



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Modelo de Simulação baseado em Agentes Interativos com Teoria de Jogos para Uso e Cobertura da Terra

Cássio Giorgio Couto Coelho

Tese apresentada como requisito parcial
para conclusão do Doutorado em Informática

Orientadora
Prof. Dr. Célia Ghedini Ralha

Brasília
2021

Universidade de Brasília — UnB
Instituto de Ciências Exatas
Departamento de Ciência da Computação
Doutorado em Informática

Coordenador: Prof. Dr. Ricardo Pezzuol Jacobi

Banca examinadora composta por:

Prof. Dr. Célia Ghedini Ralha (Orientadora) — CIC/UnB
Prof. Dr. André Carlos Ponce de Leon Ferreira de Carvalho — ICMC-USP
Prof. Dr. Bruno Luigi Macchiavello Espinoza — CIC/UnB
Prof. Dr. Christophe Yvon Le Page — CIRAD
Prof. Dr. Ricardo Bomfim Machado — ZOO/UnB

CIP — Catalogação Internacional na Publicação

Coelho, Cássio Giorgio Couto.

Modelo de Simulação baseado em Agentes Interativos com Teoria de Jogos para Uso e Cobertura da Terra / Cássio Giorgio Couto Coelho.

Brasília : UnB, 2021.

95 p. : il. ; 29,5 cm.

Tese (Doutorado) — Universidade de Brasília, Brasília, 2021.

1. agentes inteligentes, 2. deliberação distribuída, 3. políticas públicas, 4. simulação baseada em agentes, 5. modelagem e simulação de paisagem, 6. teoria de jogos evolucionários

CDU 004

Endereço: Universidade de Brasília
Campus Universitário Darcy Ribeiro — Asa Norte
CEP 70910-900
Brasília-DF — Brasil



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Modelo de Simulação baseado em Agentes Interativos com Teoria de Jogos para Uso e Cobertura da Terra

Cássio Giorgio Couto Coelho

Tese apresentada como requisito parcial
para conclusão do Doutorado em Informática

Prof. Dr. Célia Ghedini Ralha (Orientadora)
CIC/UnB

Prof. Dr. André Carlos Ponce de Leon Ferreira de Carvalho
ICMC-USP

Prof. Dr. Christophe Yvon Le Page
CIRAD

Prof. Dr. Bruno Luigi Macchiavello Espinoza
CIC/UnB

Prof. Dr. Ricardo Bomfim Machado
ZOO/UnB

Prof. Dr. Ricardo Pezzuol Jacobi
Coordenador do Doutorado em Informática

Brasília, 17 de dezembro de 2021

Dedicatória

Dedico este trabalho à minha mãe e à minha avó, que sempre me motivaram a continuar estudando e insistindo em seguir em frente.

Resumo

As mudanças ambientais, percebidas de forma cada vez mais dramática nos últimos anos, são em grande parte fruto de processos socioeconômicos e culturais provenientes de atividades humanas. Processos ligados ao uso e à transformação do solo são especialmente impactantes. Estudos sugerem que a conversão de espaços de vegetação original para área antropizada está diretamente ligado ao aumento da emissão de CO_2 na atmosfera, implicando no aumento da temperatura terrestre. Além disso, tal fato está diretamente ligado ao secamento de afluentes, perda da capacidade de absorção de água no solo, impacto na produção agrícola, extinção de espécies e outras consequência catastróficas.

A Ecologia de Paisagem, área de Ecologia que possui foco no estudo da influência humana sobre o meio ambiente e no entendimento de processos de transformação do espaço, possui um grande apoio de modelos computacionais para o alcance de seus objetivos. Modelos baseados em agentes são particularmente interessantes nesse contexto por possibilitarem a representação de modelos de cognição humana e de interação dos agentes, dentre outras propriedades. Dessa forma, este trabalho explora a hipótese que interações dos agentes são capazes de influenciar a organização do espaço por meio de processos transformativos em modelos baseados em agentes para uso e cobertura do solo.

Nesse trabalho é proposto um modelo de interação para a resolução de conflitos por recursos espaciais baseado em Teoria dos Jogos Evolucionários (TJE). Esse modelo de interação possui um sistema de decisão e um sistema de regras. O sistema de decisão define se a resolução do conflito é feita por um gerente (decisão centralizada) ou pelos agentes envolvidos no conflito (decisão distribuída). O sistema de regras define que jogo de TJE será utilizado para modelar as diferentes classes de exploração que os agentes representam, Além disso, o sistema de regras é utilizado para determinar o ganhador do recurso numa situação de conflito. Agentes ainda têm a possibilidade de trocar de estratégia com base no resultado do conflito e no sistema de regras, assim influenciando o perfil da sociedade a qual eles pertencem.

Resultados obtidos de oito rodadas de experimento com variações nos sistemas de decisão e de regras sugerem que de fato o modelo de interação é capaz de influenciar o estado do espaço simulado final produzido. A validação e verificação do modelo, feita por meio das métricas *Root Mean Square Error* (RMSE) e *Structural Similarity Index Measurement* (SSIM), além da aferição estatística do resultados, evidenciam os possíveis desdobramentos de cada variação do modelo.

Palavras-chave: agentes inteligentes, deliberação distribuída, políticas públicas, simulação baseada em agentes, modelagem e simulação de paisagem, teoria de jogos evolucionários

Abstract

Environmental changes, perceived dramatically in the last few years, are in general the result of socioeconomic and cultural processes that are directly related to human activity. Land use cover change processes are especially impactful to the environment. Recent studies suggest that the conversion of original vegetation to anthropized spaces is linked to high CO_2 emissions to the atmosphere. This process is also linked to the drying of rivers and basins, loss of soil's water absorption capacity, negative impact of agricultural yields, species extinction and many other catastrophic consequences.

Landscape Ecology, an Ecology field of study that focuses on the study of the human influence over the environment and on the understanding of space transformation processes, is greatly supported by computational models to achieve its goals. In this context, agent-based models are particularly relevant to represent human cognition models and agent interactions. Thus, this work explores the hypothesis that agent interactions can influence the spatial organization through transformative processes of usage and soil coverage in agent-based models.

In this work, an interaction model of spatial resources conflict resolution based on *Evolutionary Game Theory* (EGT) is proposed. This interaction model contains a decisions system and a rules system. The decisions system defines if the conflict resolution is handled by a manager (centralized decision) or by the agents involved in the conflict (distributed decision). The rules system defines what EGT game will be used to model which exploration classes the agents represent. Furthermore, the rules system determines who wins in a conflict scenario. Agents can change strategies based on conflict results and the rules system, influencing the societal profile to which they belong.

Results obtained through eight rounds of experiments with variations of the decision and rules systems suggest the interaction model influences the final simulated spatial state. The model's validation & verification, through *Root Mean Square Error* (RMSE) and *Structural Similarity Index Measurement* (SSIM), not only measure the results statistically but also bring to highlight possible unfoldings of each model variation.

Keywords: intelligent agents, distributed deliberation, public policies, agent-based simulation, landscape simulation modeling, evolutionary game theory

Sumário

1	Introdução	1
1.1	Problema	3
1.2	Justificativa	4
1.3	Hipótese e Objetivos	5
1.4	Metodologia	5
1.5	Contribuições	7
1.6	Estrutura do Documento	8
2	Fundamentação Teórica	9
2.1	Sistema Multiagente	9
2.2	Ecologia de Paisagem: Modelagem e Simulação	13
2.3	Teoria de Jogos	15
2.3.1	Estratégias Puras e Mistas	15
2.3.2	Jogos Evolucionários	18
2.3.3	Força do Dilema	22
3	Trabalhos Correlatos	24
3.1	Modelos Espaciais e Ecológicos	24
3.1.1	Jogos em Espaços Celulares	24
3.1.2	Irrigação e Depleção de Aquíferos Subterrâneos	25
3.2	Ferramentas de Simulação	26
3.2.1	Cormas	26
3.2.2	GAMA	27
3.2.3	MASS	27
3.2.4	NetLogo	28
3.2.5	TerraME	28
3.2.6	ABED	28
3.2.7	Dynamo	29
4	Proposta	30
4.1	Modelo de Simulação	30
4.1.1	Espaço	30
4.1.2	Tempo	31
4.1.3	Agentes	32
4.1.4	Interação	35
4.1.5	Política Pública	44
4.2	Simulador	44

4.2.1	Arquitetura	44
4.2.2	Implementação	46
5	Caso de Uso	51
5.1	Caracterização do Modelo	51
5.1.1	Visão Geral	51
5.1.2	Conceitos de Projeto	55
5.1.3	Detalhes	56
5.2	Resultados Experimentais	60
6	Conclusão	74
	Referências	77

