Universidade de São Paulo
Escola de Artes, Ciências e Humanidades
Programa de Pós-Graduação em Modelagem de
Sistemas Complexos

Paulo dos Santos França

Comunidades Epistêmicas Artificiais: O Papel da
Confiança na Comunidade Científica

São Paulo
2017

Paulo dos Santos França

Comunidades Epistêmicas Artificiais: O Papel da Confiança na Comunidade Científica

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

Versão corrigida contendo as alterações solicitadas pela comissão julgadora em 28 de setembro de 2017. A versão original encontra-se em acervo reservado na Biblioteca da EACH/USP e na Biblioteca Digital de Teses e Dissertações da USP (BDTD), de acordo com a Resolução CoPGr 6018, de 13 de outubro de 2011.

Área de concentração: Ciências Sociais e Ambientais Aplicadas

Orientador: Prof. André Cavalcanti Rocha Martins

São Paulo

2017

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)

França, Paulo dos Santos

Comunidades epistêmicas artificiais : o papel da confiança na comunidade científica / Paulo dos Santos França ; orientador, André Cavalcanti Rocha Martins. – 2017.

51 p. : 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 corrigida.

1. Ciências sociais - Simulação; Modelagem. 2. Inferência Bayesiana. 3. Redes complexas. 4. Sistemas dinâmicos. I. Martins, André Cavalcanti Rocha, orient. II. Título

CDD 22.ed.– 300.11

Paulo dos Santos França
**Comunidades Epistêmicas Artificiais: O Papel da Confiança na
Comunidade Científica**

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

Área de concentração: Ciências Sociais e Am-
bientais Aplicadas

Aprovado em 28 de Setembro de 2017.

Banca Examinadora

Prof. Dr. Renato Vicente
Instituto de Matemática e Estatística - Universidade de São Paulo

Prof. Dr. José Raymundo Novaes Chiappin
Faculdade de Economia, Administração e Contabilidade - Universidade de São Paulo

Nuno Miguel Melo Crokidakis Peregrino
Instituto de Física - Universidade Federal Fluminense

Prof. Dr. André Cavalcanti Rocha Martins (Presidente)
Escola de Artes Ciências e Humanidades - Universidade de São Paulo

Resumo

FRANÇA, Paulo S. **Comunidades Epistêmicas Artificiais: O Papel da Confiança na Comunidade Científica**. 2017. 50 f. Dissertação (Mestrado) - Escola de Artes, Ciências e Humanidades, Universidade de São Paulo, São Paulo, 2017. Versão Corrigida.

O estudo de sistemas complexos nos ajuda a entender como regras locais simples podem gerar padrões agregados complexos e muitas vezes inesperados. Quando as regras são bem definidas e os padrões observáveis, o sistema pode ser modelado e seus resultados comparados. Um dos maiores desafios para a modelagem de sistemas complexos é definir a regra de interação responsável pelo comportamento complexo. Em dinâmica de opiniões, padrão complexo e inesperado pode ser o súbito consenso ou até mesmo a polarização, e objetivo, então, se torna verificar em que circunstâncias podemos observar pessoas concordarem ou discordarem. Embora haja uma série de modelos de dinâmica de opiniões para descrever como as pessoas interagem, cada um define a regra de formação da opinião de forma *ad hoc*. O modelo CODA (*Continuous opinions and Discret Actions*) propõe uma fundamentação teórica para os modelos de dinâmica de opiniões baseada em teoria de probabilidade. Suas aplicações se estendem desde estudos sobre inovação à epistemologia. Nesta dissertação, aprofundamos os estudos de epistemologia que envolvem o CODA, investigando principalmente o efeito da confiança no processo de confirmação científica. Nossas simulações corroboram investigações sociológicas e históricas sobre o papel fundamental da confiança no processo de aquisição e geração do conhecimento.

Palavras-chave: Dinâmica de Opiniões. CODA. Teorema de Bayes. Confiança. Teoria da Confirmação.

Abstract

FRANÇA, Paulo S. **Artificial Epistemic Communities: The Role of Trust in the Scientific Community.** 2016. 50 f. Dissertation (Master degree). Escola de Artes, Ciências e Humanidades, Universidade de São Paulo, São Paulo, 2016. Corrected Version.

The study of complex systems helps us understand how simple local rules can generate complex and often unexpected aggregate patterns. When the rules are well defined and patterns observed, the system can be modeled and its results compared. One of the major challenges for modeling complex systems is to define a rule of interaction responsible for complex behavior. In opinion dynamics, complex and unexpected pattern may be the sudden consensus or even a polarization, so the aim it is to verify under what circumstances we can observe agreement or disagreement. Although there are a number of models of opinion dynamics to describe how people should interact with each other, each one defines an *ad hoc* opinion formation rule. The model of opinion dynamics CODA (Continuous Opinions and Discret Actions) proposes a theoretical framework for the models of opinion dynamics, based on probability theory. Their applications range from studies on innovation to epistemology. In this dissertation, we deepen the studies of epistemology that involve the CODA, investigating mainly the effect of the trust in the process of scientific confirmation. Our simulations corroborates sociological and historical researches on the role of trust in the process of acquisition and generation of knowledge.

Keywords: Opinion Dynamics. CODA. Bayes' Theorem. Trust. Confirmation Theory.

Lista de ilustrações

Figura 1 – A hipótese H se sustenta se qualquer um dos candidatos na área hachurada ganhar.	14
Figura 2 – Representação da árvore de decisão para o CODA. Através dela conseguimos visualizar como obtemos a verossimilhança.	33
Figura 3 – Representação da árvore de decisão para o CODA com confiança. τ é a probabilidade de que j seja confiável e μ é a probabilidade de que j faça a escolha correta quando este não é confiável. Semelhantemente, $1 - \tau$ é a probabilidade de que j não seja confiável, e $1 - \mu$ é a probabilidade de que j faça escolha errada quando, na verdade, ele é confiável.	35
Figura 4 – Dinâmica das médias das opiniões ao longo do tempo. No Gráfico a esquerda (a), 35% da comunidade científica realiza experimentos, enquanto que no Gráfico (b) apenas 10%. As linhas correspondem a diferentes níveis de influência social, baixa, média e alta. Os resultados são para $\tau_{ij} = 0,7$	39
Figura 5 – Evolução das opiniões contínuas ao longo do tempo. Do lado esquerdo estão os gráficos que representam as opiniões sobre as teorias, enquanto que do lado direito a confiança dos cientistas. O eixo Y representa cada classe m_i de um total de 25 classes. As cores representam o log frequência de cada classe, variando do vermelho (alta frequência) ao branco (nenhuma frequência). Nos gráficos da parte superior, apenas 10% dos cientistas realizam experimentos, enquanto que na parte debaixo, 35% dos cientistas realizam experimentos. Os efeitos sociais para ambos os casos são os mesmo ($\rho = 0,9$) e a confiança foi inicializada em $\tau_{ij} = 0,7$ para toda comunidade científica.	40
Figura 6 – Evolução das opiniões contínuas ao longo do tempo. Do lado esquerdo estão os gráficos que representam as opiniões sobre as teorias, enquanto que do lado direito a confiança dos cientistas. O eixo Y representa cada classe m_i de um total de 25 classes. As cores representam o log frequência de cada classe, variando do vermelho (alta frequência) ao branco (nenhuma frequência). Nos gráficos da parte superior, apenas 10% dos cientistas realizam experimentos, enquanto que na parte debaixo, 35% dos cientistas realizam experimentos. Os efeitos sociais para ambos os casos são os mesmo ($\rho = 0,9$) e a confiança foi inicializada em $\tau_{ij} = 0,5$ para toda comunidade científica.	41

Figura 7 – Desvio padrão das opiniões. Os quadrados variam entre o preto (desvio padrão igual à zero, consenso) e o branco (padrão igual à 0.5, polarização). Simulações para $\tau_{ij} = 0.5$	42
Figura 8 – Proporção dos cientistas em favor da teoria correta em função da confiança inicializada nos cientistas para três casos distintos: opiniões em relação à teoria dispersas, próximas e extremas. Todas geradas a partir de uma distribuição uniforme, sendo que para opiniões dispersas $0.01 \leq p \leq 0.99$, para opiniões próximas $0.4 \leq p \leq 0.6$ e para opiniões extremas p se encontra em duas regiões distintas: $0 \leq p \leq 0.01$ e $0.99 \leq p \leq 1$. Cada quadrante representa diferentes níveis de influência social ou de proporção de cientistas experimentadores.	43

Sumário

1	INTRODUÇÃO	8
2	INTERPRETAÇÃO SUBJETIVA DE PROBABILIDADE . .	11
2.1	Elementos de Cálculo de Probabilidade	11
2.2	Crenças Probabilísticas	13
2.3	Crenças Consistentes	13
2.4	Teorema de Bayes	17
3	RACIOCÍNIO HUMANO E PROBABILÍSTICO	20
4	CONFIRMANDO TEORIAS	22
5	ASPECTOS SOCIAIS DA CIÊNCIA	24
5.1	O Papel da Confiança	26
6	MODELO DE DINÂMICA DE OPINIÕES CODA	30
6.1	CODA com Confiança	34
6.2	CODA na Comunidade Científica	36
6.3	Introdução da Confiança na Comunidade Científica	37
7	SIMULAÇÕES	38
8	CONSIDERAÇÕES FINAIS	45
	REFERÊNCIAS	47

1 Introdução

Epistemologia é o ramo da ciência que estuda as formas pelas quais fazemos e adquirimos conhecimento. O conhecimento científico é uma consequência direta do nosso conhecimento ordinário (POPPER, 2014) (POPPER, 2005), e o que o torna de algum modo especial é a forma como as ideias são justificadas frente à uma organização social muito específica.

No meio científico existe uma estrutura muito eficaz na geração do conhecimento, uma estrutura que tende a promover os trabalhos mais inovadores e a punir severamente cientistas que, por descuido ou incompetência, são mal sucedidos em suas empreitadas (WHITLEY, 2000). Sem nenhum controle central, a comunidade científica consegue se organizar para produzir um conhecimento que aumente nosso poder de explicação sobre o universo, se baseando, para isso, em normas e procedimentos formais e informais, estabelecidos em um ambiente institucional bem definido.

Apesar dos benefícios associados aos avanços científicos serem evidentes, a estrutura organizacional da ciência está longe fornecer mecanismos ideais para geração do conhecimento. Argumentos mais radicais, por exemplo, afirmam que o conhecimento científico em nada se difere da cultura popular. Como é o caso do *Strong Programme*, uma agenda de pesquisa que entende a geração do conhecimento como consequência de fatores puramente sociais (MARTINS, 2013a).

Este trabalho não parte dos mesmo princípio do *Strong Programme*, embora assumimos que os efeitos sociais em ciência existam. O carácter social da produção científica começa a ficar mais evidente no decorrer do século passado, com o surgimento do que ficou conhecido como *Big Science*, grandes projetos de pesquisa fomentados principalmente pelo governo, como no caso do *Projeto Manhattan*. Solla Price mencionava essa tendência ao observar uma queda no número publicações com apenas um autor nos anos de 1960 (PRICE; PRICE, 1965). Se a produção científica já dependia das relações sociais estabelecidas muito antes dos grandes projetos, hoje, com a especialização do cientista e com o surgimento da carreira acadêmica esta dependência está ainda mais evidente.

O que permite essa interdependência é confiança. Cientistas recorrem ao consenso para legitimar seu discurso, correndo o risco de confiar em instituições ou pessoas que dificilmente podem avaliar. Por isso, confiar também é correr um risco, pois as ações ou julgamentos praticados por aqueles que confiamos podem afetar diretamente nossas ações e performances (CREASE, 2004).

Nesse sentido, o desenvolvimento da ciência dificilmente se daria sem a confiança. Em Shapin (1994) é possível encontrar uma descrição do surgimento de uma ciência

moderna baseada em códigos e convenções cortesias, como civilidade, honra e integridade. Sem a confiança nesse tipo de conduta dificilmente teríamos uma organização científica tal como conhecemos. Sociólogos argumentam que nesse caso a confiança funciona como um mecanismo de coesão social entre os grupos (GOVIER, 1997).

