 1992. Citado na página 33.

ZALLER, J.; FELDMAN, S. A simple theory of the survey response: Answering questions versus revealing preferences. *American journal of political science*, JSTOR, p. 579–616, 1992. Citado 2 vezes nas páginas 21 e 39.

Apêndice A – Definições formais complementares

O Capítulo 1 suscita algumas definições formais apresentadas a seguir.

Propriedades Lógicas da Preferência

As seguintes propriedades definem a noção lógica de relação de preferência (HANS-SON; GRÜNE-YANOFF, 2012):

1. *Assimetria da preferência*: $x \succ y \rightarrow \neg(y \succ x)$;
2. *Simetria de indiferença*: $x \sim y \rightarrow y \sim x$;
3. *Reflexividade da indiferença*: $x \sim x$;
4. *Incompatibilidade entre preferência e indiferença*: $x \succ y \rightarrow \neg(x \sim y)$.

A definição axiomática das propriedades de uma relação de preferência é a seguinte (GINTIS, 2016; BINMORE, 2008): para todo $x, y, z \in X$, onde X é o conjunto de alternativas, e para todo conjunto $Z \subset X$:

1. *Completeness*: $\{x \succeq y|X\}$ ou $\{y \succeq x|X\}$;
2. *Transitividade*: $\{x \succeq y|X\}$ e $\{y \succeq z|X\}$ tem por implicação $\{x \succeq z|X\}$;
3. *Independência das alternativas irrelevantes*: para $x, y, z \in Z$, $\{x \succeq y|Z\}$ se e somente se $\{x \succeq y|X\}$.

Regra de Bayes e Utilidade Esperada

Suponha que um agente quer atualizar sua crença sobre uma alternativa $x \in X$, tendo em vista a observação de um dado m . Se ele atualizar sua crença segundo o Teorema de Bayes temos que:

$$p(x|m) = \frac{p(m|x)p(x)}{\int p(m|x)p(x)dx}$$

Um corolário de agentes que têm preferências e crenças consistentes é que vão agir segundo o *princípio da utilidade esperada* (BRIGGS, 2017). Para tal pressupõe-se que agentes vão ter uma relação de preferência sobre *apostas* (JEHLE, 2001), onde o conjunto de apostas $\mathcal{G}$ em $X = \{x_1, \dots, x_n\}$ é dado por:

$$\mathcal{G} \equiv \{(p_1 \circ x_1, \dots, p_n \circ x_n) | p_i \geq 0, \sum_{i=1}^n p_i = 1\}$$

Sendo assim, quando as alternativas são probabilísticas a utilidade $u : \mathcal{G} \rightarrow \mathbb{R}$ do agente é (JEHLE, 2001; BRIGGS, 2017):

$$u(\mathcal{G}) = \sum_{i=1}^n p_i u(x_i)$$

Apêndice B – Dos dados

A primeira ressalva metodológica em relação aos dados é que não aplicamos os pesos recomendados pelo *European Social Survey*. Isso significa que, dado o viés de seleção, as figuras representam o auto-posicionamento dos respondentes, mas não da população¹. Por não termos aplicado o peso que controla pelo tamanho das populações a Figura 4 não nos permite comparar o auto-posicionamento entre os países². Além de haver uma variação entre o tamanho das amostras, só representamos, obviamente, respostas válidas, embora houvesse opção de responder “Não sei”.

Países	N total	Fração de Respostas válidas
Alemanha	2919	0.93
Bélgica	1899	0.86
Dinamarca	1506	0.93
Eslovênia	1519	0.79
Espanha	1729	0.81
Finlândia	2000	0.95
França	1503	0.94
Grécia	2566	0.77
Hungria	1685	0.83
Irlanda	2046	0.83
Israel	2499	0.92
Luxemburgo	1552	0.77
Noruega	2036	0.98
Países Baixos	2364	0.95
Polônia	2110	0.83
Portugal	1511	0.80
Reino Unido	2052	0.91
Suécia	1999	0.95
Suíça	2040	0.92
Áustria	2257	0.86

Tabela 1 – Número de Entrevistados (N) para 20 países do ESS 2002

Fonte: Marcelo Veloso Maciel, 2018. Dados do *European Social Survey*.