Lista de Figuras

1.1	Os três níveis de interação explorados no MASE-EGTI. Fonte: elaborado pelo autor (2021).	7
2.1	Várias arquiteturas propostas para SMA. Fonte: Pokahr e Braubach (2009) [55]). Traduzido pelo autor.	11
4.1	Um exemplo de máquina de estados para a representação das células no espaço. Fonte: Sano et al. (2008) [61]. Adaptado pelo autor.	31
4.2	A representação do espaço e respectivos detalhamentos. Fonte: elaborado pelo autor (2021).	32
4.3	A representação simplificada de um step i do tempo. Fonte: elaborado pelo autor (2021).	33
4.4	A visão geral da arquitetura do MASE-EGTI. Fonte: elaborado pelo autor (2020).	45
4.5	A interface gráfica do MASE-EGTI com uma simulação em execução. Fonte: elaborado pelo autor (2020).	45
4.6	A representação de um agente BDI implementado com o <i>framework</i> JADEX. Fonte: Braubach e Pokahr (2011) [9]. Traduzido pelo autor.	47
4.7	Amostra do espaço em que quatro agentes coincidentemente desejam trocar de célula. Enquanto o agente 3 (A3) não tem concorrentes, agentes 1, 2 e 4 (A1, A2 e A4) terão que resolver seus conflitos por meio do gerente ou entre si, de acordo com o sistema de decisão definido. Fonte: elaborado pelo autor (2021).	48
4.8	Um exemplo de troca de mensagens entre quatro agentes e o gerente, baseado nas intenções de mudança registradas na Figura 4.7. Fonte: elaborado pelo autor (2021).	48
5.1	Os estágios de formação da matriz proximal. Fonte: elaborado pelo autor (2021).	53
5.2	A política pública do PDOT. Fonte: Secretaria de Habitação, Regularização e Desenvolvimento Urbano do Distrito Federal (2009) [29]. Adaptado pelo autor.	54
5.3	O espaço inicial do modelo. Fonte: Souza et al. (2020) [67]. Adaptado pelo autor.	56
5.4	Os atributos proximais do modelo. Fonte: Souza et al. (2020) [67]. Adaptado pelo autor.	57
5.5	As imagens utilizadas para a avaliação da atratividade e valiosidade. Fonte: elaborado pelo autor (2021).	61

5.6	Os resultados das oito rodadas de experimentos, em que as áreas laranjas foram ocupadas e exploradas por agentes de grande porte e as azuis, subsistência. Fonte: elaborado pelo autor (2021).	67
5.7	A quantidade de espaços dos tipos de floresta original e de espaço antropizado obtidas por classe de exploração por experimento. Fonte: elaborado pelo autor (2021).	68
5.8	A quantidade de espaços dos tipos valioso, regular e não valioso obtidas por classe de exploração por experimento. Fonte: elaborado pelo autor (2021).	69
5.9	O tempo de execução dos <i>steps</i> de simulação de cada experimento. Fonte: elaborado pelo autor (2021).	70
5.10	A quantidade de mensagens trocadas durante a simulação de cada experimento. Fonte: elaborado pelo autor (2021).	71
5.11	A quantidade de agentes de cada tipo por <i>step</i> em cada simulação. Fonte: elaborado pelo autor (2021).	72
5.12	As diferenças de <i>payoffs</i> . Fonte: elaborado pelo autor (2021).	73

Lista de Tabelas

2.1	Jogo em que dois amigos decidem estudar juntos. O <i>payoff</i> do jogo é a nota que cada um irá obter dependendo de suas ações.	16
2.2	Jogo em que ambos jogadores lançam cada um uma moeda e verificam as faces obtidas. Se ambas faces forem iguais, o Jogador α ganha. Caso contrário, o Jogador β ganha. Em qualquer situação, o ganhador toma a moeda do perdedor.	17
2.3	O Jogo Hawk-Dove proposto por Maynard e Price em 1973	19
2.4	Um exemplo de jogo genérico em TJE	20
2.5	A parametrização do dilema dos prisioneiros.	22
3.1	Tabela comparativa com MASE-EGTI e as ferramentas apresentadas na Seção 3.2.	29
4.1	Os payoffs dos encontros de mineradores e extrativistas como um jogo de Hawk-Dove	37
4.2	Um jogo genérico utilizado para a construção do sistema de regras G	38
4.3	O jogo Hawk-Dove com custo de recompensa $V = 2$ e custo de conflito $C = 4$	39
4.4	Probabilidade do Agente α permanecer em sua estratégia após conflitar com Agente β	40
4.5	Resultados sintetizados módulo de estatística do MASE-EGTI.	46
5.1	A visão geral do protocolo ODD. Fonte: Grimm et al. (2020) [35]. Traduzido e adaptado pelo autor.	52
5.2	<i>Payoffs</i> utilizados para os jogos de Dilema dos Prisioneiros e <i>hawk-dove</i>	58
5.3	Os experimentos realizados com o Modelo Cerrado MapBiomias.	61
5.4	Os resultados das métricas de RMSE e SSIM.	61

Lista de Abreviaturas e Siglas

- BDI** *Belief-Desire-Intentions*. 6, 12, 29, 33, 46
- DF** Distrito Federal. 6
- EGT** *Evolutionary Game Theory*. vi
- ESS** *Evolutionary Stable Strategy*. 19, 20, 21
- FIFO** *First In, First Out*. 36
- FTA** *First Takes All*. 36, 37, 49, 57, 61, 62, 63, 64, 65, 66, 67, 68, 69, 70, 71, 75
- GID** *Gamble-Intending Dilemma*. 23, 41
- IA** Inteligência Artificial. 9, 10, 13
- INPE** Instituto Nacional de Pesquisas Espaciais. 1, 28
- LUCC** *Land Use Cover Change*. 1, 2, 3, 4, 5, 6, 13, 14, 24, 25, 30, 44, 51, 74, 75, 76
- MapBiomás** Projeto de Mapeamento de Uso e Cobertura da Terra no Brasil. 51, 52
- MASE** *Multi-Agent System for Environmental Simulation*. 6, 7, 36, 51
- MASE-BDI** *Multi-Agent System for Environmental Simulation with Belief-Desire-Intention Cognition*. 6, 7, 36, 46, 47, 51
- MASE-EGTI** *Multi-Agent System for Environmental Simulation with Evolutionary Game Theory Interactions*. ix, xi, 6, 7, 8, 24, 26, 29, 30, 44, 45, 46, 47, 49, 52, 76
- MBA** Modelos Baseados em Agentes. 3, 4, 5, 6, 12, 14, 15, 23, 24, 29, 51, 74
- ODD** *Overview, Design and Details*. xi, 51, 52, 62, 66
- PDOT** Plano Diretor de Ordenamento Territorial do Distrito Federal. 54, 56, 60, 74
- RAD** *Risk-Averting Dilemma*. 23, 41
- RMSE** *Root Mean Square Error*. v, vi, xi, 58, 59, 60, 61, 62

SMA Sistemas Multiagentes. ix, 3, 4, 6, 9, 10, 11, 12, 15, 23, 24, 25, 26, 27, 29, 47

SNG *Stop and Go*. 36, 37, 49, 57, 58, 61, 62, 63, 64, 65, 67, 68, 69, 70, 71, 72, 73, 75, 76

SSIM *Structural Similarity Index Measurement*. v, vi, xi, 58, 59, 60, 61, 62

STAIP **S**pace, **T**ime, **A**gents, **I**nteraction, **P**ublic Policy. 8, 30, 31, 33, 34, 35, 36, 38, 39, 41, 42, 43, 44, 46, 47, 51, 52, 60, 62, 74

TJ Teoria do Jogos. 3, 4, 6, 8, 9, 12, 15, 16, 17, 18, 22, 23, 24, 25, 26, 29, 37, 51

TJE Teoria dos Jogos Evolucionários. v, xi, 3, 4, 5, 6, 8, 9, 12, 18, 19, 20, 21, 22, 23, 24, 25, 26, 29, 35, 37, 51, 63, 74

V&V Verificação e Validação. 2, 5, 6, 15, 51

Capítulo 1

Introdução

Processos de uso e conversão da terra (*Land Use Cover Change* - LUCC) são contribuidores cruciais para as mudanças ambientais no planeta fortemente percebidas nas últimas décadas [37, 40, 54, 73]. A conversão e o uso de espaços naturais por atividades socioeconômicas é responsável pelo desencadeamento de diversos processos que resultam em efeitos catastróficos e muitas vezes irreversíveis, como a liberação de gases que provocam o efeito estufa, a destruição do hábitat natural de espécies e a poluição de nascentes de rios, dentre outras consequências negativas para o meio ambiente e a sociedade [26, 28, 63]. Pode-se citar a pecuária como uma das atividades socioeconômicas mais poluidoras da atmosfera, causadora da liberação de cerca de 60% de todos os gases do efeito estufa disposto pela sociedade anualmente, seja por queimadas, pelo manejo inadequado do pasto e do gado ou por outras atividades ligadas a essa prática [50, 52, 60].

Especificamente no Brasil, as atividades agropecuárias possuem grandes atrativos econômicos por causa da alta disponibilidade de territórios com preços reduzidos. Tais territórios são comumente localizados dentro da região da Floresta Amazônica [28, 52] e do Cerrado [24, 58], sendo estes os dois maiores biomas da América do Sul. Nos últimos anos, em uma frequência cada vez mais dramática, são percebidas maiores e mais desastrosas transformações ambientais. Alguns dos fenômenos registrados nesse sentido são o secamento de rios e o alagamento de áreas urbanizadas, as estiagens mais prolongadas seguidas por chuvas mais intensas e torrenciais e a quase extinção ou até a completa extinção de espécies nativas. Além disso, é cada vez mais noticiados a superpopulação de pragas, a poluição do ar, o aumento de temperaturas, a perda de produção de lavouras, dentre outros desequilíbrios ambientais severos [50].

Considerando o cenário global, mais de 50% da superfície terrestre não coberta por gelo já foi afetada ou modificada por atividades antrópicas. Uma estimativa apresentada por Vitousek et. al (1997) [49] previa que essa proporção atingiria a marca de 100% ainda no Século XXI. Entre 1990 e 2010, as atividades relacionadas à LUCC sozinhas foram responsáveis por 12.5% das emissões de gás carbônico na atmosfera [40]. Tais consequências não se restringem apenas à emissão de gases contribuintes para o aquecimento global. A Amazônia já não consegue absorver gás CO_2 com a mesma eficiência ao longo da última década, conforme mostram recentes pesquisas realizadas pelo Instituto Nacional de Pesquisas Espaciais (INPE) em parceria com diversos órgãos governamentais e instituições de pesquisa nacionais e internacionais [28]. Entre 2009 e 2018 registraram-se recordes de queimadas em áreas de floresta, de abertura de pastos para a pecuária bovina, de períodos

mais severos de estiagem, do afinamento e o assoreamento de rios e afluentes em um dos maiores biomas do planeta [28].