Se por um lado, a forma como a ciência se organiza exige um esforço coletivo para a existência da cooperação entre seus membros, por outro, o trabalho científico é uma empreitada árdua, muitas vezes desenvolvida em plena solidão e de forma monótona, em que o cientista deve coletar evidências de forma sistemática, extrair o máximo de informações possíveis delas para comparar com as teorias disponíveis e, eventualmente, propor outras que melhor se ajustem às evidências. Embora haja modelos e procedimentos indicando a melhor forma julgar teorias frente às nossas observações, as limitações cognitivas e dos recursos inviabilizam a verificação e implementação de práticas consideradas ideais no meio científico. Epistemólogos que lidam com a forma pela qual uma teoria *deveria* ser confirmada pelas evidências, são aqueles que estão em busca de uma *teoria da confirmação*.

Temos, portanto, duas dimensões do processo de confirmação científica: uma associada ao julgamento individual de cada cientista frente ao objeto de estudo, e outra social, que condiciona as opiniões do meio científico dependendo das relações estabelecidas nesta comunidade. A proposta neste trabalho é elaborar um modelo que descreva o processo de confirmação científica no nível individual e no âmbito social, levando em consideração principalmente a confiança entre os cientistas. Para isso, a estratégia aqui adotada é a de fazer o uso do modelo de dinâmica de opiniões de ação discreta e opinião contínua, o CODA (*Continuous Opinions and Discrete Actions*). Assim, haverá duas teorias concorrentes em nossa comunidade artificial e os cientistas irão buscar confirmar suas crenças subjetivas sobre elas, definidas em termos probabilidades, num processo de interação social. Para que as crenças subjetivas dos cientistas em relação às hipóteses e evidências sejam consideradas racionais os axiomas de probabilidade devem ser assegurados.

O CODA foi utilizado tanto em trabalhos que visavam capturar efeitos sociais em ciência (MARTINS, 2013a) (MARTINS, 2010) quanto em um trabalho envolvendo confiança (MARTINS, 2013b), ainda que de formas independentes. Nosso objetivo aqui é unificar esses trabalhos explorando os efeitos da confiança na estrutura social e na dinâmica da comunidade científica. Mais precisamente, estamos interessados em averiguar em que circunstância os cientistas podem chegar ao consenso sobre uma teoria científica, levando em consideração principalmente o papel da confiança nesse processo.

Do ponto de vista do agente, nosso modelo contará com uma fundamentação de teoria de probabilidade (MARTINS, 2012). Já a estrutura social da comunidade científica será desenvolvida com base nos trabalhos que já fizeram uso do CODA envolvendo epistemologia (MARTINS, 2013a) (MARTINS, 2010) e confiança (MARTINS, 2013b), além também de trabalhos pioneiros em sociologia da ciência (MERTON, 1973) (MERTON,

1969). Com este intuito, esta dissertação se dividirá em mais 7 Capítulos além da introdução. No Capítulo seguinte, explicaremos os axiomas de probabilidade e buscaremos entender os requisitos para que a crença dos agentes possa ser considerada consistente. Como raciocínio probabilístico muitas vezes não é intuitivo, compreender melhor a sua relação com o raciocínio humano é uma tarefa necessária, e é disto que trataremos no Capítulo 3. No Capítulo 4, veremos como o raciocínio probabilístico pode ser útil para confirmar teorias científicas, além de explorarmos algumas críticas sobre esta abordagem. Em seguida, trataremos de entender melhor os aspectos sociais da ciência, ressaltando principalmente o papel da confiança. Já no Capítulo 6, explicitaremos a elaboração do CODA, bem como a sua utilização no nosso modelo. No Capítulo 7, apresentaremos os resultados das simulações, enquanto que no Capítulo 8 apresentaremos nossas considerações finais.

2 Interpretação Subjetiva de Probabilidade

Como a teoria bayesiana da confirmação é construída com base na teoria da probabilidade, começaremos esse Capítulo apresentando alguns elementos de cálculo de probabilidade úteis para o desenvolvimento dos argumentos subsequentes. Embora o que se segue seja o conteúdo comum que se encontra em livros texto de probabilidade sob uma abordagem frequentista, o entendimento de probabilidade sob uma perspectiva bayesiana também se faz pelos mesmos axiomas, distinguindo somente na interpretação (SAVAGE, 1972). A subseção seguinte é baseada em Venkatesh (2012) e Rosenthal (2006).

2.1 Elementos de Cálculo de Probabilidade

Um espaço de probabilidade, ou espaço mensurável, é composto pela tríplice $(\Omega, \mathcal{F}, P)$, em que

Ω é o espaço amostral, pode ser qualquer conjunto não vazio.

$\mathcal{F}$ é uma família de eventos que incluem todas as combinações possíveis permitidas pelo espaço amostral.

P é uma medida de probabilidade que identifica uma $\mathcal{F}$ específica.

Qualquer família de eventos não vazia $\mathcal{F}$ determina um conjunto álgebra, a qual é fechada sob operações entre conjuntos. Mas em probabilidade, $\mathcal{F}$ ser fechado sobre operações entre conjuntos não é o suficiente, ele precisa ser também contável.

Definição 1 *Uma $\mathcal{F}$ σ -álgebra é uma coleção de conjuntos ou eventos mensuráveis e deve satisfazer 3 condições:*

1. Se $A_1, A_2, A_3, \dots, A_n, \dots \subseteq \Omega$ e se $A \in \mathcal{F}$, então, $A^c \in \mathcal{F}$.
2. Se $A_1, A_2, A_3, \dots, A_n, \dots \subseteq \Omega$ e se $A_i \in \mathcal{F}$, então, $\bigcup_{i \geq 1} A_i \in \mathcal{F}$.
3. Se $A_1, A_2, A_3, \dots, A_n, \dots \subseteq \Omega$ e se $A_i \in \mathcal{F}$, então, $\bigcap_{i \geq 1} A_i \in \mathcal{F}$ ¹.

Assim, uma σ -álgebra $\mathcal{F}$ contém Ω e é fechado sobre complementares, uniões e intersecções contáveis. O prefixo σ é utilizado para dizer que a álgebra dos conjuntos é

¹ Embora a definição esteja redundante, já que se $\mathcal{F}$ é fechado sobre complementares e uniões contáveis, então ele também é fechado sobre intersecções contáveis (lei de Morgan), decidimos explicitar a definição em sua forma mais elementar.

fechada sob operações de números infinitos contáveis². O motivo pelo qual $\mathcal{F}$ necessita ser fechado sobre operações contáveis é a possibilidade de trabalharmos com limites em teoria da probabilidade.

Uma medida de probabilidade é um mapa $A \mapsto P(A)$ que para cada evento A pertencente a $\mathcal{F}$ atribui um valor $P(A)$. Ou seja, $P : \mathcal{F} \rightarrow \mathbb{R}$ é uma função e deve satisfazer os seguintes axiomas:

Axioma 1 *Positividade:* $P(A) \geq 0$ para todo evento $A \in \mathcal{F}$.

Axioma 2 *Normalização:* $P(\Omega) = 1$

Axioma 3 *Additividade:* suponha que A e B sejam eventos disjuntos, $A \cap B = \emptyset$. Então $P(A \cup B) = P(A) + P(B)$.

A abordagem frequentista se baseia em uma idealização matemática de repetidos experimentos realizados de forma independente. Por exemplo, se a ocorrência de A é verificada m vezes em n tentativas independentes, é comum pensarmos que a frequência relativa $\frac{m}{n}$ de A como uma medida de probabilidade. Sendo assim, $\frac{m}{n}$ deve satisfazer os axiomas acima. Portanto, $0 \leq \frac{m}{n} \leq 1$, de acordo com os axiomas 1 e 2, o que é bem intuitivo quando pensamos nas chances de ganho em jogos no geral. E se pensarmos que a ocorrência de dois eventos mutuamente exclusivos, A e B , por exemplo, se dão m_1 e m_2 vezes, respectivamente, em n tentativas independentes, então a probabilidade observar ou A ou B será $\frac{m_1+m_2}{n} = \frac{m_1}{n} + \frac{m_2}{n}$.

Assumindo continuidade³, o axioma 3 permite estender o princípio da aditividade de uma coleção finita de conjuntos disjuntos para uma coleção de infinitos contáveis disjuntos, chegando assim no princípio da aditividade contável.

Theorem 1 *Se $\{A_{n,n \geq 1}\}$ é uma sequência pareada de eventos disjuntos em algum espaço de probabilidade, então $P(\cup_{n=1}^{\infty} A_n) = \sum_{n=1}^{\infty} P(A_n)$*

A prova pode ser conferida em Venkatesh (2012). O princípio da aditividade contável, apresentado na forma de teorema, é apenas uma versão mais forte do terceiro axioma. Embora maior parte da nossa discussão se restrinja a $n = 2$, nada impede trabalharmos com $n > 2$. No nosso modelo, n é o número de teorias concorrentes.

² Um conjunto S é dito infinito se contém um subconjunto próprio S' que possa ser posto em correspondência biunívoca com o conjunto S . Um conjunto é dito infinito contável se pode ser posto em correspondência biunívoca com os naturais. Neste caso, também se diz que o conjunto é enumerável.

³ Suponha que $A_1, A_2, \dots$ é uma sequência de eventos decrescendo monotonicamente para um conjunto vazio: isto é, $A_n \supseteq A_{n+1}$ para todo n e $\cap_{n \geq 1} A_n = \emptyset$. Então $P(A_n) \rightarrow 0$ quando $n \rightarrow \infty$.

2.2 Crenças Probabilísticas

A interpretação de probabilidade como uma medida que descreve o estado do conhecimento, independente de um experimento físico baseado em tentativas independentes, é uma interpretação subjetiva de probabilidade. Ainda assim, a fundamentação teórica embutida na noção de probabilidade subjetiva não contradiz os axiomas probabilidade, ela apenas busca um fundamento lógico robusto que permita sua extensão às aplicações ainda necessárias, como em casos em que não podemos reproduzir experimentos sob condições minimamente idênticas⁴. Jogos de futebol, corridas de cavalo e o próprio mercado de ações são bons exemplos deste tipo de experimento.

A abordagem subjetivista em probabilidade tem suas origens nos trabalhos de Ramsey (1931) e de Finetti (1992). A ideia é fornecer uma lógica para o desenvolvimento de uma teoria de probabilidade. E aqui, probabilidade é uma medida de crença que serve como base para a tomada de decisão. Como estamos interessados em descrever como cientistas escolhem suas teorias, nosso debate envolve também uma discussão sobre a teoria da decisão.

A teoria da decisão visa fornecer modelos teóricos para a tomada de decisão em situações sob incerteza. E se tratando de incertezas, nada mais natural do que trabalharmos com probabilidades. Mas definir crenças em termos de probabilidade também impõe algumas restrições, de tal forma que, se estas forem satisfeitas, as crenças probabilísticas serão consideradas consistentes. Recentemente, esta é uma literatura que tem ganhado contribuições significativas a partir dos trabalhos de Jeffrey (2004), Jaynes (2003) e entre outros discutidos na seção seguinte.

2.3 Crenças Consistentes

Não somos capazes ainda de dizer definitivamente se há ou não vida em Marte. Ainda assim, podemos fazer conjunturas e expressar nossa opinião ao ponto de se fazer uma aposta de que há vida inteligente ou ao menos de que há vida em Marte. Assim, digamos que suas chances de haver vida em marte são de 1:9 e de haver vida inteligente é de 1:999. Isso significa que não há vantagem nenhuma para arriscar um real para ganhar nove no caso de haver vida em marte e o mesmo raciocínio se aplica a aposta de haver vida inteligente em marte. Ou seja, não valeria a pena apostar quando o risco é um milésimo dos mesmos dez reais reais (1 centavo) quando o ganho é de 999 milésimos (R\$ 9.99).

As chances, nesse sentido, medem um nível de incerteza na aposta. Por isso o

⁴ Como no caso de lançamento de moedas e dados, por exemplo.

conceito de chances está também relacionado com probabilidades. Assim, temos que,

$$m : n \text{ corresponde à probabilidade } \frac{m}{m+n}. \quad (2.1)$$

Em que, $m : n$ ⁵ é uma relação que vem do julgamento das chances relativas de uma hipótese e sua negação, também é conhecida simplesmente como chances⁶. O quociente $\frac{m}{m+n}$ é uma normalização das chances e é chamado de coeficiente de aposta. Assim, a probabilidade subjetiva corresponde à um coeficiente *justo* de aposta, sendo que *justo* aqui implica que a crença probabilística de fato balança o risco entre os lados da aposta (HOWSON; URBACH, 2006).