Outra ressalva é que as respostas são discretas (0-10) enquanto a teoria e nosso modelo supõem pontos ideais num espaço contínuo.

¹ Escolhemos a Polônia para a Figura 3, contudo, por ser o país com a menor variância do peso pós-estratificação.

² Mesmo que tivéssemos aplicado o peso a comparação entre países usando um auto-posicionamento ideológico é complicada dado que a dimensão tem significados distintos em diferentes contextos (LAVER, 2014).

Apêndice C – Da implementação

O modelo foi implementado na linguagem Julia¹. Como discutido na página oficial da linguagem, o design da linguagem é pensado tendo em vista a computação científica, buscando tanto performance quanto legibilidade. Esse objetivo traduz-se numa sintaxe próxima à de Python ou Matlab², uma semântica procedural próxima a de Common Lisp e módulos-base para a construção e transformação de arranjos. Pragmaticamente, a linguagem é, portanto, familiar a usuários de Python-Matlab, mas com melhor performance.

Os scripts usados para implementação e análise do modelo, assim como qualquer³ material necessário para a replicação do trabalho estão no repositório: <https://github.com/marcelovmaciel/Projeto>. De qualquer forma, apresentamos o código base para replicar a simulação em Julia a seguir.

¹ Site oficial da linguagem: <https://julialang.org/>.

² Para uma comparação das sintaxes ver <https://cheatsheets.quantecon.org/>.

³ Com exceção dos dados do European Social Survey, os quais podem ser baixados no site <http://europeansocialsurvey.org/> . Não estão no github devido ao tamanho do arquivo.

O código base para a simulação está num módulo que contém os tipos e procedimentos necessários.

```
[3] module DyDeo2
using LightGraphs, MetaGraphs, Distributions, DataFrames
using Parameters, StatPlots, ProgressMeter, JLD2, StatsBase

# package code goes here
include("basefns.jl")
include("runfns.jl")

end # module
```

O arquivo **basefns.jl** contém o seguinte código:

```
[ ] #Structs for Agents and Beliefs -----

abstract type AbstractAgent end
abstract type AbstractBelief end

"Concrete type for Agents' beliefs;
comprised of opinion, uncertainty and an id (whichissue)"
mutable struct Belief{T1 <: Real, T2 <: Integer}
    o::T1
    σ::T1
    whichissue::T2
end

"""
    mutable struct Agent_o{T1 <: Integer, T2 <: Vector, T3 <: Real,
        T4 <: Vector, T5 <: Tuple} <: AbstractAgent

Concrete type for an Agent which only change its opinion.

Fields:
- id::Integer
- ideo:: Vector
- idealpoint::Real
- neighbors::Vector
- certainissues::Vector
- certainparams::Tuple

"""
```

```

mutable struct Agent_o{T1 <: Integer, T2 <: Vector, T3 <: Real,
                        T4 <: Vector, T5 <: Tuple} <: AbstractAgent
    id::T1
    ideo::T2
    idealpoint::T3
    neighbors::T4
    certainissues::T4
    certainparams::T5
end

"Concrete type for an Agent which changes both opinion and uncertainty"
mutable struct Agent_oo{T1 <: Integer, T2 <: Vector, T3 <: Real,
                        T4 <: Vector, T5 <: Tuple} <: AbstractAgent
    id::T1
    ideo::T2
    idealpoint::T3
    neighbors::T4
    certainissues::T4
    certainparams::T5
end

#= "Constructors" for Beliefs, Agents and Graphs
- All I need for the initial condition
=#
•

"""
    createbetaparams(popsiz::Integer)

Creates a list of parameters for posterior instantiation of Belief
"""
function createbetaparams(popsiz::Integer)
    αs = linspace(1.1, 100, popsiz) |> shuffle
    βs = linspace(1.1, 100, popsiz) |> shuffle
    betaparams = collect(zip(αs,βs))
    return(betaparams)
end

"""
    create_belief(σ::Real, issue::Integer, paramtuple::Tuple)

Instantiates beliefs;
note o is taken from a Beta while σ is global and an input
"""
function create_belief(σ::Real, issue::Integer, paramtuple::Tuple)
    o = rand(Beta(paramtuple[1],paramtuple[2]))
    belief = Belief(o, σ, issue)
end