Outros estudos direcionados ao Cerrado demonstraram que os sistemas de manejo podem afetar o equilíbrio sensível entre secas/queimadas e chuvas/reabsorção da água pelo solo [24]. Enquanto o fogo é importante para processos biofísicos no Cerrado, o seu uso descontrolado para a abertura de áreas para agropecuária causa desbalanceio na permeabilidade do solo, dentre outras consequências, que podem refletir em outras áreas dentro e fora do bioma. Isso é observado, dentre outros fatores, pelo uso impróprio de queimadas para a limpeza de regiões a serem usadas como pasto, processo que pode interferir nas propriedades químico-físicas do solo, afetando sua capacidade de absorver água e abastecer mananciais subterrâneos. Uma consequência possível deste cenário é a diminuição do volume de rios que se estendem a outras áreas brasileiras, cujas nascentes e afluentes se encontram dentro da área do Cerrado [24, 58]. Conforme descrito, particularidades em LUCC não apenas se resumem a consequências locais, mas podem interferir em outras regiões além da estudada através de um “efeito dominó”.

Questões ambientais como as descritas são de interesse não apenas de estudiosos na área de Ciências Biológicas e Gestão Ambiental, mas também em Economia, Ciência Política, Direito, Engenharia, Geologia, dentre outras, devida à grandiosidade de seu impacto no presente e no futuro do planeta e da humanidade [7, 50, 57]. Dentro da disciplina de Ecologia de Paisagem o estudo de LUCC encontra interseção com essas e muitas outras áreas do conhecimento, uma vez que suas questões envolvem diversos fatores interligados entre si [57].

Partindo de um fato cientificamente comprovado, o efeito estufa é diretamente relacionado à emissão de carbono na atmosfera por causa de queimadas [26, 40, 50, 52, 58, 63]. Cabe não somente à Ecologia investigar a correlação entre o volume de CO_2 desprendido de queimadas e o aumento das temperaturas globais, mas também ao Direito Ambiental buscar o cumprimento e o reforço de leis de proteção ambiental de áreas de conservação e preservação. No entanto, a agropecuária é base da economia local de muitos municípios dentro da Amazônia e do Cerrado. Sendo assim a restrição de tais práticas pode encontrar uma resistência de donos de fazendas de produção de gado e bens agricultáveis, envolvendo questões em Economia e Ciência Política. Geólogos e engenheiros também possuem questões relacionadas às mudanças ambientais - uma vez que podem provocar impactos em relevo e paisagem não apenas na área do bioma em si, mas em diversas regiões adjacentes. Por isso, Ecologia de Paisagem é uma disciplina intrinsecamente multidisciplinar, produzindo pesquisas importantes não apenas envolvendo mudanças globais em clima e outros aspectos ambientais, mas em outras diversas áreas do conhecimento humano.

A relação entre Ciência da Computação e Ecologia de Paisagem é enfatizada neste trabalho por meio de investigações em modelos de dinâmica da terra com uso de simulação computacional. Como já observado, sistemas ecológicos possuem grandes dimensões com conexões complexas entre diversos saberes, e por isso é inviável fazer a Verificação e Validação (V&V) de hipóteses sobre políticas públicas, por exemplo, no ambiente físico. Em face à complexidade apresentada por estudos realizados em LUCC e Ecologia de Paisagem, modelos de simulação são comumente elaborados no estudo de fenômenos em cenários ambientais [72]. Nesses modelos, por exemplo, agentes movem-se e exploram o espaço de acordo com regras pré-estabelecidas pelo modelador, tentando representar ocor-

rências observadas no mundo real. Os agentes são capazes de interagir entre si, competir por recursos e cooperar para alcançar objetivos comuns ou individuais, envolvendo-se em dilemas e negociações. Mesmo que seja impossível capturar e transpor todos os elementos e detalhes do fenômeno a ser estudado, esses modelos podem ser úteis para o detalhamento e entendimento das principais características observáveis da realidade [5, 6, 53].

1.1 Problema

Conforme exposto, os modelos de simulação são instrumentos úteis para a compreensão do fenômeno principal estudado e de processos correlatos, ainda que de forma artificial [48]. Modelos Baseados em Agentes (MBA) têm destaque nesse contexto, uma vez que neles agentes autônomos podem destacar características emergentes do modelo oriundas tanto das especificações feitas pelo modelador quanto pelas suas propriedades cognitivas, sociais e autônomas definidas [53, 55, 78]. Emergência é um tema bastante abordado em estudos em Sistemas Multiagentes (SMA) - área afim de MBA - pela possibilidade de fornecer teorias sobre o funcionamento de sistemas complexos de forma empírica [70] - como os representados por MBA para LUCC.

A ocorrência de conflitos entre agentes por recursos é uma propriedade emergente que não deriva necessariamente de regras estabelecidas em modelos de LUCC. Adicionalmente, conflitos podem emergir de situações em que agentes precisam escolher entre potenciais consequências. Consequentemente, a disposição dos recursos do solo e a transformação da sociedade também pode emergir dessas situações estratégicas. A partir disso, o principal problema explorado neste trabalho é o entendimento de como as interações sociais entre agentes podem afetar a organização do espaço final explorado em simulações de MBA para LUCC. Deseja-se, então, evidenciar a produção de resultados diferentes quando há mudança no relacionamento, na hierarquia e nas ações entre os agentes da simulação.

O problema principal desta pesquisa tem origem nas relações humanas entre si da sociedade e com o meio ambiente, e suas representações computacionais em MBA, especialmente no contexto de simulações em LUCC. Por isso, este trabalho possui o foco no relacionamento entre agentes e seus ganhos e perdas de utilidade por meio da exploração dos recursos, pelo conflito por áreas, pela deliberação entre si ou pela cooperação no alcance do objetivo da simulação. Essas situações estratégicas poderiam ser interpretadas como jogos sob a ótica de Teoria dos Jogos (TJ), em que agentes são jogadores, seus comportamentos são as estratégias possíveis e o *payoff* dependem da ação coletiva entre dois ou mais agentes. No entanto, uma questão adicional agrega-se ao problema principal: Seriam jogos em TJ provedores de arquétipos válidos e representativos para a criação de modelos de interação de agentes em simulações de LUCC?

Uma ideia explorada neste trabalho é considerar a implementação de regras de Teoria dos Jogos Evolucionários (TJE) na evolução dos agentes como consequência da resolução de conflitos por recursos ambientais. Considera-se que o impedimento na expansão da fronteira agrícola, por exemplo, pode representar a perda da influência de um agricultor sobre a transformação do espaço. Portanto, intuitivamente pode-se concluir que a variação na utilidade de um agente ou uma classe de agentes pode diretamente influenciar na sua presença como força de transformação da paisagem. A variação da influência pode estabelecer um paralelo com a variação da adaptabilidade - um dos pontos centrais do estudo em TJE, validando a ideia de estender o domínio de modelos de interação apoiados

em TJ para TJE. Por esse motivo, agrega-se ao problema dessa pesquisa o uso de TJE na construção de modelos de interação em LUCC e suas eventuais consequências na paisagem final.

1.2 Justificativa

Em SMA é esperado que agentes, ao estabelecer comportamentos cooperativos com troca de informações por meio de mensagens, demonstrem competência como propriedade emergente de suas interações [36]. Competência, como sinônimo de capacidade de resolver um problema de forma acurada e qualificada pode emergir: i) tanto de uma quantidade populosa de agentes simples e unidos diante do mesmo objetivo de forma estruturada; ii) quanto de agentes inteligentes trabalhando diante de uma problema complexo, mas passível de ser modularizado e processado concorrentemente [36]. Em ambos paradigmas, agentes trabalham conjuntamente no ambiente que convivem, seja programados para cumprir ações pré-estabelecidas e bem estruturadas, compartilhando informações que forem obtendo ao longo de suas execuções, ou realizando um equilíbrio de ambas atividades enquanto tentam alcançar um objetivo comum.

Sob a premissa que os agentes são benevolentes [78, 79] e considerando que as simulações de MBA em LUCC envolvem os agentes com pelo menos um objetivo comum - representar a influência antrópica de uso e transformação da terra - espera-se que agentes que interagem possuam competência em cumprir esse objetivo. Mesmo que no contexto do modelo os agentes assumam papéis antagônicos, em sua globalidade eles trabalham para que a representação do modelo seja executada com sucesso.

No entanto, pela autonomia intrínseca dos agentes, emergem em contraponto à competência problemas de sincronização que precisam ser tratados para que o objetivo seja cumprido eficientemente e consistentemente [78]. Essa é uma desvantagem em apoiar-se em propriedades emergentes para o estudo de sistemas complexos - a emergência observada pode adicionar dificuldades no entendimento do fenômeno, em vez de explicá-lo. No contexto de MBA em LUCC, isso é notável em processos de compartilhamento de recursos, especialmente em modelos espacialmente explícitos [13]. Nesses modelos, pode ocorrer competição entre agentes pelas mesmas unidades do espaço e comportamentos adicionais precisam ser implementados para tratar condições de inconsistência - também conhecidas como condições de corrida [68].