Podemos também pensar o exemplo acima da seguinte forma: Você estaria disposto a pagar 1 real num bilhete que vale 10 reais se existisse vida em marte, e não pagaria nada caso contrário. De forma semelhante, você acharia que 1 centavo é o preço que se deveria pagar num bilhete que também vale 10 reais, caso exista vida inteligente em marte, e não daria nada caso não existisse.

Assim, se você tiver um julgamento probabilístico exato em relação a veracidade de uma hipótese, isso implica que o valor de um bilhete para você é 1 ou 0, dependendo se a hipótese for verdadeira ou falsa. Note que no exemplo acima 1 corresponde ao valor do bilhete, 10 reais.

Considere agora que a probabilidade p de a hipótese H , de que um candidato honesto ser eleito, é $q + r + s$. A figura 1 mostra a listas de candidatos que podem vencer, sendo que os honestos são os candidatos A , B e C , e a probabilidade de cada um ganhar é q , r e s , respectivamente.

Figura 1 – A hipótese H se sustenta se qualquer um dos candidatos na área hachurada ganhar.

Seguindo o mesmo raciocínio do exemplo anterior, temos quatro bilhetes, cada um com o preço atribuído correspondente a sua probabilidade. O interessante aqui é que se A ou B ou C ganhar, então H também ganha, ao passo que se H não ganhar é porque A , B , e C também não ganharam. Portanto, se o preço do bilhete H for diferente da soma dos outros três, há uma *inconsistência* no sentido haver dois valores para um mesmo contrato, dependendo de como ele vir a ser apresentado.

⁵ Lê-se " m para n ".

⁶ tradução livre para *betting odds*.

A noção de consistência aqui é muito importante⁷, pois conseguimos justificar leis de probabilidade se demonstrarmos que apostas que as violam são inconsistentes. A justificação vem do que é conhecido como argumentos de *Dutch book*. O termo *Dutch Book* tem origem nas corridas inglesas, em que *book* é um conjunto de apostas feitas por um *bookmaker* e um *book* contra alguém, ou seja, um *Dutch book*, é aquele em que o *bookmaker* terá alguma perda líquida, não importando resultado final. Assim, dizemos que as pessoas as quais as chances não satisfazem os axiomas de probabilidade estão sujeitas sofrerem um *Dutch book*. Mais precisamente, o Teorema de *Dutch Book*, apresentado originalmente por de Finetti (HOWSON; URBACH, 2006), afirma que,

Definição 2 *Os coeficientes de aposta não geram nenhuma perda ou ganho líquido numa aposta, independente dos valores lógicos das proposições apostadas, se e somente se, eles satisfazerem os axiomas de probabilidade de forma finitamente aditiva*⁸.

No contexto do exemplo dos candidatos honestos, qualquer crença probabilística que implicasse na desigualdade $p \neq q + r + s$ seria inconsistente, pois isso significaria que existiria duas probabilidades distintas sendo atribuídas à mesma hipótese. Se esse for o caso, dizemos que as crenças são inconsistentes. Apesar deste exemplo se basear explicitamente no princípio da aditividade, qualquer um dos axiomas de Kolmogorov que sejam violados podem levar ao *Dutch book*.

Embora todos os adeptos dos métodos bayesianos concordem que a crença dos agentes deva satisfazer as regras do cálculo de probabilidade, há uma divergência entre aqueles que advogam por uma interpretação subjetiva de probabilidade e outros por uma interpretação objetiva. Enquanto que para os primeiros, o argumento de *Dutch book* é condição necessária e suficiente para manter a racionalidade da crença dos agentes e, portanto, garante sua convergência ao longo do tempo, o segundo grupo, por outro lado, *geralmente* sustenta que coerência é condição necessária, embora não seja suficiente⁹ (BANDYOPADHYAY; FORSTER, 2011). Mas também há desacordo entre os próprios subjetivistas. Howson, por exemplo, rejeita a teoria da utilidade, enquanto Maher (1993) e Jeffrey (2004) já a incorpora em seus argumentos.

Jaynes (2003) chega as mesmas conclusões de de Finetti, mas fazendo o uso do teorema de Cox em vez dos Axiomas de Kolmogorov, derivando teoria de probabilidade

⁷ Ramsey afirma que Leis de Probabilidade são leis de consistência, no sentido de que elas são necessariamente verdades para qualquer conjunto consistente de crenças. Assim, Ramsey deriva probabilidades a partir de preferências racionais. Portanto, a crença é inconsistente no sentido de violar tais preferências entre as opções disponíveis.

⁸ Como notado mais recentemente por Jeffrey (JEFFREY, 2004), mesmo nos casos em que hajam infinitas probabilidades alternativas (aditividade contável e não somente finita) o princípio da aditividade ainda é assegurado, desde que o conjunto não seja muito grande.

⁹ Na visão bayesiana objetiva, além dos axiomas de probabilidade duas normas epistêmicas devem ser satisfeitas: Calibração e Equivocação (BANDYOPADHYAY; FORSTER, 2011).

com base em três desideratas¹⁰ básicas:

Desiderata I Os graus de plausabilidade devem ser representados por números reais.

Desiderata II Correspondência qualitativa com o senso comum.

Desiderata III Consistência.

A desiderata I nos diz que deve haver uma correspondência entre graus de plausabilidade e os números reais, de tal forma que plausabilidade infinitesimalmente grande deve ser representada por um número infinitesimalmente grande. Mas a plausabilidade sobre determinada assertiva A, depende se B, por exemplo, é verdadeiro, caso em que temos uma probabilidade condicional ($A|B$). A desiderata II significa simplesmente respeitar a lógica aristotélica, ao passo que a desiderata III deixa claro como uma pessoa honesta deveria raciocinar:

Desiderata IIIa Se há a possibilidade de chegar à uma mesma conclusão de várias formas, então cada possibilidade deve levar ao mesmo resultado.

Desiderata IIIb Não deve haver vieses em relação às seletividade das evidências. Toda evidência relevante ao problema deve ser levada em consideração.

Desiderata IIIc Estados equivalentes de conhecimento são sempre representados por atribuições equivalentes de plausabilidade.

Nessa perspectiva, leis de probabilidade seguem princípios da lógica clássica e qualquer regra que entre em conflito com as desideratas viola o princípio de racionalidade contido nelas. Por isso, as desideratas fornecem uma norma de como o raciocínio ideal deveria ser. Ao propor uma teoria de probabilidade como lógica estendida, Jaynes (2003) elimina a distinção entre teoria de probabilidade e inferência estatística ¹¹.

É importante notar que as medidas de probabilidade aqui servem como uma medida de falta de informação ou estado de conhecimento sobre uma assertiva, por exemplo, a qual necessitamos ter algum nível de certeza. Sabemos que o teorema de Bayes nos fornece uma regra de atualização probabilística e que, portanto, satisfaz os axiomas de probabilidade e as desideratas. Como nossos cientistas farão inferência sobre as teorias em questão de forma bayesiana, discutiremos a seguir o Teorema de Bayes.

¹⁰ Desideratas apenas enunciam um objetivo desejável, não afirmam se algo é algo verdadeiro, como axiomas, por exemplo (JAYNES, 2003).

¹¹ No modelo de Jaynes, a inferência (probabilística) é uma consequência do raciocínio dedutivo.

2.4 Teorema de Bayes

Embora o Teorema de Bayes possua diversos formatos, apresentaremos aqui sua forma mais comum e útil no que se refere ao desenvolvimento desta dissertação¹². Assim, sua formula relaciona uma probabilidade condicional e sua inversa da seguinte forma,

$$pr(H|D) = pr(D|H) \cdot \frac{pr(H)}{pr(D)} \quad (2.2)$$

Em que, H é uma hipótese e D uma evidência. $pr(H)$ é a probabilidade a priori de H ser verdadeira. $pr(H|D)$, sua posteriori, indica a chance de H ser verdadeira dado que foi observado D . Já $pr(D|H)$ é a probabilidade inversa de $pr(H|D)$, conhecida também como verossimilhança.

No caso de haver um conjunto de hipóteses $H_i, i = 1, 2, 3, \dots$, todas mutualmente incompatíveis e coletivamente exaustivas, e possuímos suas respectivas probabilidades a priori, é possível calcular a probabilidade a posteriori para cada H_i frente à uma nova evidência D , desde que contemos com um valor para cada probabilidade condicional $pr(D|H_i)$ e incondicional em D . Neste caso, podemos fazer uso do Teorema de Bayes em sua forma de probabilidades totais para o calculo da probabilidade a posteriori:

$$pr(H_i|D) = \frac{pr(H_i)pr(D|H_i)}{\sum_j pr(H_j)pr(D|H_j)}, \quad (2.3)$$

Assim, o Teorema de Bayes fornece uma regra de atualização probabilística sempre que surge uma nova evidência. Para ficar claro em que circunstância essa regra pode ser útil, consideremos o exemplo a seguir baseado em Pena (2006).

Em média, 1% das mulheres de 40 anos são portadoras de um tumor de mama assintomático. Por isso, recomenda-se que, ao atingir essa idade, as mulheres devam fazer a mamografia. O resultado da mamografia, contudo, não é definitivo: o resultado é positivo em 80% das mulheres com câncer de mama e ele também é positivo em 9,6% das mulheres que não possuem câncer. Assim, qualquer mulher aos quarenta anos de idade, que tenha realizado o teste e o resultado obtido seja positivo, ainda tem a chance de não ser definitivamente diagnosticada com câncer de mama.

O problema, na verdade, se torna dizer precisamente qual a chance da mulher ser portadora do câncer de mama. Em problemas como este é comum as pessoas sobrestimarem a probabilidade a posteriori - neste caso, de a pessoa estar com câncer. Se aplicarmos o raciocínio bayesiano veremos que, mesmo com um resultado positivo da mamografia, a chance de uma mulher aos 40 anos de idade não ser portadora de câncer ainda é considerável, como veremos a seguir.

¹² Em Howson e Urbach (2006) e Jeffrey (2004) é possível verificar outros formatos do Teorema de Bayes.

Tabela 3 – Probabilidade a Posteriori

	Tem Câncer	Não tem Câncer
Prob. a priori	0,01	0.99
Prob. condicional	0,8	0.096
Prob. conjunta	$0,01 \times 0,8 = 0,008$	$0,99 \times 0,096 = 0,0095$
Normalização	$0,008 + 0,0095 = 0,0175$	$0,008 + 0,0095 = 0,0175$
Prob. Posteriori	$0,008 / 0,0175 = 0,46$	$0,0095 / 0,0175 = 0,54$

Uma mulher pode ou não ter câncer de mama. Como esses eventos são mutualmente excludentes e coletivamente exaustivos, a probabilidade de uma mulher não ser portadora de câncer nessa idade é de 99%. Este é um conhecimento anterior ao teste. No modelo ele será incorporado na probabilidade a priori.

Tabela 1 – Conhecimento a Priori

	Tem Câncer	Não tem Câncer
Prob. a priori	0,01	0.99

Mas também existe o conhecimento adquirido após a realização do teste. Na situação em que a mulher é portadora do câncer de mama, a probabilidade do teste ser positivo é de 80% e de ser negativo é de 9,6%. Estas são as probabilidades condicionais inversas. O produto da probabilidade a priori com as condicionais nos fornece a probabilidade conjunta.

Tabela 2 – Probabilidades Condicionais Inversas

	Tem Câncer	Não tem Câncer
Prob. a priori	0,01	0.99
Prob. Condicional	0,8	0.096
Prob. Conjunta	$0,01 \times 0,8 = 0,008$	$0,99 \times 0,096 = 0,0095$

A probabilidade a posteriori pode ser obtida através das probabilidades já obtidas e de um fator de normalização calculado a partir da soma das probabilidades conjuntas.

Assim, a chance de uma mulher não estar câncer mesmo com o resultado do teste sendo positivo, aos quarenta anos de idade, é de 54%. Este é um resultado contra-intuitivo, já que a maioria das pessoas tendem a ignorar informações gerais, como de populações

relativas, e focar em informações mais específicas, gerando um viés no cálculo probabilístico. Este em específico, é conhecido como viés das taxas base.