```

```

function create_idealpoint(ideology)
    opinions = []
    for issue in ideology
        push!(opinions,issue.o)
    end
    ideal_point = mean(opinions)
end

"""
    create_agent(agent_type,n_issues::Integer,
    id::Integer,  $\sigma$ ::Real, paramtuple::Tuple)

Instantiates agents; something missing in terms of design
"""
function create_agent(agent_type,n_issues::Integer,
    id::Integer,  $\sigma$ ::Real, paramtuple::Tuple)

    ideology = [create_belief( $\sigma$ , issue, paramtuple) for
        issue in 1:n_issues ]
    idealpoint = create_idealpoint(ideology)

    if agent_type == "mutating o"
        agent = Agent_o(id,ideology, idealpoint,[0], [0], paramtuple)
    elseif agent_type == "mutating o and sigma"
        agent = Agent_oo(id,ideology, idealpoint,[0],[0], paramtuple)
    else
        println("specify agent type: mutating o or mutating o and sigma")
    end
    return(agent)
end

"""
    createpop(agent_type,  $\sigma$ ::Real, n_issues::Integer, size::Integer)

Creates an array of agents
"""
function createpop(agent_type,  $\sigma$ ::Real,
    n_issues::Integer, size::Integer)
    betaparams = createbetaparams(size)
    population = [create_agent(agent_type, n_issues,
        i, $\sigma$ , betaparams[i]) for i in 1:size]
end

"""
    createintransigents!(pop,propextremists::AbstractFloat)

turn some agents into extremists; that is,
given a number or proportion of extremists and
issues it makes the  $\sigma$  of some issues and some agents into  $\approx 0$  (1e-20)
"""
function createintransigents!(pop,propintransigents::AbstractFloat;
    position = "random")

```

```

n_issues = length(pop[1].ideo)
nintransigents = round(Int, length(pop) * propintransigents)

if position == "random"
  whichintransigents = sample(1:length(pop),nintransigents,
                             replace = false)
elseif position == "extremes"
  # gives an error if nintransigents > len(extremistsid)
  extremistsid = map( x-> x.id,
                      filter(x-> ( x.idealpoint < 0.2) ||
                                (x.idealpoint > 0.8),
                                pop))
  if nintransigents > length(extremistsid)
    error("there aren't enough agents on the extremes;
          try a lower prop_intran")
  else
    whichintransigents = sample(extremistsid,nintransigents,
                                replace = false)
  end
end

elseif position == "center"
  centristsid = map( x-> x.id,
                    filter(x-> ( x.idealpoint > 0.25) &&
                              (x.idealpoint < 0.75),
                              pop))
  if nintransigents > length(centristsid)
    error("there aren't enough agents on the center;
          try a lower prop_intran")
  else
    whichintransigents = sample(centristsid,nintransigents,
                                replace = false)
  end
end
else
  error("wrong position argument; correct: random,extremes,center")
end

for i in whichintransigents
  whichissues = sample(1:n_issues, 1,
                       replace = false)
  pop[i].certainissues = whichissues
  for issue in whichissues
    pop[i].ideo[issue].σ = 1e-20
  end
end
end

====
creategraphfrompop(population, graphcreator)