Além disso, a emergência das competições por espaço na sociedade implica no surgimento de situações estratégicas cujos desdobramentos dependem da resposta de múltiplos agentes. Por exemplo, se dois agentes buscam obter uma mesma unidade de espaço mas somente um pode obtê-la, como eles irão decidir quem, por direito, é detentor desse recurso espacial? Dentre as possíveis ações a serem tomadas, como o uso da força bruta ou o uso da lei, qual é o resultado obtido pelos agentes e qual o destino do espaço almejado por eles? Esses questionamentos adquirem mais força se tais recursos possuírem elementos atrativos ou algum tipo de característica que agregue valor à sua localização - o que é observado na vida real. Adicionalmente, se os desdobramentos da competição espacial implicam no ganho de influência de uma das partes do conflito e na perda da outra, a forma como os agentes se relacionam é relevante para a evolução do perfil das atividades socioeconômicas que alteram o espaço. Sendo assim, o resultado da resolução

de conflitos espaciais é fator determinante para a transformação das paisagens naturais e da sociedade.

1.3 Hipótese e Objetivos

Agentes em MBA para LUCC podem representar esforços antrópicos realizando a transformação do solo por meio de atividades socioeconômicas. Além de ferramentas, técnicas de manejo e outras características dos atores do modelo, as suas inter-relações influenciam na maneira como o espaço poderá ser usado e transformado. Essas inter-relações, principalmente manifestadas por relações de conflitos bilateral ou multilateral por espaço, podem ser modeladas a partir de jogos em TJE. Isso é justificável porque o resultados dos conflitos também influencia a preponderância de atividades socioeconômicas mais influentes. Nesse sentido, diferentes modelos de interação entre agentes com jogos distintos são capazes de produzir diferentes resultados no ambiente simulado final e no perfil de atividades exploratórias do espaço.

Desta forma, a hipótese que este trabalho investiga pode ser descrita como:

Interações multilaterais modeladas por meio de jogos entre agentes de TJE em MBA influenciam como o espaço será usado e transformado - trazendo novos conhecimentos a respeito da preponderância de atividades socioeconômicas sobre o uso e conversão da terra.

Definida a hipótese de investigação, especifica-se como objetivo geral deste trabalho a demonstração de como as inter-relações de agentes podem produzir diferentes espaços resultantes de LUCC por meio de modelos de interação baseado em TJE. Esse objetivo refere-se aos modelos espacialmente explícitos, onde o espaço é subdividido em unidades de terra que não podem ser explorados por mais de um agente simultaneamente. Logo, se dois ou mais agentes quiserem obter o mesmo recurso espacialmente definido, eles terão que resolver um conflito para decidir quem ficará com o espaço. Além disso, não apenas a resolução do conflito indica quem deve ficar com o espaço, mas também sugere que atividade tem mais influência sobre a transformação do cenário de forma interativa. Para fins de comparação entre diferentes possibilidades de interação, é almejada a definição de variações do modelo e a averiguação das possíveis dissimilaridades dos resultados.

Sendo assim, são objetivos secundários dessa pesquisa:

- definir um cenário-base para a implementação de um modelo que será utilizado como referência para comparação;
- definir protocolos de interação de agentes para a implementação do modelo;
- estabelecer que variações do modelo serão exploradas e comparadas com o modelo do cenário-base;
- delinear um conjunto de métricas para V&V dos resultados dos modelos.

1.4 Metodologia

Para cumprir os objetivos desse trabalho foram utilizadas as seguintes etapas metodológicas interdependentes:

- estudo de conceitos teóricos para delineamento dos materiais e métodos atrelados à fundamentação teórica em LUCC, MBA, SMA, TJ e TJE;
- levantamento do estado da arte, incluindo trabalhos correlatos buscando o contexto situacional para esclarecimento das delimitações e potencialidades do projeto de pesquisa;
- definição da proposta de solução, incluindo a concepção e implementação do modelo de solução relacionados à hipótese e aos objetivos;
- experimentação e análise de resultados através da execução de simulações de cenários reais com aplicação de um conjunto de métricas de V&V.

Este trabalho utilizou a ferramenta *Multi-Agent System for Environmental Simulation* (MASE) [56] como base. Foi desenvolvida uma versão expandida do simulador MASE com o modelo de cognição de agentes *Belief-Desire-Intentions* (BDI), dando origem ao nome da versão MASE-BDI [11]. A atual versão denomina-se MASE-EGTI - *Multi-Agent System for Environmental Simulation with Evolutionary Game Theory Interactions*¹. Tal continuidade no desenvolvimento da ferramenta é um apoio importante para a problemática que este trabalho trata, uma vez que sustenta a investigação de cenários ambientais de MBA em LUCC, dentre eles o estudo realizado com o bioma Cerrado no Distrito Federal (DF) [11, 56]. Neste trabalho, utilizou-se um período mais amplo de 2000 a 2018 do Cerrado no DF [15]. Múltiplos cenários podem ser explorados com o auxílio de ferramentas de simulação, uma vez que eles facilitam a administração de regras definidas, a variação nos cenários e a produção de resultados experimentais - necessários para as atividades de validação de regras, sintonização de parâmetros e análise de sensibilidade, dentre outros processos. [7, 11, 15, 16, 21, 23, 43, 56, 71].

Essas funcionalidades são possíveis porque o MASE-EGTI possui uma interface gráfica a qual é utilizada para a definição do modelo a ser simulado. A partir do modelo gerado, é simples criar sub-modelos com variações de cenários. Tal interface será mostrada com mais detalhes no Capítulo 4, na Seção 4.2.2. Resumidamente, o modelo é definido pelo usuário e transformado pela ferramenta em um arquivo JSON, que então é lido e processado pela camada de controle do MASE-EGTI. A partir disso são estabelecidos os agentes, o espaço, as regras e outros objetos importantes para a simulação, a serem apresentados na Seção 4.1.

Nesse tópico, o ciclo de desenvolvimento do MASE ofereceu um novo incentivo que se alinha à justificativa deste trabalho. Em sua primeira versão, o MASE [56] foi apresentado como uma ferramenta com seis níveis de parametrização empírica para sistemas de representação de comportamento humano em cenários ambientais, conforme proposto por Smajgl et al. (2011) [64]. Além disso, foram apresentadas regras e agentes a nível de sociedade, por meio de políticas públicas para o ordenamento territorial do modelo explorado. Na versão do MASE-BDI[11] foi introduzido um novo modelo de cognição para os agentes estabelecendo regras a nível individual. Já no âmbito do MASE-EGTI considera-se as variações encontradas nas interações entre agentes competindo por recursos localizados no mesmo espaço, completando a lacuna entre parâmetros sociais e cognição individual, por meio das relações estabelecidas entre as entidades envolvidas no modelo e na ferramenta

¹Disponível em <https://gitlab.com/InfoKnow/MASE/MASE-BDI/mase-egti>

de simulação. Com isso, busca-se interligar raciocínio individual dos agentes às políticas públicas por meio das interações dos agentes. Desta forma, investiga-se quais possíveis resultados podem ser evidenciados em cenários distintos com três níveis de deliberação, conforme apresentado na Figura 1.1.

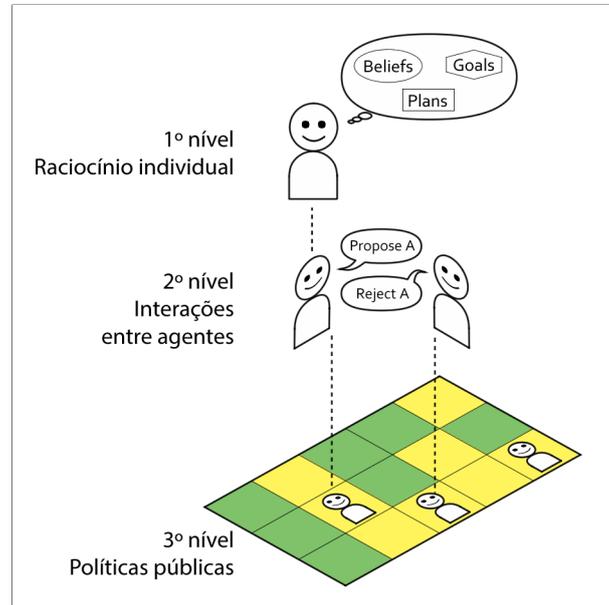


Figura 1.1: Os três níveis de interação explorados no MASE-EGTI. Fonte: elaborado pelo autor (2021).

Uma característica importante dos modelos explorados nos ciclos de vida do MASE, do MASE-BDI e do MASE-EGTI é a ocupação dos espaços por agentes de acordo com a cognição apresentada por eles (1º nível - raciocínio individual da Figura 1.1) e com as políticas públicas implementadas (3º nível - políticas públicas da Figura 1.1). Tais propriedades criaram a emergência de cenários de conflitos por espaço, os quais são ponto de partida para o desenvolvimento deste projeto. Uma vez que áreas individuais do espaço simulado não podem ser exploradas por mais de um agente simultaneamente, é criada uma competição por espaços mais atrativos. Essa situação estratégica depende de todos os agentes que estão interessados em obter o recursos, visto que suas próximas ações determinarão quem deles irá, de fato, obter a célula espacial. Então, intuitivamente, é possível perceber que interações entre os agentes (2º nível - interações entre agentes da Figura 1.1) acabam por ser parte integrante dos três níveis de deliberação explorados pelo projeto.