3 Raciocínio Humano e Probabilístico

O viés das taxas base não é o único viés presente em nosso raciocínio. Há uma lista infundável de vieses cognitivos os quais estamos sujeitos e que muitas vezes nos levam à fazer julgamentos logicamente equivocados. Enquanto que a psicologia cognitiva tenta desvendar os processos mentais que estão por trás do nosso comportamento, a probabilidade nos fornece algo além da nossa heurística para lidar com problemas de decisão. Na verdade, foi disso do que tratamos na sessão anterior quando apresentamos argumento de *Dutch book* e as desideratas de Jaynes. Na prática, o que vimos foi que podemos fazer inferências erradas se algumas condições não forem satisfeitas, no sentido de que podemos violar alguns princípios ideais de racionalidade.

Na lógica clássica, ou aceitamos ou rejeitamos a veracidade de uma proposição, de tal forma que nada pode se dizer em relação à sua plausibilidade. No mundo real, porém, é comum situações em que não podemos estar cem por cento certo de algo. Nessas circunstâncias, gostaríamos de ter algo a dizer em relação à plausibilidade das assertivas de forma minimamente razoável. Ou seja, neste caso estamos interessados no processo de raciocínio que nos leva à crença numa proposição. Diariamente nosso cérebro tira conclusões sem base em uma lógica dedutiva, e ainda assim somos capazes de fazer muitas inferências e tomar decisões coerentes. Como, por exemplo, levar um guarda-chuva quando saímos de casa, ao notar nuvens escuras e ventos fortes. Ainda que não calculamos exatamente probabilidades, nesse caso, atribuímos chances de chover ou não de forma consistente ao nos basearmos nas evidências disponíveis.

Mas não calcular explicitamente probabilidades não nos impede de entender a forma como as pessoas raciocinam sob incerteza a partir destes modelos. Na verdade uma série de problemas envolvendo cognição já foram tratados sob uma perspectiva bayesiana. Tenenbaum e Griffiths (2001), por exemplo, mostraram que generalizações de indução podem ser explicadas a partir de inferência bayesiana. Os trabalhos de Chater e Oaksford (1999) e Krauss, Martignon e Hoffrage (1999) ajudam a entender em que medida nossas heurísticas se aproximam de uma inferência bayesiana.

Ainda assim, sabemos que seres humanos não são bons probabilistas (CHATER; OAKSFORD, 1999). Os paradoxos de Allais e de Ellsberg são bons exemplos de que as pessoas violam os postulados de Savage, princípios básicos da teoria da decisão (HALPERN, 2005). Os modelos da *Prospect Theory* (KAHNEMAN; TVERSKY, 1979) e da *Cumulative Prospect Theory* (TVERSKY; KAHNEMAN, 1992), por outro lado, modelam escolhas da vida real. Seus propósitos, nesse sentido, são descritivos. Contudo, eles são incapazes de prever violações de racionalidade.

Essa falta de acurácia nos modelos é compreensível se entendermos que o cérebro humano possui uma capacidade limitada de cognição e, portanto, não consegue cumprir os princípios necessários para que haja racionalidade perfeita. Nosso cérebro parece ter evoluído a um estado que nos permita resolver problemas, mas levando em consideração o custo associado à cada estratégia de raciocínio. Assim, somos dotados de uma racionalidade capaz de resolver problemas de forma satisfatória e simples sem incorrer em grandes custos de energia e tempo.

Testes em laboratório indicam o surgimento de uma série de vieses no raciocínio das pessoas (NICKERSON, 2004). A psicologia evolucionária, por outro lado, afirma que não faria sentido haver algo como um mecanismo em nosso cérebro que permitisse o cálculo errôneo de probabilidades (PINKER, 1999). Nessa mesma perspectiva, a teoria de probabilidade adaptativa (MARTINS, 2005) faz o uso de métodos bayesianos para entender esse aparente contra senso, sugerindo que a forma como fazemos inferências evolui para resolver problemas mais complexos¹ do mundo real e não para fazer escolhas em laboratório. Se este for o caso, nós talvez seríamos mais espertos que os experimentos de laboratório sugerem, já que estaríamos mais bem adaptados para situações complexas do que para testes controlados.

¹ Como comentado por Nickerson (2004): In many real-life situations involving probabilistic events, we care a lot about outcomes and strongly prefer some of the possibilities over others. We care, for example, about how likely we are to end up as a highway fatality statistic, about the probability that the global temperature really is on the rise, about the prospects of an improved economy, maybe even about the likelihood that the weather will be good tomorrow.

4 Confirmando Teorias

Ciência não responde tudo. Na verdade, é bem o oposto: há um espaço limitado de questões que a ciência consegue lidar. Por isso é primordial que cientista conheça bem o problema e saiba que pergunta responder precisamente. Muitos cientistas passam anos para entender um problema e eventualmente podem até falhar na elaboração de uma hipótese ou teoria. E por mais que uma teoria seja sofisticada, ela nunca dará conta de explicar todos os fenômenos simultaneamente. Isso porque os modelos propostos em teorias não são constituídos pura e completamente por todas variáveis que constituem o fenômeno como ele é. E ainda se assim os fossem, dificilmente conseguiríamos fazer qualquer tipo de inferência útil, já que informações demais podem dificultar maiores generalizações.

Nossas teorias se baseiam em uma série de pressupostos que nem sempre estão de acordo com as observações: imposição de restrições e hipóteses auxiliares, são recorrentes e tornam o problema mais palatável, passível de chegarmos à algum tipo de inferência. Mas justificar a crença em cima de hipóteses não é trivial. Hume (WILLIAMS, 2001) foi o primeiro a enxergar essa dificuldade, ao notar que fazer previsões impõe condições restritivas que não necessariamente podem ser uma verdade. Como no caso de garantir que o sol sempre nasça no leste e se ponha no oeste. A crença de que isso pode ocorrer no futuro é justificada basicamente pelas observações do passado, mas impor que o dia de amanhã será igual ao dia anterior é algo restritivo, embora possuímos a crença de que a *chance* de isso acontecer é alta. Neste caso, o desafio então se torna justificar as crenças nos pressupostos ou na própria teoria, este é o *problema da indução*.

Há quem diga que a epistemologia por si só está morta e que ela necessite estar em contato contínuo com outras ciências para seu desenvolvimento, como psicologia cognitiva, por exemplo (WILLIAMS, 2001). É bem verdade que um número significativo de pessoas de diversas áreas começaram a demonstrar interesse e a contribuir com a epistemologia ao longo século XX. O avanço da teoria da probabilidade, por exemplo, contribuiu com o surgimento de toda uma comunidade científica dentro da epistemologia preocupada com o problema da indução. Parte significativa desta comunidade busca a construção de modelos com base no raciocínio não dedutivo, capazes de fornecer algum nível de confirmação para as teorias. O uso do Teorema de Bayes tem se tornado uma prática comum dentro da teoria da confirmação, pois ele pode fornecer uma regra de atualização das crenças probabilísticas em face às novas evidências.

Como foi visto na sessão anterior, o desenvolvimento de métodos bayesianos para lidar com problemas relacionados com o pesamento indutivo tem se mostrado promissor. Exemplos históricos de que cientistas fazem seus julgamentos sobre hipóteses com base em

um raciocínio composto por uma parte objetiva e outra subjetiva, seguindo princípios de inferência bayesiana estão bem documentados (PRESS; TANUR, 2012). Assim, é natural que surjam também modelos bayesianos para representar a forma pela qual cientistas decidem - ou, pelo menos, deveriam decidir - suas teorias.

Há um certo consenso de que a teoria bayesiana da confirmação deva ser normativa (MAHER, 1993) (NICKERSON, 2004) (HAWTHORNE, 2011) (JAYNES, 2003) e portanto, não corresponda exatamente a forma como os cientistas pensam, mas sim como deveriam pensar. Uma função de confirmação probabilística (P), idealmente, deve funcionar como um indicador da verdade, de tal forma que se evidência (e) induz a função de confirmação à falsidade da hipótese (h), então a função deve retornar um valor próximo de 0. Caso contrário, se as evidências confirmam probabilisticamente a verdade da hipótese em questão, então a função de probabilidade produzirá um valor próximo de 1 (HAWTHORNE, 2011). Assim, a função de confirmação deve legitimar a crença na hipótese, de tal forma que,

$$1. \ e \text{ confirma ou dá suporte à } h \Leftrightarrow P(h|e) > P(h),$$

$$2. \ e \text{ desconfirma } h \Leftrightarrow P(h|e) < P(h) \text{ e}$$

$$3. \ e \text{ é neutro em relação à } h \Leftrightarrow P(h|e) = P(h)$$

A diferença $P(h|e) - P(h)$ nos fornece o grau de confirmação de e sobre h . Quando a hipótese h é refutada temos que $P(h|e) = 0$, ao passo que se $P(h|e) = 1$, a confirmação máxima é alcançada. Neste caso, temos que, em termos lógicos, $h \Rightarrow e$.

Se assumirmos que os cientistas confirmam suas teorias com base em um cálculo bayesiano, então as crenças dos cientistas são consideradas consistentes, pois os axiomas de probabilidade estão garantidos. Embora possamos estipular um ideal normativo, a inferência na prática não é trivial. Por exemplo, pelo axioma da *normalização*, sabemos que a crença probabilística atribuída à teoria da relatividade de Einstein e sua negação tinham que somar 1. Mas quando Einstein propôs sua teoria pela primeira vez, os cientistas possuíam apenas uma ideia vaga do que poderia conter no espaço de chances da negação da teoria da relatividade, o que acabava dificultado processo inferência (EARMAN, 1992).

O argumento de que poderíamos aplicar probabilidades subjetivas sobre teorias também é alvo de críticas. Em uma linha mais ortodoxa da estatística, Fisher, Neyman and Pearson não concordam com aplicação do teorema de Bayes no tratamento da inferência indutiva, pois afirmam que, em geral, a probabilidade a priori é assumida de forma arbitrária. Os bayesianos, por outro lado, afirmam que isso não seria um grande problema já que se houver evidências fortes o bastante o resultado converge com o acúmulo de evidências.

5 Aspectos Sociais da Ciência

A descrição das crenças subjetivas em termos de probabilidades e sendo atualizadas puramente com base nas observações dos cientistas parece uma visão um tanto que romântica da descoberta científica, pelo menos em nível macro. Embora a teoria da probabilidade nos forneça ferramentas para ajudar a entender o raciocínio indutivo, ela não parece ser suficiente para descrever a forma como os cientistas avaliam suas teorias. Se os cientistas atualizassem suas crenças baseados puramente nas evidências, assim como o teorema de Bayes sugere, por exemplo, não haveria lugar para opiniões divergentes no longo prazo. E, como sabemos, a ciência não funciona assim, sempre há algo para discordar se tratando de teorias.

Enquanto parece intuitivo que a ciência trabalhe sob uma perspectiva empiricista voltada para um raciocínio objetivo e matemático¹, a ideia de que o conhecimento produzido em ciência depende das relações sociais estabelecidas entre os cientistas pode parecer estranha à primeira vista. Isso porque estamos acostumados a pensar que cientistas impreterivelmente testam hipóteses e escolhem suas teorias de forma imparcial, comparando previsões de seus modelos com as observações do mundo real, de sorte que, se o modelo descrever bem o fenômeno, então a teoria tem uma boa chance de estar *certa*, caso contrário, rejeita-se a teoria em questão e segue a busca por uma com um maior poder explicatório.

Esse raciocínio parece ser uma boa aproximação do que realmente acontece na ciência e embora alguém possa afirmar ser essa a descrição precisa do funcionamento de alguma ou qualquer ciência, não podemos esquecer que cientistas estão imersos em um emaranhado social que envolve pressão, conflito e interesses dispares. Além disso, assim como em diversas organizações sociais, podemos encontrar comportamentos oportunistas em indivíduos que adotam estratégias não-cooperativas, levando à resultados socialmente indesejados. Hoje a própria estrutura da carreira acadêmica parece incentivar a produção de trabalhos menos inovadores (WANG; VEUGELERS; STEPHAN, 2016) (SMALDINO; MCELREATH, 2016), isso quando eles não estão errados (IOANNIDIS, 2005).

Cada vez mais os cientistas dependem uns dos outros para obter seus resultados. Pesquisas como o Projeto Genoma e a construção do Grande Colisor de Hádrons, por exemplo, evidenciam a preocupação do governo e das instituições de pesquisa em resolver os problemas de forma coletiva. A queda no número de publicações com apenas um autor também já foi observada nos meados do século passado (PRICE; PRICE, 1965), sugerindo o surgimento de uma comunidade científica mais interdependente. O envolvimento dos cientistas em grandes equipes de trabalhos, com orçamentos consideráveis e geralmente

¹ Ver Godfrey-Smith (2009).

sendo financiados pelo governo, levou alguns historiadores da ciência a cunhar o termo *Big Science* (GALISON; HEVLY, 1992).