```

```

Creates a graph; helper for add_neighbors!
"""
function creategraphfrompop(population, graphcreator)
    graphsize = length(population)
    nw = graphcreator(graphsize)
    return(nw)
end

"""
    add_neighbors!(population, nw)

adds the neighbors from nw to pop; the fn neighbors is from LightGraphs
"""
function add_neighbors!(population, nw)
    for i in population
        i.neighbors = neighbors(nw,i.id)
    end
end

#= Interaction functions
=#
•
"""
    getjtointeract(i::AbstractAgent, population)
Chooses and returns a neighbor for i
"""
function getjtointeract(i::AbstractAgent, population)
    whichj = rand(i.neighbors)
    j = population[whichj]
end

"""
    pick_issuebelief(i::AbstractAgent, j::AbstractAgent)

Takes two agents and returns a tuple with:
* which issue they discuss
* i and j beliefs
"""
function pick_issuebelief(i::AbstractAgent, j::AbstractAgent)
    whichissue= rand(1:length(i.ideo))
    i_belief = i.ideo[whichissue]
    j_belief = j.ideo[whichissue]
    return(whichissue, i_belief, j_belief)
end

"""
    calculate_pstar(i_belief::Belief, j_belief::Belief, p::AbstractFloat)

helper for posterior opinion and uncertainty
"""
function calculate_pstar(i_belief::Belief,

```

```

        j_belief::Belief, p::AbstractFloat)
    numerator = p * (1 / (sqrt(2 * π) * i_belief.σ) ) *
    exp(-((i_belief.o - j_belief.o)^2 / (2*i_belief.σ^2)))
    denominator = numerator + (1 - p)
    p_p = numerator / denominator
    return(p_p)
end

"""
    calc_posterior_o(i_belief::Belief, j_belief::Belief,
p::AbstractFloat)

Helper for update_step
Input = beliefs in an issue and confidence paramater;
Output = i new opinion
"""
function calc_posterior_o(i_belief::Belief, j_belief::Belief,
p::AbstractFloat)
    p_p = calculate_pstar(i_belief, j_belief, p)
    posterior_opinion = p_p * ((i_belief.o + j_belief.o) / 2) +
        (1 - p_p) * i_belief.o
end

"""
    calc_pos_uncertainty(i_belief::Belief,
j_belief::Belief, p::AbstractFloat)
helper for update_step
"""
function calc_pos_uncertainty(i_belief::Belief,
j_belief::Belief, p::AbstractFloat)
    p_p = calculate_pstar(i_belief, j_belief, p)
    posterior_uncertainty = sqrt(i_belief.σ^2 * (1 - p_p/2) + p_p *
        (1 - p_p) *
        ((i_belief.o - j_belief.o)/2)^2)
end

"""
    update_o!(i::AbstractAgent, which_issue::Integer,
posterior_o::AbstractFloat)

    update_step for changing opinion but not belief
"""

function update_o!(i::AbstractAgent, which_issue::Integer,
posterior_o::AbstractFloat)
    i.ideo[which_issue].o = posterior_o
    newidealpoint = create_idealpoint(i.ideo)
    i.idealpoint = newidealpoint
end

"""

```

```

        update_oσ!(i::AbstractAgent,issue_belief::Integer,
posterior_o::AbstractFloat, posterior_σ::AbstractFloat)

update_step for the version with
changing opinions and changing uncertainty
"""
function update_oσ!(i::AbstractAgent,issue_belief::Integer,
    posterior_o::AbstractFloat, posterior_σ::AbstractFloat)
    i.ideo[issue_belief].o = posterior_o
    i.ideo[issue_belief].σ = posterior_σ
    newidealpoint = create_idealpoint(i.ideo)
    i.idealpoint = newidealpoint
end

"""
    updateibelief!(i::Agent_o, population, p::AbstractFloat )

Main update fn; has two methods depending on the agent type

"""
function updateibelief!(i::Agent_o, population, p::AbstractFloat )

    j = getjtointeract(i,population)
    whichissue,ibelief,jbelief = pick_issuebelief(i,j)
    pos_o = calc_posterior_o(ibbelief,jbelief, p)
    update_o!(i,whichissue,pos_o)
end

function updateibelief!(i::Agent_oσ, population,p::AbstractFloat )

    j = getjtointeract(i, population)
    whichissue,ibelief,jbelief = pick_issuebelief(i,j)
    pos_o = calc_posterior_o(ibbelief,jbelief, p)
    pos_σ = calc_pos_uncertainty(ibbelief, jbelief, p)
    update_oσ!(i,whichissue,pos_o, pos_σ)
end

"""
    p_update!(i::AbstractAgent, σ::AbstractFloat, p::AbstractFloat)

fn for noise updating; note it returns
a randomly taken  $o(t+1) = o(t) + r$ ,
but the new  $\sigma$  is the initial one
"""
function p_update!(i::AbstractAgent, p::AbstractFloat)
    whichissue = rand(1:length(i.ideo))
    r = rand(Normal(0,p))
    if (i.ideo[whichissue].σ != 1e-20)