1.5 Contribuições

Durante o desenvolvimento desse projeto foram realizadas divulgações dos resultados em conferências e periódicos da área de Computação. Como contribuições científicas podemos citar as seguintes publicações:

- Cássio Giorgio Couto Coelho, Carolina Gonçalves Abreu, Rafael Marconi Ramos, Aldo Henrique Dias Mendes, George Teodoro, Célia Ghedini Ralha. MASE-BDI:

agent-based simulator for environmental land change with efficient and parallel auto-tuning. *Applied Intelligence* 45, 904–922, Electronic ISSN 1573-7497, Print ISSN 0924-669X (2016). <https://doi.org/10.1007/s10489-016-0797-8> [11]

- Cássio Giorgio Couto Coelho, Célia Ghedini Ralha. MASE-EGTI: Simulador baseado em Teoria dos Jogos Evolucionários para Sustentabilidade Ambiental. *Anais do X Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais. XXXIX Congresso da Sociedade Brasileira de Computação* (2019). <https://doi.org/10.5753/wcama.2019.6430> [14]
- Cássio Giorgio Couto Coelho, Célia Ghedini Ralha. MASE-EGTI: An agent-based simulator for environmental land change, *Environmental Modelling & Software*, Volume 147, 105252, ISSN 1364-8152 (2022). <https://doi.org/10.1016/j.envsoft.2021.105252> [15]
- Cássio Giorgio Couto Coelho, Célia Ghedini Ralha. Agent Interaction Models for Conflict Resolution on Land Use Cover Change Simulations, *Journal of Simulation*, Print ISSN 1747-7778, Online ISSN: 1747-7786 (submetido em 24-Nov-2021, em revisão).

1.6 Estrutura do Documento

Este manuscrito inclui nos capítulos que se seguem:

- Fundamentação Teórica (Capítulo 2) - apresenta conceitos que formam a base teórica deste trabalho incluindo sistema multiagente, simulação baseada em agentes, modelagem e simulação em Ecologia de Paisagem, TJ e TJE;
- Trabalhos Correlatos (Capítulo 3) - inclui a revisão da literatura com modelos e ferramentas de simulação relacionados a base teórica apresentada;
- Proposta (Capítulo 4) - apresenta o modelo de simulação proposto incluindo a especificação do espaço, tempo, agentes, modelo de interação e política pública (denominado pelo acrônimo STAIP - **S**pace, **T**ime, **A**gents, **I**nteraction, **P**ublic Policy), a introdução do modelo de interação composto por um sistema de decisão e de regras baseadas em TJE, e a descrição do simulador MASE-EGTI;
- Caso de Uso (Capítulo 5) - caracteriza o modelo Cerrado-MapBiomas utilizado para a validação do trabalho incluindo os resultados experimentais realizados com as respectivas discussões;
- Conclusão (Capítulo 6) - as considerações finais do trabalho realizado são apresentadas, bem como os trabalhos futuros são elencados.

Capítulo 2

Fundamentação Teórica

Neste capítulo serão apresentados os conceitos que formam a base teórica deste trabalho de pesquisa e dão apoio à proposta de modelo de interação. Na Seção 2.1, agentes, um dos pontos focais desta pesquisa, são caracterizados no contexto de SMA, área comum entre Sistemas Distribuídos e Inteligência Artificial (IA). A seguir, é explorado o tópico de modelagem em Ecologia de Paisagens na Seção 2.2, uma vez que conecta-se com SMA por meio de modelos baseados em agentes. Por fim, na Seção 2.3 são apresentados conceitos importantes em TJ e TJE.

2.1 Sistema Multiagente

A área de IA possui como um de seus focos principais o entendimento e a representação da cognição humana de forma pragmática, integrando seus conceitos e técnicas a sistemas computacionais para a resolução de problemas diversos [59]. Em conjunção com a área de sistemas distribuídos, destaca-se SMA, que baseia-se em agentes - entidades autônomas inteligentes capazes de realizar ações no ambiente em que se encontram interagindo com outros agentes. SMA é utilizado em diversos tipos de aplicação, de jogos eletrônicos a robôs e simuladores para os mais diversos tipos de modelos em diferentes aplicações reais, como monitoramento, robótica e automação industrial.

O termo agente é comumente utilizado em diversos contextos como sinônimo de entidade atuante em um certo ambiente. Do ponto de vista de SMA, pode-se definir um agente como um elemento computacional que possui: i) autonomia (atua de forma autossuficiente); ii) habilidade social (comunica-se com outras entidades em seu ambiente); iii) reatividade (responde a estímulos ou percepção automaticamente); e iv) proatividade (age orientado a objetivos, reconhecendo oportunidades) [78, 80]. Dessa forma, um agente é uma entidade capaz de realizar ações em um ambiente de forma autogovernada, de acordo com entradas percebidas, comunicando-se com outros indivíduos nesse processo.

No entanto, de acordo com Wooldridge e Jennings (1995) [80], essa definição é considerada fraca, por ser muito generalista e aplicar-se a diversos tipos de artefatos computacionais, tanto de hardware quanto de software. Sob a ótica da definição apresentada, um processo *daemon* em um sistema operacional UNIX pode ser considerado um agente, por exemplo. De acordo com esses autores, um agente seguindo a definição forte possui não apenas as quatro propriedades definidas na noção fraca, mas também apresenta comportamentos e raciocínio comparáveis a de um ser humano. Shoham (1993) [62] define noções

mentalísticas inerentes a um agente, incluindo compreensão, crenças, intenções e obrigações - que podem ir além, incluindo sapiência e emoções no conjunto de capacidades. Essas características que especializam o agente em um ente bem definido são importantes para a área de IA, porque um dos propósitos de IA é o estudo da automatização do pensamento e da ação racional - sendo relevantes na criação de um agente definido pela noção forte.

Ao longo dos últimos anos, diversos pesquisadores das áreas de SMA e IA incluíram mais propriedades que auxiliam a descrição de um agente de forma mais precisa, como mobilidade (mover-se entre diferentes plataformas de uma rede), veracidade (comunicar-se e transmitir informações de forma idônea), benevolência (agir sempre coerentemente e produtivamente, e nunca deliberadamente ineficiente) e racionalidade (executar suas ações de forma a atingir seus objetivos) [78]. Tendo em vista essa grande quantidade de propriedades inerentes a agentes, para Programação Orientada a Agentes, subárea de SMA, é importante descrever um agente para melhor defini-lo - compreender seu propósito e designar suas funcionalidades.

Sistemas Intencionais e Raciocínio Prático

Wooldridge e Jennings [79], em seu levantamento sobre teorias, arquiteturas e linguagens de agentes afirmam que a atividade humana estabelece uma relação de intenção e causalidade. A Figura 2.1 ilustra essa relação através de arquiteturas de SMA conforme apresentado por Braubach e Pokahr (2009) [55]. Nessa Figura, diversas disciplinas que lidam com o conhecimento do indivíduo e de suas relações com a sociedade deram origem a teorias sobre o raciocínio humano. Essas teorias, por sua vez, foram utilizadas como base para modelos mentalísticos de *frameworks* e ferramentas de simulação da mente humana. Seja por meio da divisão inteligente de tarefas complexas em tarefas simples e compartilhadas (*TaskModel*) ou pela programação orientada por aspectos (*AOP Interpreter*), essas ferramentas possuem embasamento teórico em disciplinas das humanidades para o alcance do propósito que se dispõem.

Dentro desse contexto, Daniel Dennett, filósofo estadunidense, propôs que fatos internos e externos percebidos e tomados como verdadeiros são levados em consideração para a escolha da próxima ação a ser tomada, tendo em consideração uma situação que se almeja alcançar [22]. Por exemplo, se percebemos que o dia está nublado (percepção de fato externo tomado como verdadeiro), levamos um guarda-chuva conosco ao sair para trabalhar (ação) para não nos molharmos no trajeto (situação que se deseja alcançar). Dennett então propõe estratégias de predição de ações baseada em três posturas [22], a saber:

1. Postura física - ações podem ser preditas com base em leis naturais da física, química e biologia. Por exemplo, se uma bola em cima de uma mesa é rolada, é possível prever que sua próxima ação será cair por causa das leis de atração gravitacional;
2. Postura de formação ou projeto - ações podem ser preditas pela definição ou pelo propósito do objeto em si. Se o pedal do freio de um carro em movimento é ativado, então é possível prever que o carro irá frear;
3. Postura intencional - ações podem ser preditas pelas capacidades, pelas intenções dos agentes e pelos fatos que são conhecidos e considerados verdadeiros. Um carro

inteligente tem a intenção de partir da cidade A e chegar na cidade B. Considerando que os passageiros sentados com o cinto de segurança afivelado e que há combustível suficiente, pode-se prever que a próxima ação a ser tomada pelo carro é mover-se.

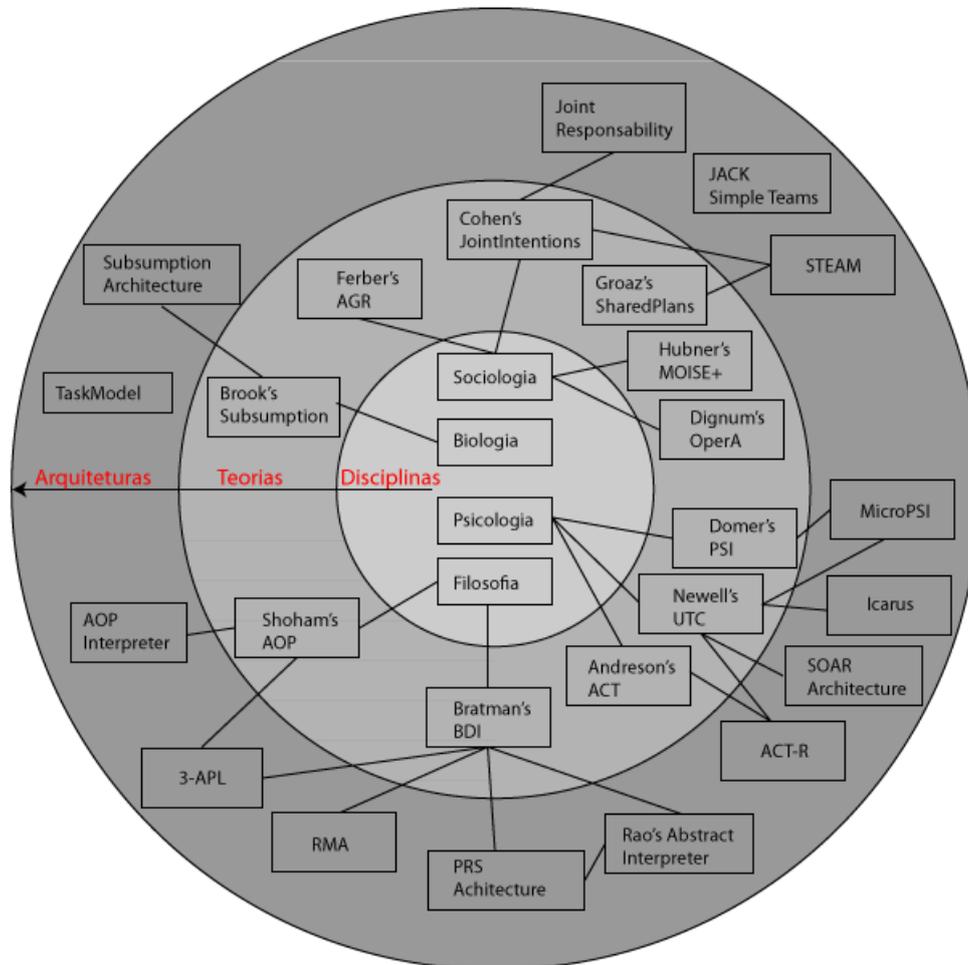


Figura 2.1: Várias arquiteturas propostas para SMA. Fonte: Pokahr e Braubach (2009) [55]. Traduzido pelo autor.