O processo de especialização do cientista e a concomitante criação da carreira científica serviu para aumentar a complexidade das relações estabelecidas entre os cientistas. Durante o surgimento da ciência moderna os cientistas eram reconhecidos pelos hábitos corteses e pelo temperamento polido os quais tornavam possível a percepção de um compromisso moral com a *verdade* (SHAPIN, 1994). O tamanho do corpo científico era tão restrito que era possível ter ciência dos valores das pessoas detentoras e produtoras do conhecimento. Nos últimos dois séculos, com o crescimento exponencial da ciência e a sua divisão técnica, a crença de que o compromisso com a verdade estava sendo assegurado vinha não mais da moral dos cientistas, mas sim das instituições e suas políticas de controle sobre conhecimento científico (SHAPIN, 2009). O que não quer dizer que o cientista agora seja desprovido de moral, pelo contrário. Merton (1973), por exemplo, identifica normas institucionais² que correspondem ao *ethos* da ciência e afirma que estas não são somente prescrições técnicas mas também morais.

Podemos pensar ainda em áreas e grupos específicos, em que as relações são tão estreitas que é bem provável que estas pessoas se conheçam pessoalmente e tenham algo a dizer uma sobre a outra, sugerindo a existência de uma relação não muito diferente entre dos cientistas do século XVII (SHAPIN, 1994). Conferências internacionais, afiliações teóricas³ e os próprios grupos de pesquisa acabam criando e reforçando laços entre os cientistas. O contato contínuo dos cientistas com sua comunidade ajuda a tirar novos *insights* sobre os problemas bem como submeter seus julgamentos à um público altamente qualificado.

O reconhecimento do cientista é algo bem estimado dentro da comunidade científica e serve para estreitar as relações entre cientistas. A busca pela recompensa e reconhecimento extraordinários incentivam a produção de trabalhos mais inovadores, o que pode ter um efeito potencial sobre o orçamento da pesquisa e sobre o efetivo que nela trabalha (WHITLEY, 2000). Isso pode gerar um efeito de transbordamento benéfico para comunidade científica ao aumentar a produtividade de seus membros, além de aumentar a popularidade dos mais produtivos. Bagrow et al. (2004), por exemplo, encontraram uma correlação positiva entre a fama e o mérito entre físicos envolvidos com pesquisa de matéria condensada e física estatística.

O aumento na produtividade e a fama geralmente conferem ao cientista um poder de autoridade, pelo menos em seu campo de atuação. Desde que não seja empregada de forma abusiva, a autoridade dos cientistas é vista como algo benéfico, já que permite o desenvolvimento de um corpo científico mais coerente. Em uma fase inicial em que o

² Comunismo, Universalismo, Desinteressamento e Ceticismo Organizado

³ Mathematics Genealogy Project (JACKSON, 2007).

jovem cientista ainda não está maduro para desenvolver sua própria pesquisa é natural sua afiliação à área de pesquisa de seu orientador. Mas essa relação não é particular da comunidade científica: a criança mesmo em seus primeiros anos de vida precisa se submeter à educação e normas desenhadas por instituições e líderes com consideráveis poderes de autoridade. A forma complexa a qual nos organizamos culturalmente, adaptada para lidar com nossas capacidades cognitivas de comunicação, tem um papel fundamental na transmissão do conhecimento inter e intra gerações. Em ambos os casos, a relação mestre-aprendiz está presente e na ciência não é diferente (POLANYI, 2015).

5.1 O Papel da Confiança

Embora tenhamos descrito alguns aspectos sociais da comunidade científica, não explicitamos devidamente a força que sustenta as relações entre os cientistas e que, por consequência, torna possível a aquisição do conhecimento: a confiança. Difícil é pensar em relações entre pessoas e/ou instituições que não envolvam confiança: transações econômicas, acordos de paz e contratos formais ou informais são alguns exemplos de relações em que a confiança se torna indispensável. A vida social tal como conhecemos, organizada de forma coletiva, exige que as pessoas confiem uma nas outras para a manutenção e o desenvolvimento de uma vida em sociedade.

No caso do conhecimento científico, o papel da confiança já tem sido notado por historiadores e sociólogos da ciência. Shapin (1994), por exemplo, argumenta que o surgimento da ciência moderna se deve em grande medida a confiança que a sociedade e a comunidade de científica depositavam nos cientistas. Merton (1973) afirma que, embora não possamos afirmar que os cientistas possuam qualidades morais superiores aos profissionais de outras áreas, as características do próprio meio científico proporcionam um ambiente mais favorável à cooperação. As relações professor/aluno e orientador/orientando, por exemplo, exigem confiança de ambos os lados para que o conhecimento possa ser devidamente transmitido e assimilado. Aprender a pensar cientificamente não é nada simples: conceitos científicos não brotam de resultados experimentais, o esforço da manipulação do aparato técnico científico se torna inútil sem o devido treinamento e até o domínio da linguagem científica fica impossível sem auxílio de um instrutor ou de livros que expressam algum consenso (ZIMAN, 1991). Muito do conhecimento científico, portanto, envolve um conhecimento tácito que só é possível adquirir através de um contato contínuo com quem pratica e domina a linguagem científica.

Assim, mais do que propor uma estrutura social para a comunidade científica, o objetivo aqui é ressaltar a importância da confiança como um insumo básico para processo de aquisição do conhecimento, tão básico quanto dados empíricos e argumentos lógicos. A ideia é que, muitas vezes, aqueles que não fazem o uso da confiança submetem suas crenças

a um número restrito de evidências, quando comparados com indivíduos que confiam. Assim, aqueles que não confiam podem não possuir as melhores evidências para justificar suas crenças (HARDWIG, 1991).

No contexto dos grupos acadêmicos, a confiança fica ainda mais evidente, como no exemplo de Hardwing sobre a matemática e a física de partículas. Embora a matemática seja uma área construída basicamente a base de provas, nem sempre os matemáticos conhecem todas justificativas lógicas para cada passo das provas anteriores, assim como no caso da prova matemática de Branges que depende de partes muito específicas da matemática para ser propriamente justificada⁴. De forma semelhante, na física de partículas há experimentos que são impossíveis de realizar individualmente, como a mensuração da vida útil de um quark c , por exemplo. Pesquisas interdisciplinares e experimentos em laboratório geralmente implicam em colaborações diversas, rendendo publicações de até dezenas de cientistas por publicação (AIRAPETIAN et al., 2005). Hardwig (1991) afirma existirem dois motivos para acreditar que a comunidade científica vem se organizando cada vez mais como grupos colaborativos: um relacionado com o custo associado a coleta e análise dados e outro, mais importante no contexto da análise epistemológica, devido ao fato de ninguém saber o suficiente para estar apto à realizar experimentos por conta própria. Em ambos os casos confiar é indispensável.

Podemos identificar dois tipos de confiança (BARBER, 1987). O primeiro se refere à expectativa ou previsão de que a atribuição de alguma tarefa será cumprida. Confiamos em alguém, nesse sentido, quando acreditamos que uma pessoa, dotada de alguma capacidade específica, exerça seu papel com adequado nível de proficiência⁵. Um segundo tipo de confiança está relacionado com uma obrigação fiduciária e responsabilidades de pessoa para pessoa. Quando confiamos desta forma é porque cremos no dever moral da pessoa a qual as responsabilidades foram conferidas, no sentido de que ela não privilegiará seus próprios interesses em detrimento dos demais.

Estes tipos de confiança podem variar de organização para organização. Os mercados, embora dependam dos dois tipos de confiança, parecem ser muito mais responsivos aos mecanismo de preços do que à confiança. O mesmo não pode se dizer das instituições científicas e médicas que, para garantirem efetiva performance e manter a responsabilidade moral, parecem depender mais da obrigação fiduciária. Mas confiança também muda dentro dos próprios grupos ou instituições com o passar do tempo. Em uma pesquisa envolvendo 350 médicos, no final dos anos de 1960, estes participantes tinham que escolher

⁴ Louis de Branges provou a conjectura de Ludwig Bieberbach, uma conjectura em análise complexa que resistiu à provas por quase 70 anos. Louis de Branges contou com a ajuda de Walter Gautschi para verificar a conjectura por métodos numéricos. Ainda assim, foi somente com a desigualdade de Askey–Gasper, desenvolvida dentro do contexto de análise de funções complexas, que a prova de Branges pode ser completada.

⁵ Este tipo de confiança existiu em diversas sociedades, mas na atual era da especialização ele parece ainda mais evidente.

entre alguns atributos que consideravam importantes ao escolher um outro médico cientista para colaborar, e o detalhe é que apenas 6 % dos entrevistados responderam a alternativa *questões éticas da pesquisa*. Hoje é bem provável que este quesito tenha um maior peso, até mesmo pelos escândalos relacionados com a falta de ética na pesquisa médica (BARBER, 1987).

Mudanças nas crenças dos indivíduos em relação a confiança são naturais e eventualmente levam a cisões das relações sociais ou até mesmo de ideias dentro de um grupo. As divergências são fomentadas dentro dos próprios vínculos de confiança, que aos poucos vão também sendo dominados por um sentimento de desconfiança e isto dá origem ao que Merton (1973) chama de *verdades baseadas em grupos*: verdades internas que fazem oposição às verdades externas e verdades externas que fazem oposição às verdades internas. A ideia é que o grupo forma a crença de que as pessoas que não participam dele não são confiáveis e as perspectivas intelectuais dentro e fora do grupo são tão distintas que elas deixam de habitar um lugar comum. Os argumentos são confrontados com questões totalmente diferentes, evitando qualquer progresso no diálogo.

Quanto mais estratificada a sociedade mais contundentes são os argumentos sobre a legitimidade dos mesmos dentro de cada estrato. Os grupos podem ter diferentes inclinações políticas, culturais ou sociais e uma pessoa que não compartilha dos mesmos valores do grupo pode facilmente ser vista como não confiável. Quando isso ocorre fica cada vez mais difícil de avaliar a consistência lógica e a plausibilidade das afirmações de quem é percebido como não confiável. Por outro lado, quando há a confiança existe a crença de que o que lhe foi conferido será cumprido, seja por um dever moral ou pela confiança na aptidão de quem é confiado. Em ambos os casos, os motivos os quais levam a pessoa a confiar depende do grupo o qual ela pertence.

Assim, pode existir uma visão de quem está dentro do grupo e outra de quem está fora dele, mas ela vai depender de como se dá o acesso e a difusão do conhecimento intra e extra grupos. Em uma perspectiva mertoniana, dentro dos grupos há uma tendência de restringir o acesso ao conhecimento aos indivíduos que ali são julgados como confiáveis. Ernest Kriek, líder nazista de assuntos em ciência, por exemplo, contrastava o cientificismo ariano com o cientificismo dos não arianos, além de diferenciar em ciência protestante e católica, bem como ciência alemã e judia. De forma semelhante, uma quantidade considerável de sociólogos negros se dedicam aos estudos sobre raça, assim como várias sociólogas se ocupam com estudos de gênero, seja por auto seleção ou por seleção social.

Nesse sentido, a mente humana é tão livre quanto as nossas instituições a permite ser. Em um mundo ideal seríamos livres para ter acesso a qualquer tipo de conhecimento por conta própria, mas a realidade é que podemos saber muito pouco sobre o mundo, e para tudo aquilo que não conseguimos alcançar diretamente recorreremos a confiança (POLANYI, 2013). Confiamos porque não podemos prever ou assegurar todos os resultados

possíveis. Confiar reduz a complexidade da vida real que é simplificada ao tomar o risco. Quanto maior a confiança, maior o risco (CREASE, 2004).

6 Modelo de Dinâmica de Opiniões CODA

O estudo da emergência de padrões sociais como resultado de interações entre indivíduos tem ganhado contribuições das mais diversas áreas ultimamente. A Física, em especial, passou a compor mais significativamente esse corpo a partir do último quarto do século passado, introduzindo os modelos da mecânica estatística para entender a formação de padrões sociais (CASTELLANO; FORTUNATO; LORETO, 2009), o que mais tarde permitiu o desdobramento de uma nova agenda de pesquisa dentro da Física: a Sociofísica. Os padrões relacionados com a opinião dos indivíduos, como comportamentos extremistas e consenso, por exemplo, têm ocupado um lugar central nesta agenda, principalmente com os modelos de dinâmica de opiniões. Esta é uma área relativamente recente e suas origens remetem a Física e a Modelagem Computacional.