```

```

        if i.ideo[whichissue].o + r > 1.0
            i.ideo[whichissue].o = 1.0
        elseif i.ideo[whichissue].o + r < 0.0
            i.ideo[whichissue].o = 0.0
        else
            i.ideo[whichissue].o += r
        end
        newidealpoint = create_idealpoint(i.ideo)
        i.idealpoint = newidealpoint
    end
end

```

Já o arquivo **runfns.jl** possui o seguinte código:

```

[ ] # Types needed for the simulation
•
"Parameters for the simulation; makes the code cleaner"
@with_kw struct DyDeoParam{R<:Real}
    n_issues::Int = 1
    size_nw::Int = 2
    p::R = 0.9
    σ::R = 0.1
    time::Int = 2
    ρ::R = 0.01
    agent_type::String = "mutating o"
    graphcreator = CompleteGraph
    propintransigents::R = 0.1
    intranpositions::String = "random"
end

## Information Storing Fns
#I'm going to initialize a dataframe and update it at each time step.
"""
    create_initialcond(agent_type, σ, n_issues, size_nw, graphcreator,
        propintransigents; intranpositions = "random")

this fn is a helper for all other fns used in the simulation
"""
function create_initialcond(agent_type, σ, n_issues,
    size_nw, graphcreator,
        propintransigents; intranpositions = "random")
    pop = createpop(agent_type, σ, n_issues, size_nw)
    g = creategraphfrompop(pop, graphcreator)
    add_neighbors!(pop, g)
    createintransigents!(pop, propintransigents,
        position = intranpositions)
    return(pop)
end

```



```

end

"""
    function createstatearray(pop,time)

Creates an array with the agents' ideal points;
it's an alternative to saving everything in a df

"""
function createstatearray(pop,time)
    statearray = Array{Array{Float64}}(time+1)'
    statearray[1] = pullidealpoints(pop)
    return(statearray)
end

"""
    create_initdf(pop)

fn to initialize the df; it should store all the info I may need later.
"""
function create_initdf(pop)
    df = DataFrame(time = Integer[], id = Integer[],
                   ideal_point = Real[])
    for agent in pop
        time = 0
        push!(df,[time agent.id agent.idealpoint ])
    end
    return df
end

"""
    update_df!(pop,df,time)

fn to update the df with relevant information.
"""
function update_df!(pop,df,time)
    for agent in pop
        push!(df,[time agent.id agent.idealpoint ])
    end
    return(df)
end

"self-describing... it takes a population and returns an array
of ideal points"
function pullidealpoints(pop)
    idealpoints = Float64[]
    for agent in pop
        push!(idealpoints,agent.idealpoint)
    end
    return(idealpoints)

```

```

end

"""
    outputfromsim(endpoints::Array)
fn to turn extracted information into system measures;
pressuposes an array with some system state (set of agents attributes)
"""

function outputfromsim(endpoints::Array)
    stdpoints = std(endpoints)
    num_points = endpoints |> countmap |> length
    return(stdpoints,num_points)
end

#= Running Functions
=#
•
"""
    agents_update!(population,p,  $\sigma$ ,  $\rho$ )

this executes the main procedure of the model:
one pair of agents interact and another updates randomly (noise).
"""

function agents_update!(population,p,  $\sigma$ ,  $\rho$ )
    updateibelief!(rand(population),population,p)
    p_update!(rand(population),  $\rho$ )
    return(population)
end

"""
    runsim!(pop,df::DataFrame,p, $\sigma$ , $\rho$ ,time)
this fn runs the main procedure iteratively while updating the df;
"""

function runsim!(pop,df::DataFrame,p, $\sigma$ , $\rho$ ,time)
    for step in 1:time
        agents_update!(pop,p,  $\sigma$ ,  $\rho$ )
        update_df!(pop,df,step)
    end
    return(df)
end

"""
    runsim!(pop,p, $\sigma$ , $\rho$ ,time)

runs the main procedure iteratively then returns the final population
"""

function runsim!(pop,p, $\sigma$ , $\rho$ ,time)
    for step in 1:time
        agents_update!(pop, p,  $\sigma$ ,  $\rho$ )
    end
end