Sistemas intencionais são aqueles compostos por uma ou mais entidades cujas ações podem ser preditas pela composição de suas posturas intencionais [8], podendo possuir duas ordens [22]:

1. Primeira ordem - as entidades possuem crenças sobre o ambiente em que se inserem e desejos internos, e com base neles as ações podem ser preditas pelas intenções; e
2. Segunda ordem - além de possuir as características de um sistema de primeira ordem, possui desejos e crenças a respeito de sua própria definição e de outras entidades do sistema, podendo inclusive ter intenções de segunda ordem.

Sistemas intencionais de segunda ordem são mais complexos e possuem um nível de alcance maior sobre o sistema, uma vez que suas possibilidades não se limitam aos desejos

internos, crenças e percepções do ambiente. Entidades capazes desse alcance podem controlar outras entidades, além de possuir maior controle de si mesmas, aumentando seu domínio e aplicabilidade sobre problemas mais complexos.

O conceito de raciocínio prático se baseia nos sistemas intencionais de primeira e segunda ordem [8]. Raciocínio prático é definido por processos deliberativos objetivados a ações. O processo cognitivo prático pode ser subdividido em duas etapas[78]: i) deliberação, em que a entidade analisa que crenças são verdadeiras e escolhe qual é o objetivo mais adequado a ser cumprido no momento e; ii) raciocínio meio-fim, em que a entidade adota o conjunto de ações necessário para cumprir o objetivo a ser alcançado. Tais etapas são acessadas novamente no caso no cumprimento ou da falha do objetivo atual, compondo o ciclo de execução do agente cognitivo prático.

O modelo BDI é uma implementação de raciocínio prático que é a mais conhecida e aplicada em agentes inteligentes [30]. Ela teve origem em estudos da Filosofia, sendo primeiramente apresentado por Michael Bratman em 1987 [9]. A implementação inclui características próprias além das definidas para o conceito de raciocínio prático. Uma delas é o conjunto de desejos afins, o qual é composto em objetivo (desejo - *desire*), ligado ao conjunto de ações tomadas (intenções - *intentions*), direcionado ao alcance desse objetivo. Ações são sujeitas a possibilidade de que fatos interiores e exteriores serem verdadeiros (crenças - *beliefs*), já que eles podem permitir ou não que elas sejam executáveis.

Resumidamente, um agente cuja cognição é baseada em raciocínio prático BDI possui crenças, desejos e intenções que guiam o processo de deliberação e de raciocínio meio-fim para a decisão da próxima ação a ser executada. Após uma ação ser executada, é averiguado se o objetivo foi alcançado ou se ele falhou. Além disso, as crenças a respeito dos fatos internos e externos são atualizadas. O processo de deliberação e raciocínio meio-fim se reinicia, compondo a execução autônoma do agente.

Crenças, objetivos e ações afins podem ser agrupadas em capacidades. Por exemplo, se um agente possui vários objetivos definidos, ações distintas para alcançá-las e crenças ligadas a essas outras características, elas podem ser agrupadas numa capacidade própria. Isso torna agentes mais modularizáveis e flexíveis, de acordo com a necessidade de uso na composição de MBA [9].

Dois tipos de modelos de agentes cognitivos com aplicabilidade em problemas de mundo real no contexto de SMA são os de aprendizado por reforço e aprendizado por reforço profundo [27]. Apesar destes modelos de aprendizado de máquina não serem o foco deste projeto, é interessante notar que há trabalhos que utilizam conceitos de TJ em conjunção a essas técnicas dentro do tópico de SMA [51]. Essa conjunção é relevante em tomadas de decisão dinâmicas baseadas em processos sem treinamento prévio, como em projetos que envolvam controle distribuído, controle de semáforos, robótica, telecomunicações, leilões, economia, operações no mercado de ações, aplicação de métodos de otimização para problemas reais, dentre outros exemplos [27, 51, 76]. O modelo de aprendizado por reforço, de forma intuitiva é dado por meio de prêmios e punições dos agentes ao interagir com o meio em que se encontram. Esses resultados motivam ou desmotivam os agentes a praticarem certos comportamentos convergindo gradativamente à prática de comportamentos adequados. Tais propriedades podem ser entendidas do ponto de vista de TJ e TJE como a evolução dos indivíduos por meio de resultado de situações estratégicas, em ambientes com múltiplos agentes, onde as punições e prêmios são resultados das interações [27]. Por esse motivo, TJ e TJE oferecem oportunidades de criação de

modelos em aprendizado de máquina para o treinamento de comportamentos inteligentes dos agentes em ambientes dinâmicos.

2.2 Ecologia de Paisagem: Modelagem e Simulação

Modelagem e simulação são aplicáveis a uma variedade de disciplinas biológicas, sociais e exatas, sendo utilizados para desenvolver hipóteses, realizar testes empíricos, prever fenômenos meteorológicos, produzir massas de dados para IA, dentre outros propósitos. Tendo esse contexto em vista, modelagem é particularmente importante para o estabelecimento do estudo em Ecologia de Paisagem e consequentemente de LUC. Isso porque modelagem é entendida como componente essencial para o alcance de seus objetivos [72]. Tais objetivos são, mas não se limitam a: aperfeiçoar o entendimento das dinâmicas de uso e ocupação da terra; a desenvolver empiricamente diagnósticos precoces com base em imagens de satélite e monitoramento; e o desenvolver testes e previsões de consequências de políticas com base em descobertas realizadas, dentre outros.

Por esse motivo a adoção de modelagem nessa área não é apenas ligada à representação de cenários ambientais transversalmente, mas também ao estudo de processos sociais e ecológicos correlatos. Modelagem também pode ser vinculada a métodos de análise de sensibilidade e ajuste de parâmetros, entre outros processos [10]. Isso se justifica porque conceito de causalidade é muitas vezes o objetivo da investigação promovida por trabalhos de modelagem, incluindo a delimitação das causas aproximadas ou finais de processos de uso e cobertura do solo [48]. O uso de técnicas combinadas com modelagem não é incomum, como o uso de metamodelos ou submodelos, integração de dados estatísticos e inteligência adaptativa dos atores no modelo, por exemplo.

Verburg et al. (2006) [74] realizam uma classificação de diversas características comumente encontradas em modelos em LUC com o objetivo de destacar atributos que distinguem um modelo de outro. A classificação dos modelos de forma resumida é listada a seguir:

- Espacial/Não-espacial: Se o modelo apresenta a representação do espaço e seus atributos, como relevo, solo, hidrografia, como ponto importante para a observação de um fenômeno, então ele é espacialmente explícito; Se ele não apresenta representação do espaço ou o foco da modelagem é em processos de transformação do espaço sem características que distinguem o espaço em si, então ele é não-espacial;
- Dinâmico/Estático: Modelos que incluem a mudança de características de forma dinâmica ao longo do tempo, como a evolução populacional de indivíduos ao longo de um intervalo do tempo, são considerados dinâmicos; em contraponto, modelos que utilizam de regressão linear para a predição de fenômenos com base em dados obtidos de observações de um cenário podem ser considerados estáticos;
- Descritivo/Prescritivo: Um modelo que é simulado em busca dos resultados gerados a partir de regras e padrões pré-estabelecidos é descritivo - normalmente, modelos que tomam premissas observadas para a predição de cenários em futuros próximos possuem essa descrição. Por outro lado, modelos que possuem parâmetros que são ajustados com o propósito de se atingir um cenário pré-determinado é classificado como prescritivo;

- Dedutivo/Indutivo: De forma similar a modelos matemáticos, modelos dedutivos são aqueles em que se prevê um padrão a partir dos dados gerados pelo processo descrito no modelo; por outro lado e de forma mais comum, modelos indutivos possuem padrões percebidos na natureza e na sociedade, e seus resultados são analisados e correlacionados com relações ou características encontradas na vida real;
- Baseados em Agentes/Baseados em autômatos celulares: Apesar dessas não serem as únicas abordagens possíveis, elas englobam grande parte dos modelos em LUCC quanto a representação de atores causadores de transformações. Nos Modelos Baseados em Agentes, entidades equivalentes às abordadas na Seção 2.1 são normalmente configuradas para representar diferentes tipos de força antrópica; em autômatos celulares, *pixels* de imagens representativas do cenário real possuem regras e gatilhos com condições para mudarem de estado.
- Global/Regional: De forma simples, modelos globais não apenas podem considerar uma área de extensão de terra muito grande, mas investigar processos que afetam grandes extensões do meio ambiente de uma forma mais generalista. Por outro lado, modelos que se preocupam em delimitar um processo a uma realidade mais contida em um local característico são considerados regionais.