Os modelos de dinâmica de opiniões podem ser de três tipos: (1) discretos, (2) contínuos ou (3) mistos, no caso de a opinião ser contínua mas as ações discretas. Abaixo faremos uma descrição sucinta de cada um deles¹.

Modelos Discretos

Muitas vezes a forma como expressamos nossa opinião se dá de forma discreta. Ou seja, todos nós podemos decidir entre apoiar ou não uma ação ou, até mesmo, fazer ou não fazer algo. Assim, a partir das interações dos agentes definidas por regras simples, os modelos discretos de dinâmica de opiniões permitem observar a tendência de concordância acerca de uma ou outra opinião ou ação. Os modelos do votante, de Sznaid e da maioria, são exemplos onde a modelagem da opinião é feita de forma discreta.

Modelos Contínuos

Porém, há circunstâncias em que nossas opiniões podem ser melhor representadas por algum nível de intensidade em relação a alguma assertiva. Por exemplo, apesar de existirem opiniões extremas em política que pendam para esquerda ou para a direita, é muito comum as pessoas se identificarem de forma mais moderada, como no caso de posições centro/direita ou centro/esquerda. Nesses casos, o emprego de modelos contínuos de dinâmica de opiniões pode ser mais adequado. Alguns modelos deste tipo levam o nome de modelo confiança limitada, pois a dinâmica de convergência

¹ Baseada em (CASTELLANO; FORTUNATO; LORETO, 2009) e (MARTINS, 2012).

das opiniões depende de um limiar que indica o quanto os indivíduos são próximos um do outro em relação às suas opiniões.

Modelos Mistos

Podemos também estar interessados em verificar o quão certo o indivíduo pode estar acerca de sua opinião, ainda que esta se manifeste de forma discreta. Isso porque embora as pessoas possam demonstrar a mesma opinião, cada indivíduo pode alterá-la mais ou menos facilmente. No modelo CODA, por exemplo, cada agente observa a ação discreta embora sua atualização se dê forma contínua. O CODA propõe entender opiniões contínuas através do cálculo bayesiano de probabilidades.

A busca por uma teoria capaz de descrever o comportamento humano de forma racional ou parcialmente racional é uma agenda bem conhecida em áreas como psicologia e economia, por exemplo. Contudo, esse ainda é um problema pouco explorado nos trabalhos de dinâmica de opiniões. De fato, o modelo de dinâmica de opiniões CODA busca uma fundamentação teórica para mudança nas opiniões dos agentes, fornecendo uma norma para atualização das crenças probabilísticas. Nesse contexto, o arcabouço bayesiano serve como aproximação do raciocínio humano indutivo e indica qual seria a forma ideal de raciocínio que leva as pessoas a definirem suas opiniões.

A hipótese básica por de traz dos modelos de dinâmica de opiniões é a de que, para alterar sua opinião, o agente deve levar em consideração as opiniões das pessoas as quais ele interage e usá-las como informação na escolha do que viria ser a melhor alternativa. Contudo, tanto os modelos contínuos quanto os discretos não distinguem opiniões internas e externas. Como muitas vezes as observações das pessoas não correspondem às suas verdadeiras opiniões e a interação humana não se dá de forma exatamente numérica, estes modelos podem ser vistos como limitados. O modelo CODA lida justamente com esta questão ao propor uma opinião contínua e uma ação discreta. Assim, este modelo faz uso regras baysianas para atualização das opiniões contínuas internas, embora os agentes só consigam observar as ações discretas daqueles com quem ocorre a interação. Os passos a seguir ajudam a entender melhor a elaboração do CODA².

1. *Após escolher o assunto a ser debatido, deve-se atribuir uma variável x a ele. Esta é uma variável discreta que representa a escolha observável de cada agente.*
2. *A intensidade com que cada agente defende x pode ser representada por uma distribuição de probabilidade $f_i(x)$.*

² Os passos são descritos em Martins (2012) e aqui estão apresentados em uma tradução livre.

3. Definir a forma de comunicação C_j . No CODA, a comunicação ocorre quando o agente i observa j escolher uma entre as opções em x . Assim, C_j pode ser uma função que dependa do quanto o agente j acredita que sua escolha seja a melhor.
4. A comunicação é uma expectativa do agente i de que, ao se comunicar com j , este fará melhor escolha (x^*). Portanto, podemos definir uma função de probabilidade condicional, $P(C_j|x^*)$. No CODA esta probabilidade é constante.
5. A distribuição de probabilidade $p(C_j|x)$ faz o papel da função de verossimilhança, enquanto que opinião representada pela função $f_i(x)$ desempenha o papel da priori. A aplicação do Teorema de Bayes garante a obtenção de uma nova opinião probabilística a posteriori.
6. Definir quem interage com quem e com que frequência.

Os passos acima são regras gerais para implementação de regras bayesianas em um modelo de dinâmica de opiniões. A seguir, explicaremos o modelo CODA.

Considere duas alternativas, A e B , de tal forma que cada agente i possua uma determinada opinião p_i a favor de A , e uma opinião $1 - p_i$ a favor de B , ambas definidas em termos de crenças probabilísticas. O problema então se resume em fazer a melhor estimativa acerca das alternativas. As escolhas podem ser descritas como um campo discreto em função de p_i (doravante p), tal que, $x_i(p) = +1$ se i escolhe A , e $x_i(p) = -1$, se i escolhe B .

Considere também que um vizinho j possui uma probabilidade $\alpha = P(x_j = +1|A)$ de escolher A , dado que A é verdadeiro. Da mesma forma que, se B é a melhor alternativa, há a probabilidade $\beta = P(x_j = -1|B)$ de que j escolha B . Dadas as probabilidades a priori e as verossimilhanças é possível obter a probabilidade $P(A|x_j = +1)$ de que A seja a melhor alternativa, após observar alguém escolher A . Dentro do contexto do Teorema de Bayes e do que foi descrito nos passos acima, a nova crença de i em A passa a ser definida como $P(A|x_j = +1) \propto p\alpha$. A árvore de decisão pode ser conferida na Figura 2.

Figura 2 – Representação da árvore de decisão para o CODA. Através dela conseguimos visualizar como obtemos a verossimilhança.

Trabalhar com o logaritmo da razão de chances em favor de A permite simplificar o modelo, de tal forma que a atualização da opinião se torne uma simples soma. Sendo assim, temos que, se o agente i observar j escolher A, então,

$$O(A|x_j = +1) = \frac{P(A|x_j = +1)}{P(B|x_j = +1)} = \frac{p}{1-p} \frac{\alpha}{1-\beta}, \quad (6.1)$$

e fazendo o $\ln$ de $O(A|x_j = +1)$,

$$\ln(O(A|x_j = +1)) = l(A) + v, \quad (6.2)$$

em que $l(A) = \ln \frac{p}{1-p}$ e $v = \ln \frac{\alpha}{1-\beta}$.

Sendo que, se j for observado suportando B, então,

$$O(A|x_j = -1) = \frac{P(A|x_j = +1)}{P(B|x_j = +1)} = \frac{p}{1-p} \frac{1-\alpha}{\beta}, \quad (6.3)$$

aplicando $\ln$ novamente, obtemos,

$$\ln(O(A|x_j = -1)) = l(A) + \eta, \quad (6.4)$$

em que $\eta = \ln \frac{1-\alpha}{\beta}$. Por simplificação podemos assumir que $\alpha = \beta$. Neste caso, $\eta = -v$. A opinião inicial do agente i pode ser definida como,

$$\nu_i(t) = l(A) = \ln \frac{p}{1-p}, \quad (6.5)$$

e evoluirá da seguinte forma,

$$\nu_i(t+1) = \begin{cases} \nu_i(t) + v & \text{Se } i \text{ observar } j \text{ escolher } A \\ \nu_i(t) - v & \text{Se } i \text{ observar } j \text{ escolher } B \end{cases} \quad (6.6)$$

Sabemos que j escolhe A quando $p_i > 0,5$ e isso implica que $v_i > 0$. Caso contrário, saberemos que j é a favor de B .

6.1 CODA com Confiança

Assim como na subseção anterior, recorreremos à árvore de decisão para identificar as probabilidades associadas a cada evento e obtermos a verossimilhança $P(x_j = +1|A)$ para fazer a estimação de $P(A|x_j)$ através do Teorema de Bayes. No entanto, introduzir a confiança neste sistema implica em dobrar os possíveis resultados finais, como pode ser observado na Figura 3.

Figura 3 – Representação da árvore de decisão para o CODA com confiança. τ é a probabilidade de que j seja confiável e μ é a probabilidade de que j faça a escolha correta quando este não é confiável. Semelhantemente, $1 - \tau$ é a probabilidade de que j não seja confiável, e $1 - \mu$ é a probabilidade de que j faça escolha errada quando, na verdade, ele é confiável.

Note que, neste caso, obter $P(x_j = +1|A)$ é um pouco mais complicado, pois temos que levar em conta todos os casos em que A é escolhido por j , dado que A é verdadeiro. Por isso, a probabilidade de j escolher A , dado que A é verdadeiro e que j pode ser confiável ou não é $P(x_j = +1|A) = \tau\alpha + (1 - \tau)\mu$. Aplicando o Teorema de Bayes em que,

$$p(t+1) = \frac{p[\tau\alpha + (1 - \tau)\mu]}{p[\tau\alpha + (1 - \tau)\mu] + (1 - p)[\tau(1 - \alpha) + (1 - \tau)(1 - \mu)]} \quad (6.7)$$

A opinião sobre a confiança τ que cada agente i deposita em j também é obtida pelo método bayesiano, por isso sua regra de atualização é definida como,

$$\tau(t+1) = \frac{\tau[p\alpha + (1 - p)(1 - \alpha)]}{\tau[p\alpha + (1 - p)(1 - \alpha)] + (1 - \tau)[p\mu + (1 - p)(1 - \mu)]}. \quad (6.8)$$

Estas duas equações valem sempre quando i observa j escolher A . Quando j escolhe B as regras de atualização das opiniões passam a ser,

$$p(t+1) = \frac{p[\tau(1 - \alpha) + (1 - \tau)(1 - \mu)]}{p[\tau(1 - \alpha) + (1 - \tau)(1 - \mu)] + (1 - p)[\tau\alpha + (1 - \tau)\mu]} \quad (6.9)$$

e

$$\tau(t+1) = \frac{p[\tau(1-\alpha) + (1-\tau)(1-\mu)]}{\tau[p(1-\alpha) + (1-p)\alpha] + (1-\tau)[p(1-\mu) + (1-p)\mu]} \quad (6.10)$$

Trabalhar com o log da razão de chances aqui não é muito útil já que o cálculo pode se tornar mais complicado sem qualquer vantagem adicional. No CODA original, era conveniente o uso do log da razão de chances na atualização das opiniões, até mesmo porque as opiniões no formato das equações (4) e (6) levam a convergência quase que instantânea do modelo. Contudo, aqui este não é o caso.

6.2 CODA na Comunidade Científica

No contexto da comunidade científica (MARTINS, 2010) (MARTINS, 2013a), A e B são teorias concorrentes e os agentes são cientistas artificiais que irão debater sobre qual teoria poderia melhor descrever a natureza. O CODA é um modelo que diz a forma como os agentes devem atualizar suas opiniões, porém ele não diz nada sobre a estrutura social da rede. Esse fato, impunha a necessidade da definição de regras de interação local e de especificações da comunidade científica, até mesmo para o modelo não convergir rapidamente para o consenso.

As opiniões se atualizam de forma assíncrona de acordo com a equação (6.6). Como é esperada a correspondência entre a teoria e a natureza, são introduzidos alguns cientistas sob influencia de um campo externo. Estes são os cientistas que realizam experimentos, que conseguem observar de forma clara a correspondência entre a teoria e as observações quando não estão sob influência de outros cientistas. Por simplificação, a opinião do cientista experimentador, na ausência de influencia social, é incrementada da mesmo forma como se i observasse j escolher a teoria *correta*. Assim, experimentadores também podem estar sob influência social. Portanto, existe uma proporção γ de cientistas que, com probabilidade ρ , estão sob a influência de um campo externo o qual favorece a opinião sobre a teoria que melhor descreve a natureza. Embora os cientistas não saibam qual seria a melhor teoria, como programadores é possível escolher arbitrariamente A como a teoria que melhor descreve a natureza. Este é um aspecto importante do modelo, pois o intuito é descobrir as circunstância em que podemos observar a convergência das opiniões para teoria que julgamos ser a mais adequada ($x^* = A$).