```

```

    end
    return(pop)
end

"repetition of the sim for some parameters;"
function one_run(pa::DyDeoParam)
    @unpack n_issues, size_nw, p,  $\sigma$ , time,  $\rho$ ,
    agent_type, graphcreator, propintransigents, intranpositions = pa
    pop = create_initialcond(agent_type,  $\sigma$ , n_issues,
        size_nw, graphcreator, propintransigents,
        intranpositions = intranpositions)
    initdf = create_initdf(pop)
    df = runsim!(pop, df, p,  $\sigma$ ,  $\rho$ , time)
    return(df)
end

"""this runs the simulation without using any df;
this speeds up a lot the sim, but i can't keep track of
the system state evolution;
that is, I only save the end state
"""
function simple_run(pa::DyDeoParam)
    @unpack n_issues, size_nw, p,  $\sigma$ , time,  $\rho$ ,
    agent_type, graphcreator, propintransigents, intranpositions = pa
    pop = create_initialcond(agent_type,  $\sigma$ , n_issues,
        size_nw, graphcreator, propintransigents,
        intranpositions = intranpositions)
    endpop = runsim!(pop, p,  $\sigma$ ,  $\rho$ , time)
    return(endpop)
end

"""
    simstatesvec(pa::DyDeoParam)
runs the simulation and keeps each iteration configuration (ideal points)
"""
function simstatesvec(pa::DyDeoParam)
    @unpack n_issues, size_nw, p,  $\sigma$ , time,  $\rho$ ,
    agent_type, graphcreator, propintransigents, intranpositions = pa
    pop = create_initialcond(agent_type,  $\sigma$ ,
        n_issues, size_nw, graphcreator, propintransigents,
        intranpositions = intranpositions)
    statearray = createstatearray(pop, pa.time)

    for step in 1:time
        pop = agents_update!(pop, p,  $\sigma$ ,  $\rho$ )
        statearray[step+1] = pop |> pullidealpoints
    end
    return(statearray)
end

```

```

end

"""
    statesmatrix(statearray, time, size_nw)
    fn to turn the system configurations (its state) into a matrix.
    I need to plot the agents' time series.
    Takes a lot of time (10 min for 1.000.000 iterations and 1000 agents)
    """
function statesmatrix(pa; time = pa.time , size_nw = pa.size_nw)
    a = Array{Float64}(time+1,size_nw)
    statesvec = simstatesvec(pa)

    @showprogress 1 "Computing..." for (step,popstate) in enumerate(states)
        for (agent_indx,agentstate) in enumerate(popstate)
            a[step,agent_indx] = agentstate
        end
    end
    return(a)
end

"""
    sweep_sample(param_values; time = 250_000, agent_type = "mutating o")

    this fn pressuposes an array of param_values where each column is
    a param and each row is a parametization;
    Then it runs the sim for each parametization and pushes
    system measures to another array (the output array)
    """
function sweep_sample(param_values; size_nw = 500,
    time = 250_000, agent_type = "mutating o")
    Y = []
    @showprogress 1 "Computing..." for i in 1:size(param_values)[1]
        paramfromsaltelli = DyDeoParam(size_nw = round(Int,
            param_values[i,1]),
            n_issues = round(Int,
                param_values[i,2]),
            p = param_values[i,3],
            σ = param_values[i,4],
            ρ = param_values[i,5],
            propintransigents = param_values[i,6]
            time = time,
            agent_type = agent_type)

        out = (simple_run(paramfromsaltelli) |>
            pullidealpoints |>
            outputfromsim)
        push!(Y,out)
    end
    return(Y)
end