O trabalho de classificação de Verburg et al. (2006) [74] é realizado não apenas para explorar as diversas abordagens possíveis em LUCC, mas também para mostrar como os modelos possuem domínios e pontos fortes distintos entre si, justificando porque é difícil responder questionamentos como “qual é o melhor modelo?”. Na prática, a questão não é qual é o melhor modelo, mas sim qual é o domínio do modelo proposto, e quais os argumentos que dão solidez às características implementadas para a representação do processo em LUCC estudado.

Uma vez que este trabalho está interessado em evidenciar os impactos das interações entre agentes sobre a paisagem, os modelos sob o domínio desta pesquisa são os espaciais, dinâmicos, descritivos e baseados em agentes. Quanto à classificação de global ou regional, a princípio para esta proposta ambos domínios são válidos. No entanto, o modelo utilizado para a validação é regional, como será apresentado na Seção 5.1.

A sociedade possui um papel de grande relevância na transformação do meio ambiente, uma vez que atividades socioeconômicas e as influências políticas podem determinar o tipo de atividade desenvolvida no espaço, conseqüentemente influenciando na dinâmica da transformação da terra. Sendo assim, é natural associar à modelagem o estudo de relações sociais, econômicas e gestoras de uma sociedade com o ambiente em que está inserido. Isso justifica o grande volume de trabalhos nesta área que utilizam MBA para o apoio dos processos descritos e investigados [53, 64]. MBA são particularmente interessantes porque oferecem grande potencial para a utilização de novas abordagens em LUCC para a representação do comportamento humano. Como já citado na Seção 2.1, diferentes disciplinas que estudam o humano e a sociedade foram base para a criação de teorias e ferramentas para o uso de raciocínio antrópico em diversos contextos.

Um aspecto interessante de MBA que já foi mencionado na Seção 1.2 é a emergência de propriedades derivadas da interação de agentes em cenários de simulação. A comunicação, a movimentação e as capacidades cognitivas dos agentes são, em grande parte, responsáveis por essa emergência [36, 78]. Adicionalmente, a maior possibilidade da representação de

sistemas complexos por meio de MBA também contribui para o surgimento de fenômenos emergentes e a compreensão de processos adjacentes ao estudado pelo modelo [20, 45].

De Marchi e Page (2014) [20] concordam com Verburg et al. (2006) [74] que diferentes tipos e classificações de modelos não respondem o questionamento "qual o melhor modelo?"- em vez disso, proporcionam diferentes domínios para diferentes problemas. Nesse sentido, De Marchi e Page (2014) [20] comparam MBA com modelos matemáticos e mostram como eles não anulam um ao outro - eles na realidade se complementam. MBA possuem uma certa liberdade em não priorizar dados analíticos com a precisão que modelos matemáticos exigem. Fica facultado ao criador do modelo utilizar parâmetros arbitrários ou precisos, contanto que de forma consciente em MBA, uma vez que o propósito do modelo pode envolver a caracterização empírica de um fenômeno - aspecto que é explorado com profundidade por Janssen e Ostrom em seu artigo "*Empirically Based, Agent-based models* em 2006 [45]". Sob outra perspectiva, ABM beneficiam-se de modelos matemáticos bem estabelecidos em métodos estatísticos para processos de V&V. Adicionalmente, a implementação de MBA com aspectos de modelos matemáticos, como por exemplo estudos que envolvam compra e venda de criptomoedas, beneficiam-se do ambiente computacional para fácil integração entre seus requisitos [20].

2.3 Teoria de Jogos

TJ é uma área da Economia que estuda as interações entre agentes que possuem interesses próprios e que suas ações podem influenciar no ganho uns dos outros [77]. Diferentemente de SMA, os agentes estudados por TJ não são necessariamente computacionais. No entanto, os agentes em TJ são considerados racionais, e estão sempre interessados na otimização do seu ganho pessoal.

Jogos, em TJ, são situações estratégicas em que dois ou mais agentes (denominados jogadores) tomam decisões sobre sua próxima ação considerando a ação do seu oponente e o aumento de seus ganhos. A otimização do ganho de um jogador não é necessariamente a piora da condição do outro, apesar de suas escolhas serem interdependentes. Os jogadores podem possuir interesses alinhados, em um jogo que todos ganham, ou podem possuir objetivos discrepantes, em que um dos lados ganha mais que o outro, ou qualquer condição entre esses dois cenários.

A utilidade de um jogador, também denominado como *payoff* ou ganho, é um conceito similar ao conceito de utilidade de um agente racional orientado a utilidade. O *payoff* representa o bem-estar, satisfação ou felicidade do jogador de forma abstrata de acordo com o estado em que se encontra. A função utilidade u_i de um jogador i é uma função definida como $u(x) \rightarrow \mathbb{R}$, em que x é o estado em que o jogador se encontra, e $u(x)$ é o valor quantitativo de sua utilidade.

2.3.1 Estratégias Puras e Mistas

Em TJ, o conceito de estratégia diz respeito às opções de ações disponíveis pelo agente em face a um jogo, enquanto o conceito de *payoff* diz respeito ao resultado das estratégias combinadas dos jogadores. Agentes racionais, buscando o melhor lucro ou o menor prejuízo possível, devem escolher a ação considerando tanto o melhor resultado para si

quanto qual seria o melhor resultado que o oponente escolheria para si, uma vez que sua escolha pode não ser suficiente para a determinação dos resultados.

No entanto, casos em que o agente encontra uma ação que produz os melhores resultados independentemente da ação do oponente, denomina-se estratégia pura. Por exemplo, considera-se uma situação em que dois amigos, Newton e Leibniz, decidem se reunir para estudar para uma prova de Cálculo. Ambos podem escolher entre esforçar-se para se concentrar em seus estudos ou distrair-se com outras atividades, como sair para passear. Cada um deles prestou atenção em partes da matéria, então se ambos se esforçarem em conjunto eles poderão tirar uma boa nota, como 9. Se um deles se esforçar e outro se distrair, apenas o que se esforçou irá tirar uma boa nota, mas não tão boa quanto a do esforço em conjunto, como 4, enquanto o amigo distraído obterá zero. Se ambos se distraírem, ambos obterão zero.

A forma normal do jogo pode ser observada na Tabela 2.1. Analisando a perspectiva do jogador Newton, se ele decidir esforçar-se e Leibniz decidir distrair-se, Newton obtém 4 e Leibniz 0. Se Newton resolver distrair-se e Leibniz também, ambos obtém 0. Nesse caso, é melhor Newton decidir por esforçar-se, pois seu *payoff* será maior. Em uma segunda situação, se Newton decidir esforçar-se e Leibniz também, ambos obtém 9. Caso Newton acabe distraindo-se e Leibniz esforçando-se, Newton obtém 0 e Leibniz 4. Nessa situação, também é melhor que Newton escolha por esforçar-se, pois o *payoff* é melhor que distrair-se. Sendo assim, para Newton, a estratégia $S = \{esforçar - se\}$ é uma estratégia pura, pois ela sempre oferece o melhor *payoff* possível considerando a escolha de Leibniz.

No entanto, nem todos os jogos possuem estratégias que sempre obtém o melhor *payoff*, caso o jogador permaneça executando o mesmo conjunto de ações. Um jogo clássico em TJ é o de *Matching Pennies* (Tabela 2.2). Nesse jogo, os jogadores α e β possuem cada um uma moeda não viciada, ambos escolhem por mostrar para o adversário a cara ou a coroa de sua moeda. Caso as moedas dos jogadores estiverem mostrando o mesmo lado (cara e cara OU coroa e coroa), o jogador α ganha o jogo, e leva a moeda do jogador β . Caso ambas moedas estejam mostrando lados diferentes (cara e coroa OU coroa e cara), o jogador β ganha o jogo, e pode pegar a moeda do jogador α para si. Intuitivamente, para qualquer um dos jogadores permanecer fixo em uma única estratégia não é uma boa ideia. Uma melhor movimentação seria adotar cada uma delas alternadamente ou aleatoriamente. Nesse caso, os jogadores deveriam escolher ações determinadas aleatoriamente por uma distribuição probabilística para tentar aumentar suas chances de lucro, e por consequência suas utilidades. A esse tipo de estratégia denomina-se estratégia mista.

Tabela 2.1: Jogo em que dois amigos decidem estudar juntos. O *payoff* do jogo é a nota que cada um irá obter dependendo de suas ações.

		Newton	
		<i>Distrair - se</i>	<i>Esforçar - se</i>
Leibniz	<i>Distrair - se</i>	(0, 0)	(0, 4)
	<i>Esforçar - se</i>	(4, 0)	(9, 9)

O jogo de *Matching Pennies* (Tabela 2.2) denomina-se jogo de soma zero (*zero-sum*, uma vez que as utilidades dos jogadores sempre se anulam quando adicionadas uma a outra. Isso significa que eles estão sempre em conflito direto, onde o lucro de um implica no prejuízo do outro em qualquer cenário. Desta forma, não existe uma situação que

ambos jogadores se beneficiam de suas estratégias simultaneamente. Na seção a seguir, será verificado que não existe equilíbrio no jogo de *Matching Pennies*.

Tabela 2.2: Jogo em que ambos jogadores lançam cada um uma moeda e verificam as faces obtidas. Se ambas faces forem iguais, o Jogador α ganha. Caso contrário, o Jogador β ganha. Em qualquer situação, o ganhador toma a moeda do perdedor.