Quando os experimentadores estão sob influência social a atualização de suas opiniões depende somente da interação com j , assim como no caso dos não experimentadores, isto é, de acordo com as equações (6.6).

6.3 Introdução da Confiança na Comunidade Científica

O modelo CODA já explorou problemas relacionados com a confiança (MARTINS, 2013b) e epistemologia (MARTINS, 2010) (MARTINS, 2013a), mas de forma independente. Os modelos que simulavam a comunidade científica não levavam em consideração a percepção que cada cientista tinha em relação aos outros membros desta comunidade no que se refere a confiabilidade. Por isso, nesta dissertação introduziremos uma memória em cada cientista em relação a confiança que este deposita nos demais através de vetor τ_{ij} . Portanto, a estrutura da comunidade científica utilizada nos modelos do CODA é preservada, a diferença agora é que as atualizações das opiniões deixam de ser atualizadas pela equação (6.6) e passam a ser definidas a partir das equações (6.7-6.10).

Os cenários a serem explorados, determinando o nível de confiança (τ), a influência social (ρ) e a proporção de experimentadores (γ) serão explicitados na seção seguinte.

7 Simulações

Simulamos uma comunidade de $n = 32^2$ cientistas, em que todos interagem de forma aleatória entre si. Nas simulações são sorteados 32^2 cientistas por rodada (t), ou seja, cada agente tem a chance de interagir pelo menos uma vez em cada passo t . O número de rodadas pode ser conferido ao longo do capítulo. Para garantir a robustez dos resultados obtidos, foram realizados blocos de simulação que serão explicitados em cada simulação.

As opiniões dos cientistas em relação às teorias são geradas a partir de uma distribuição uniforme entre 0,01 e 0,99. Cada cientista i só consegue observar a opinião discreta de j e não o valor de p_j . O valor inicial da confiança τ_{ij} é explicitada nos gráficos, ao passo que α e μ se manterão fixados, exceto quando dito contrário. Via de regra, consideraremos que a probabilidade de j escolher a teoria correta quando ele não é confiável é $\mu = 1 - \alpha$, enquanto que a probabilidade α do cientista i observar j fazer a escolha *correta* será igual a 0,55. Este é o caso razoável que indica que a probabilidade de um cientista tomar a decisão correta será menor quando j não for confiável, ainda que cenários alternativos sejam explorados mais adiante.

Por hora estamos interessados em avaliar quando que os cientistas podem entrar em consenso em média. Os Gráficos da Figura 4 mostram o nível e a velocidade de convergência das opiniões discretas dos cientistas ao longo tempo. Foram realizados blocos de 100 simulações para o computo das médias em cada rodada. Nos Gráficos é possível visualizar cenários em que são variados o número de cientistas experimentares (γ) e os efeitos sociais (ρ). O aumento da influência social torna a velocidade da convergência das opiniões mais lenta. Mesmo assim, o consenso é atingido quando o número de experimentadores é suficientemente alto ($\gamma = 35\%$).

No entanto, quando o número de cientistas que realizam experimentos diminui, os cientistas podem não entrar no consenso ou até mesmo escolher a teoria *errada* quando os efeitos sociais forem altos. Este é o caso mais preocupante, quando há poucos cientistas realizando experimentos aliado ao ambiente de extrema influência social (Figura 4, b - linha vermelha). Mas esse é o caso extremo. Para todos os outros casos a convergência para teoria correta foi quase que unânime. A maior diferença é a velocidade de convergência entre todos cenários.

Figura 4 – Dinâmica das médias das opiniões ao longo do tempo. No Gráfico a esquerda (a), 35% da comunidade científica realiza experimentos, enquanto que no Gráfico (b) apenas 10%. As linhas correspondem a diferentes níveis de influência social, baixa, média e alta. Os resultados são para $\tau_{ij} = 0, 7$.

A velocidade de convergência das opiniões pode ser melhor visualizada nos Gráficos das Figuras (5) e (6), onde mostra a opinião contínua relativa a teoria (lado esquerdo) e a confiança dos cientistas (lado direito). Os Gráficos são mapas de calor das opiniões e estão separadas em 25 classes representadas no eixo Y . Cada classe m_i contém uma frequência que é medido pelo mapa de calor. Quanto mais próximo do vermelho maior a frequência em cada classe, quanto mais próximo do branco, menor a frequência. Para melhorar a visualização, calculamos o $\log$ da frequência de cada classe. Para cada passo t foram realizados blocos de 40 simulações. Como a difusão das opiniões das teorias ocorre muito mais rápido do que em relação à confiança, prolongamos as simulações para a confiança até $t = 10000$. A evolução da confiança é mais lenta devido à τ_{ij} ser uma matriz que contém um vetor por agente, responsável por armazenar a informação relativa à confiança de todos os outros cientistas.

Figura 5 – Evolução das opiniões contínuas ao longo do tempo. Do lado esquerdo estão os gráficos que representam as opiniões sobre as teorias, enquanto que do lado direito a confiança dos cientistas. O eixo Y representa cada classe m_i de um total de 25 classes. As cores representam o log frequência de cada classe, variando do vermelho (alta frequência) ao branco (nenhuma frequência). Nos gráficos da parte superior, apenas 10% dos cientistas realizam experimentos, enquanto que na parte debaixo, 35% dos cientistas realizam experimentos. Os efeitos sociais para ambos os casos são os mesmos ($\rho = 0,9$) e a confiança foi inicializada em $\tau_{ij} = 0,7$ para toda comunidade científica.

Mantendo os efeitos sociais relativamente baixos e constantes ($\rho = 0.9$), o aumento da proporção de cientistas que realizam experimentos diminui a velocidade de convergência das opiniões das teorias em 100 passos em média. Assim, o aumento de experimentos na comunidade científica pode promover a difusão das opiniões sobre as teorias de forma mais efetiva, levando a comunidade científica ao consenso rapidamente.

O aumento do número de cientistas que realizam experimentos também torna a polarização mais rápida no modelo (Figura 6). A polarização é verificada quando a confiança é inicializada 0,5¹. No CODA com confiança, opiniões mais moderadas tendem a desaparecer ao longo do tempo, e neste modelo isso pode ser observado no aumento da área branca entre as extremidades das classes nos mapas de calor.

¹ Ou próximo à 0,5, como será visto mais adiante.

Figura 6 – Evolução das opiniões contínuas ao longo do tempo. Do lado esquerdo estão os gráficos que representam as opiniões sobre as teorias, enquanto que do lado direito a confiança dos cientistas. O eixo Y representa cada classe m_i de um total de 25 classes. As cores representam o log frequência de cada classe, variando do vermelho (alta frequência) ao branco (nenhuma frequência). Nos gráficos da parte superior, apenas 10% dos cientistas realizam experimentos, enquanto que na parte de baixo, 35% dos cientistas realizam experimentos. Os efeitos sociais para ambos os casos são os mesmos ($\rho = 0,9$) e a confiança foi inicializada em $\tau_{ij} = 0,5$ para toda comunidade científica.

A dinâmica de longo prazo do modelo CODA com confiança leva os agentes a confiarem naqueles que concordam entre si. Este resultado se mostrou robusto em nossas simulações, já que quando os cientistas entram em consenso, a confiança tendeu a 1 e quando os cientistas polarizam suas opiniões a confiança entre cada grupo tende a zero, embora essa seja uma dinâmica bem lenta no modelo.

Mas também é possível atingir o consenso em outros casos quando $\tau_{ij} = 0,5$. Para isso, os cientistas tem que perceber que a informação que eles recebem de outros cientistas é a que de fato corresponde à melhor descrição da natureza. Os Gráficos da Figura 7 representam o desvio padrão das opiniões para cada par de parâmetro α e μ . Cada quadrado é o resultado de uma média de 40 simulações que são realizadas até $t = 1000$. A tendência para a polarização se torna maior na medida em que os agentes não confiáveis estão mais sujeitos a cometer erros. Por outro lado, os cientistas tendem a entrar em acordo quando a informação dos agentes confiáveis passa a ser mais confiável. Mesmo variando parâmetros de efeito social e da proporção de experimentadores os resultados se mantiveram muito semelhantes ao do CODA com confiança (MARTINS, 2013b), mostrando ser essa uma

característica intrínseca do modelo. A diferença aqui é que, o baixo número de cientistas que realizam experimentos, aliado a um cenário de alta influência social pode tornar mais difícil a convergência das opiniões para teoria que julgamos ser a correta.

Figura 7 – Desvio padrão das opiniões. Os quadrados variam entre o preto (desvio padrão igual a zero, consenso) e o branco (padrão igual a 0.5, polarização). Simulações para $\tau_{ij} = 0.5$

Mesmo com alta confiança os cientistas podem eventualmente opinar unanimemente a favor de B (Figura 8). Este cenário é observado quando há poucos experimentadores e é mais forte ainda quando, além de poucos experimentadores, também há forte influência social sobre o resultados dos cientistas. Assim, embora a chance dos cientistas escolherem a teoria correta aumente na medida que eles confiem mais um nos outros, este é um resultado que depende da dinâmica do modelo. Em especial, os efeitos sociais em ciência parecem exercer pouca ou nenhuma influência no que parece caracterizar uma transição de fase, da polarização para o consenso, nos gráficos da Figura 8. Ao passo que, a diminuição do número de experimentadores tende a deslocar as curvas para a direita, exigindo mais confiança para haver o consenso.

Os Gráficos da Figura 8 também nos permitem ter um ideia do papel da confiança em cenários mais ou menos polarizados. Quanto maior a polarização da comunidade científica maior o nível de confiança necessário para que o consenso emergja. E por mais que a comunidade esteja polarizada, se o número de cientistas que realizam experimentos for suficientemente alto, o nível da confiança entre os grupos não precisa ser tão elevado.

Neste caso é como se as evidências estivessem tão claras que os efeitos sociais entre os grupos diminuíssem devido à facilidade com que a informação é difundida pelo próprio peso das evidências.

Figura 8 – Proporção dos cientistas em favor da teoria correta em função da confiança inicializada nos cientistas para três casos distintos: opiniões em relação à teoria dispersas, próximas e extremas. Todas geradas a partir de uma distribuição uniforme, sendo que para opiniões dispersas $0.01 \leq p \leq 0.99$, para opiniões próximas $0.4 \leq p \leq 0.6$ e para opiniões extremas p se encontra em duas regiões distintas: $0 \leq p \leq 0.01$ e $0.99 \leq p \leq 1$. Cada quadrante representa diferentes níveis de influência social ou de proporção de cientistas experimentadores.

Em todos os casos, quando a confiança é grande o suficiente podemos observar uma convergência para as opiniões no sentido da teoria correta. A descontinuidade nas curvas sugere uma transição de fase de primeira ordem entre as opiniões.

Na medida em que os cientistas vão se tornando confiáveis o consenso para teoria correta fica mais evidente. O problema é que eventualmente os cientistas podem estar com opiniões tão extremas, devidos a fatores sociais, por exemplo, que mesmo eles estando errados eles irão precisar de muita confiança para poder concordar com outro cientista.

Caso não se verifique significativo nível de confiança, os cientistas tenderão a reforçar suas opiniões mesmo que estas sejam opiniões equivocadas.

8 Considerações Finais

Os resultados de nossa pesquisa permitiram representar os efeitos sociais em ciência com a devida ênfase a confiança. Essa tarefa foi realizada com base nos trabalhos anteriores, os quais buscaram descrever o processo de difusão de teorias científicas fazendo o uso do modelo de dinâmica de opiniões CODA.

Fazer o uso de técnicas bayesianas para aproximação do raciocínio indutivo com o auxílio da computação tem se mostrado algo promissor. Neste trabalho em específico, buscamos descrever o processo de confirmação científica no âmbito micro e macro. Do ponto de vista micro, nosso cientista atualiza suas opiniões através de regras bayesianas, enquanto que macro, estávamos interessados nas circunstâncias e a magnitude em que os cientistas poderiam concordar ou discordar sobre as teorias.