```

```

"""
    function getsample_initcond(param_values; time = 250_000,
agent_type = "mutating o")
returns Initstd and Initnips (outputfromsim from initialcond)
"""

function getsample_initcond(param_values; time = 250_000,
    agent_type = "mutating o")

    param_values[:,1] = round.(Int,param_values[:,1])
    param_values[:,2] = round.(Int,param_values[:,2])
    Y = Tuple{Float64,Int64}[]

    @showprogress 1 "Computing..." for i in 1:size(param_values)[1]
        paramfromsaltelli = DyDeoParam(size_nw = convert(Int,
            param_values[i,1]),
            n_issues = convert(Int,
            param_values[i,2]),
            p = param_values[i,3],
            σ = param_values[i,4],
            ρ = param_values[i,5],
            propintransigents = param_values[i,6],
            time = time,
            agent_type = agent_type)
        @unpack n_issues, size_nw, p, σ,
            time, ρ, agent_type, graphcreator,
            propintransigents, intranpositions = paramfromsaltelli
        pop = create_initialcond(agent_type, σ,
            n_issues, size_nw, graphcreator, propintransigents,
            intranpositions = intranpositions)
        out = pop |> pullidealpoints |> outputfromsim
        push!(Y,out)
    end
    return(Y)
end

function extractys(Ypairs)
    Ystd = Float64[]
    Ynips = Int64[]
    for i in Ypairs
        push!(Ystd,i[1])
        push!(Ynips,i[2])
    end
    return(Ystd,Ynips)
end

"""
function multiruns(sigmanissues::Tuple; repetitions = 50)

```

```

    helper function to plot the box plots
    """
    function multiruns(sigmanissues::Tuple; repetitions = 100)
        pa = DyDeoParam(n_issues = sigmanissues[1],
                         $\sigma$  = sigmanissues[2],
                        size_nw = 500,
                        time = 1_000_000,
                        p = 0.9,
                         $\rho$  = 1e-5,
                        propintransigents = 0.0,
                        intranpositions = "random")

        repetitionsout = Array{Float64}[]

        @showprogress 1 "Multiruns" for run in 1:repetitions
            singleout = simple_run(pa) |> pullidealpoints
            push!(repetitionsout, singleout)
        end
        return(repetitionsout)
    end

    function mkdirs(filename)
        !(filename in readdir(pwd())) ? mkdir(filename):
        println("dir $(filename) exists... no need to create one ")
    end

```

Arquivos usados na análise da simulação estão no repositório.

Apêndice D – Gráficos e tabelas complementares

Tabela 2 – Índices de Sobol e coeficientes de erro correspondentes para análise de sensibilidade com 70.000 parametrizações.

	S1	S1_conf	ST	ST_conf
N	0.004881	0.006388	0.022210	0.003495
n_issues	0.186464	0.025251	0.234629	0.014013
p	0.063561	0.015413	0.115790	0.009160
σ	0.462022	0.035358	0.576110	0.029141
ρ	0.129280	0.018281	0.242048	0.016394
p_intran	0.000949	0.004267	0.011563	0.001754

Fonte: Marcelo Veloso Maciel, 2018.

Tabela 3 – Índices de Sobol de segunda ordem (S2) para análise de sensibilidade com 70.000 parametrizações.

	N	n_issues	p	σ	ρ	p_intran
N	NaN	0.001927	0.002175	0.006913	0.000713	0.000511
n_issues	NaN	NaN	0.003479	0.002571	0.029061	0.007587
p	NaN	NaN	NaN	0.021056	0.009098	0.002245
σ	NaN	NaN	NaN	NaN	0.043554	0.005111
ρ	NaN	NaN	NaN	NaN	NaN	-0.006991
p_intran	NaN	NaN	NaN	NaN	NaN	NaN

Fonte: Marcelo Veloso Maciel, 2018.

Figura 18 – Gráfico de dispersão e regressões polinomiais para 70.000 parametrizações.

Fonte: Marcelo Veloso Maciel, 2018.