Desconsiderar os efeitos sociais em ciência pode ser uma representação distante da prática científica hoje. E como vimos, não há maiores problemas com efeitos sociais de forma moderada e isolada, o problema é quando este efeito vem acompanhado de um número muito baixo de experimentos. No mundo real, essa falta de experimentação pode ser traduzida em complicações na replicação dos experimentos, como no caso de haver dados precários e/ou complicações na conduta dos experimentos, por exemplo.

Estas são circunstâncias que de fato podem afetar as opiniões finais dos cientistas, até mesmo porque sabemos que, não raramente, eles chegam à conclusões precipitadas. Se entendermos melhor a dinâmica em que uma teoria é disseminada, é possível propor cenários e conjecturas que permitam identificar situações em que os cientistas estariam mais sujeitos ao erro. Consequentemente, as recomendações de práticas científicas poderiam ser mais efetivas. Embora este não seja o foco nesta pesquisa, os trabalhos futuros podem fazer o uso desta abordagem para entender melhor cenários mais específicos e eventualmente prescrever melhores práticas no meio científico.

Nossas simulações não só sugerem que para haver o consenso sobre uma nova teoria a comunidade científica precisa estar convencida de que os cientistas sejam confiáveis, mas como também ressalta o papel dos grupos nesse processo, ao explorar cenários com maior ou menor polarização inicial das ideias. O CODA mesmo já havia mostrado que a forma como a estrutura da rede pode afetar diretamente a disseminação das teorias, quanto mais estratificada for essa comunidade mais difícil se tornará difusão das ideias e consequente o consenso. Aqui o resultado é semelhante, já que para para haver o consenso em relação às teorias primeiro é preciso haver um consenso em relação à confiança dos cientistas. Este resultado está de acordo com os trabalhos anteriores relacionados ao CODA e confirma investigações históricas e sociológicas da ciência, de a confiança ser indispensável

na aquisição do conhecimento.

Nosso modelo descreveu cientistas artificiais obtendo opiniões bem fortes sobre suas teorias ao longo do tempo. Essa é uma descrição bem verossímil, já que cientistas em geral são pessoas treinadas especificamente para defender suas opiniões, mesmo que estas eventualmente possam estar erradas. Embora possam haver diversos tipos de teorias concorrendo, nosso modelo explorou somente a adoção de duas. Nada impede de trabalhos futuros explorarem estes e outros cenários envolvendo número de publicações, carreira e estruturas de redes diversas. Outra simplificação se refere à inexistência de erros experimentais e correções. Vale lembrar que o modelo aqui explicitado é uma simples representação do que pode ocorrer no meio científico quando os cientistas avaliam suas teorias. Manter o modelo simples é importante para descrevermos aquilo que há de mais fundamental no fenômeno.

Referências¹

- AIRAPETIAN, A. et al. Quark helicity distributions in the nucleon for up, down, and strange quarks from semi-inclusive deep-inelastic scattering. *Physical Review D*, APS, v. 71, n. 1, p. 012003, 2005. Citado na página 27.
- BAGROW, J. P. et al. How famous is a scientist?—famous to those who know us. *EPL (Europhysics Letters)*, IOP Publishing, v. 67, n. 4, p. 511, 2004. Citado na página 25.
- BANDYOPADHYAY, P. S.; FORSTER, M. R. Philosophy of statistics: An introduction. *Philosophy of Statistics*, Elsevier, v. 7, p. 1, 2011. Citado na página 15.
- BARBER, B. Trust in science. *Minerva*, Springer, v. 25, n. 1, p. 123–134, 1987. Citado 2 vezes nas páginas 27 e 28.
- CASTELLANO, C.; FORTUNATO, S.; LORETO, V. Statistical physics of social dynamics. *Reviews of modern physics*, APS, v. 81, n. 2, p. 591, 2009. Citado na página 30.
- CHATER, N.; OAKSFORD, M. The probability heuristics model of syllogistic reasoning. *Cognitive psychology*, Elsevier, v. 38, n. 2, p. 191–258, 1999. Citado na página 20.
- CREASE, R. P. *The paradox of trust in science*. [S.l.]: IOP PUBLISHING LTD DIRAC HOUSE, TEMPLE BACK, BRISTOL BS1 6BE, ENGLAND, 2004. Citado 2 vezes nas páginas 8 e 29.
- EARMAN, J. *Bayes or Bust? A Critical Examination of Bayesian Confirmation Theory*. [S.l.]: Cambridge, ma: MIT Press, 1992. Citado na página 23.
- FINETTI, B. de. Foresight: Its logical laws, its subjective sources (1935). *H. Kyburg and H. Smokler*, 1992. Citado na página 13.
- GALISON, P.; HEVLY, B. W. *Big science: The growth of large-scale research*. [S.l.]: Stanford University Press, 1992. Citado na página 25.
- GODFREY-SMITH, P. *Theory and reality: An introduction to the philosophy of science*. [S.l.]: University of Chicago Press, 2009. Citado na página 24.
- GOVIER, T. *Social trust and human communities*. [S.l.]: McGill-Queen's Press-MQUP, 1997. Citado na página 9.
- HALPERN, J. Y. *Reasoning about uncertainty*. [S.l.]: MIT press, 2005. Citado na página 20.
- HARDWIG, J. The role of trust in knowledge. *The Journal of Philosophy*, v. 88, n. 12, p. 693–708, 1991. Citado na página 27.
- HAWTHORNE, J. Confirmation theory. *Philosophy of statistics, handbook of the philosophy of science*, v. 7, p. 333–389, 2011. Citado na página 23.

¹ De acordo com a Associação Brasileira de Normas Técnicas. NBR 6023.

- HOWSON, C.; URBACH, P. *Scientific reasoning: the Bayesian approach*. [S.l.]: Open Court Publishing, 2006. Citado 3 vezes nas páginas 14, 15 e 17.
- IOANNIDIS, J. P. Why most published research findings are false. *PLoS med*, Public Library of Science, v. 2, n. 8, p. e124, 2005. Citado na página 24.
- JACKSON, A. A labor of love: the mathematics genealogy project. *Notices of the AMS*, v. 54, n. 8, p. 1002–1003, 2007. Citado na página 25.
- JAYNES, E. T. *Probability theory: The logic of science*. [S.l.]: Cambridge university press, 2003. Citado 4 vezes nas páginas 13, 15, 16 e 23.
- JEFFREY, R. *Subjective probability: The real thing*. [S.l.]: Cambridge University Press, 2004. Citado 3 vezes nas páginas 13, 15 e 17.
- KAHNEMAN, D.; TVERSKY, A. Prospect theory: An analysis of decision under risk. *Econometrica: Journal of the econometric society*, JSTOR, p. 263–291, 1979. Citado na página 20.
- KRAUSS, S.; MARTIGNON, L.; HOFFRAGE, U. Simplifying bayesian inference: The general case. In: *Model-based reasoning in scientific discovery*. [S.l.]: Springer, 1999. p. 165–179. Citado na página 20.
- MAHER, P. *Betting on theories*. [S.l.]: Cambridge University Press, 1993. Citado 2 vezes nas páginas 15 e 23.
- MARTINS, A. C. Adaptive probability theory: Human biases as an adaptation. 2005. Citado na página 21.
- MARTINS, A. C. Modeling scientific agents for a better science. *Advances in Complex Systems*, World Scientific, v. 13, n. 04, p. 519–533, 2010. Citado 3 vezes nas páginas 9, 36 e 37.
- MARTINS, A. C. Bayesian updating as basis for opinion dynamics models. In: *XI BRAZILIAN MEETING ON BAYESIAN STATISTICS: EBEB 2012*. [S.l.: s.n.], 2012. v. 1490, n. 1, p. 212–221. Citado 3 vezes nas páginas 9, 30 e 31.
- MARTINS, A. C. Modelling epistemic systems. *Theories and Simulations of Complex Social Systems*, Springer Science & Business Media, v. 52, p. 19, 2013. Citado 4 vezes nas páginas 8, 9, 36 e 37.
- MARTINS, A. C. Trust in the coda model: Opinion dynamics and the reliability of other agents. *Physics Letters A*, Elsevier, v. 377, n. 37, p. 2333–2339, 2013. Citado 3 vezes nas páginas 9, 37 e 41.
- MERTON, R. K. Behavior patterns of scientists. *The American Scholar*, JSTOR, p. 197–225, 1969. Citado na página 10.
- MERTON, R. K. *The sociology of science: Theoretical and empirical investigations*. [S.l.]: University of Chicago press, 1973. Citado 4 vezes nas páginas 9, 25, 26 e 28.
- NICKERSON, R. S. *Cognition and chance: The psychology of probabilistic reasoning*. [S.l.]: Psychology Press, 2004. Citado 2 vezes nas páginas 21 e 23.

PENA, S. D. Thomas bayes: o cara'! *Ciência Hoje*, SOCIEDADE BRASILEIRA PARA O PROGRESSO DA CIENCIA, v. 38, n. 228, p. 22, 2006. Citado na página 17.

PINKER, S. How the mind works. *Annals of the New York Academy of Sciences*, Wiley Online Library, v. 882, n. 1, p. 119–127, 1999. Citado na página 21.

POLANYI, M. *The Study of Man (Routledge Revivals): The Lindsay Memorial Lectures 1958*. [S.l.]: Routledge, 2013. Citado na página 28.

POLANYI, M. *Personal knowledge: Towards a post-critical philosophy*. [S.l.]: University of Chicago Press, 2015. Citado na página 26.

POPPER, K. *The logic of scientific discovery*. [S.l.]: Routledge, 2005. Citado na página 8.

POPPER, K. *Conjectures and refutations: The growth of scientific knowledge*. [S.l.]: routledge, 2014. Citado na página 8.

PRESS, S. J.; TANUR, J. M. *The subjectivity of scientists and the Bayesian approach*. [S.l.]: John Wiley & Sons, 2012. v. 775. Citado na página 23.

PRICE, D. J. de S.; PRICE, D. D. S. *Little science, big science*. [S.l.]: Columbia University Press New York, 1965. Citado 2 vezes nas páginas 8 e 24.

RAMSEY, F. P. Truth and probability (1926). *The foundations of mathematics and other logical essays*, p. 156–198, 1931. Citado na página 13.

ROSENTHAL, J. S. *A first look at rigorous probability theory*. [S.l.]: World Scientific Publishing Co Inc, 2006. Citado na página 11.

SAVAGE, L. J. *The foundations of statistics*. [S.l.]: Courier Corporation, 1972. Citado na página 11.

SHAPIN, S. *A social history of truth: Civility and science in seventeenth-century England*. [S.l.]: University of Chicago Press, 1994. Citado 3 vezes nas páginas 8, 25 e 26.

SHAPIN, S. *The scientific life: A moral history of a late modern vocation*. [S.l.]: University of Chicago Press, 2009. Citado na página 25.

SMALDINO, P. E.; MCELREATH, R. The natural selection of bad science. *Royal Society Open Science*, The Royal Society, v. 3, n. 9, p. 160384, 2016. Citado na página 24.

TENENBAUM, J. B.; GRIFFITHS, T. L. Generalization, similarity, and bayesian inference. *Behavioral and brain sciences*, Cambridge Univ Press, v. 24, n. 04, p. 629–640, 2001. Citado na página 20.

TVERSKY, A.; KAHNEMAN, D. Advances in prospect theory: Cumulative representation of uncertainty. *Journal of Risk and uncertainty*, Springer, v. 5, n. 4, p. 297–323, 1992. Citado na página 20.

VENKATESH, S. S. *The theory of probability: Explorations and applications*. [S.l.]: Cambridge University Press, 2012. Citado 2 vezes nas páginas 11 e 12.

WANG, J.; VEUGELERS, R.; STEPHAN, P. *Bias against novelty in science: A cautionary tale for users of bibliometric indicators*. [S.l.], 2016. Citado na página 24.

WHITLEY, R. *The intellectual and social organization of the sciences*. [S.l.]: Oxford University Press, 2000. Citado 2 vezes nas páginas 8 e 25.

WILLIAMS, M. *Problems of knowledge: A critical introduction to epistemology*. 2001. Citado na página 22.

ZIMAN, J. M. *Reliable knowledge: An exploration of the grounds for belief in science*. [S.l.]: Cambridge University Press, 1991. Citado na página 26.