		Jogador β	
		<i>Cara</i>	<i>Coroa</i>
Jogador α	<i>Cara</i>	(1, -1)	(-1, 1)
	<i>Coroa</i>	(-1, 1)	(1, -1)

Estratégias Pareto-Eficientes, Melhor Resposta e Equilíbrio de Nash

Tendo em vista que agentes em TJ buscam melhorar suas utilidades e que suas ações em conjunto influenciam no aumento de seus ganhos, torna-se óbvio que para cada agente algumas ações são preferidas em suas deliberações sobre qual estratégia escolher em um jogo. Define-se um perfil estratégico como uma combinação de todas as estratégias dos jogadores de um jogo. Alguns perfis estratégicos são mais lucrativos que outros, sendo preferidos pelos jogadores.

Considerando-se os perfis estratégicos $S_0, S_1, S_2 \dots S_n$, é dito que o perfil S_p domina S_q se [31]:

$$\forall i \in N, u_i(p) \geq u_i(q), e \quad (2.1)$$

$$\exists j \in N | u_j(p) > u_j(q). \quad (2.2)$$

Denomina-se essa definição como Dominância de Pareto ou Pareto-Dominância, a qual evidencia que mesmo que as ações dos jogadores possuam ganhos interdependentes, é possível que um jogador mude de uma estratégia para outra com melhoria ou equivalência de utilidade sem que outro jogador perca utilidade essa mudança. A Dominância de Pareto se aplica a perfis estratégicos em que a utilidade de cada agente em um perfil pareto-dominante é melhor ou igual a de outro perfil pareto-dominado [31].

Com base no conceito de dominância de Pareto, é possível definir um perfil estratégico pareto-eficiente como o seguinte: o perfil estratégico S_x é pareto-eficiente se não existe perfil estratégico S_y tal que S_y pareto-domina S_x . Um perfil estratégico pareto-eficiente é aquele em que nenhum agente poderia mudar de estratégia sem que outro sofresse perdas em um jogo específico, ou seja, cada jogador já está em um situação em que suas estratégias já trazem o melhor *payoff* para todos [31].

Analisando-se individualmente as estratégias de cada jogador, encontra-se outro conceito importante em TJ – melhor resposta. Admitindo-se que o agente não sabe qual será a estratégia de outros agentes no jogo que ele está participando, ele ainda assim precisa escolher uma estratégia que traga o melhor *payoff* para si. Sejam a_i e a_{*i} estratégias do jogador i , A_i o conjunto de todas as estratégias de i e a_{-i} as estratégias escolhidas por todos outros jogadores menos o jogador i . Considera-se a notação $u(a_i, a_{-i})$ equivalente

ao *payoff* do jogador i quando ele escolhe a estratégia a_i e os outros jogadores escolhem a_{-i} . Define-se a melhor resposta (MR) conforme a Equação 2.3 [31]:

$$a^*_i \in MR(a_{-i}) \iff \forall a_i \in A_i, u(a^*_i, a_{-i}) \geq u(a_i, a_{-i}). \quad (2.3)$$

A Equação 2.3 mostra que o jogador está usando uma estratégia que é a melhor resposta, se a utilidade dela é maior ou igual do que se ele estivesse utilizando outra estratégia qualquer, tendo em vista as estratégias escolhidas pelos outros jogadores. Essa definição permite a construção de outro conceito chave em TJ – Equilíbrio de Nash. Trata-se da situação estratégica em que nenhum jogador é motivado a mudar sua estratégia, uma vez que todos tentam dar boas respostas às estratégias dos outros, e uma situação de equilíbrio é atingida. Há jogos onde não há Equilíbrio de Nash e jogos em que há mais de um. Sua definição inicia a partir de um jogo J qualquer, tal que:

$$J = (N, A_{i,i \in N}, u_{i,i \in N}), \quad (2.4)$$

onde N são os jogadores, A_i é o perfil de ações e u_i com $i \in N$ são as utilidades. Seja $S = a^*_{i,i \in N}$ um perfil estratégico, S é um equilíbrio de Nash se:

$$\forall i \in N, \forall a'_i \in A_i, u_i(a^*) \geq u_i(a'_i, a'_{-i}). \quad (2.5)$$

Combinando as Equações 2.3 e 2.5, pode-se reescrever a definição do Equilíbrio de Nash como $A = (a_1, a_2, \dots, a_n)$ é um Equilíbrio de Nash $\iff \forall i \in N, a_i \in MR(a_{-i})$ [31].

2.3.2 Jogos Evolucionários

TJ se apresenta como uma poderosa ferramenta de análise matemática na investigação do equilíbrio de cenários estratégicos, no entanto, pode não ser suficiente em todas as situações de interação entre dois ou mais indivíduos. De fato, as interações entre indivíduos de uma população podem ser determinantes para as suas sobrevivências e crescimentos, e não necessariamente refletem os perfis estratégicos mais racionais possíveis. Comportamentos como o cuidado parental observado em mamíferos e aves, bem como o agrupamento de lobos em matilhas podem ter sido fruto da evolução, sendo cruciais para a manutenção de espécies. Sendo assim, o surgimento da TJE, introduzida originalmente em 1973 por Smith e Price, leva em consideração princípios pertinentes à Ecologia e Evolução Darwiniana, disponibilizando um novo conjunto de análises para jogos voltados a situações estratégicas entre populações [77].

A ideia chave em TJE é que estratégias adotadas pelos jogadores podem não refletir a estratégia mais racional possível, uma vez que elas refletem o comportamento determinado por fenótipos e genótipos das espécies, mas a longo prazo permitem a difusão e o sucesso de determinados comportamentos observados nas populações. A dispensabilidade da racionalidade nos jogadores em TJ seria a diferença primária de TJ clássico, em que os agentes adotam estratégias para melhorar suas utilidades racionalmente. Além disso, os jogos em TJE são dinâmicos e interativos, em que o conceito de utilidade dos jogadores pode ser adaptado para conceitos de adaptabilidade, aptidão ou *fitness* – quanto melhor o *payoff* de um jogador como resultado de um jogo, mais adaptada seria a sua estratégia para aquele cenário competitivo. Consequentemente, também é foco de TJE o

estudo e a dinâmica da variação do tamanho das populações e das trocas de estratégia dos indivíduos.

Um dos jogos propostos por Maynard e Prince para melhor explicitar TJE é o *Hawk-Dove* (Gavião-Pombo). Ainda hoje, tal jogo é utilizado como modelo de interação em diversas áreas, inclusive não relacionadas à Ecologia, como por exemplo, comércio eletrônico [46]. Nesse jogo, encontra-se indivíduos competindo por um recurso V e que possuem duas estratégias - *Hawk* e *Dove*. Os indivíduos que adotam a estratégia *Hawk* comportam-se de forma bélica e recorrem à violência para tentar obter o recurso em questão. Os indivíduos *Dove* são pacifistas e procuram fugir de situações de conflitos na obtenção do recurso. Quando dois indivíduos *Hawk* encontram-se, eles brigam pelo recurso, e metade das vezes um dos dois o obtém. Não obstante, ambos nesse tipo de situação de conflito pagam conjuntamente um custo C , relativo ao prejuízo da disputa por V . Por outro lado, quando indivíduos *Dove* encontram-se, eles dividem igualmente o recurso V de forma pacífica. Na situação que o indivíduo *Hawk* encontra um indivíduo *Dove*, o segundo foge do conflito, deixando de receber qualquer recompensa, enquanto o primeiro indivíduo obtém o recurso V inteiramente [66]. A representação desse jogo pode ser visualizada na Tabela 2.3.

Tabela 2.3: O Jogo *Hawk-Dove* proposto por Maynard e Price em 1973 [77].

		Jogador β	
		<i>Hawk</i>	<i>Dove</i>
Jogador α	<i>Hawk</i>	$((V - C)/2, (V - C)/2)$	$(V, 0)$
	<i>Dove</i>	$(0, V)$	$(V/2, V/2)$

Estratégias Evolucionárias Estáveis

É de grande interesse para TJE determinar estratégias que se mantêm estáveis mesmo com alguma perturbação externa, como por exemplo a mutação ou imigração de indivíduos. Considera-se um cenário em que grande parte dos indivíduos adota uma estratégia S_0 e que uma quantidade de mutantes invasores com frequência $p \mid p \ll 1$ adotam a estratégia S_1 distinta, mas não são capazes de perturbar esse equilíbrio, e acaba morrendo ou trocando de estratégia. Desta forma, a estratégia S_0 denomina-se Estratégia Evolucionária Estável - ou *Evolutionary Stable Strategy* (ESS).

ESS foi proposta por Maynard e Price em 1973 [65]. Essa estratégia baseia-se em variáveis como população inicial de indivíduos de estratégias distintas e de suas respectivas adaptabilidades. A adaptabilidade e o *payoff* possuem relação direta como resultado das interações entre o indivíduo em si com outros organismos, que podem estar jogando a mesma estratégia ou não. Sendo assim, o cálculo da adaptabilidade envolve a distribuição de probabilidade do organismo estar jogando uma estratégia específica e conseqüentemente influencia na evolução da população inicial ao longo do tempo.

David et al. [17] demonstra como pode acontecer ocorrência de um grupo invasor em uma população que adota uma ESS por meio do jogo simétrico genérico descrito na Tabela 2.4. Além disso, os autores apresentam quais são as condições para que a ESS permaneça estável mesmo com a invasão. Os jogadores podem adotar a estratégia S ou a T , e os *payoffs* possíveis são:

- se o jogador de estratégia S encontra outro com estratégia igual, ambos recebem a ;
- se o jogador de estratégia T encontra outro com estratégia igual, ambos recebem d ;
- se o jogador de estratégia S encontra um de estratégia T , o primeiro recebe b e o segundo c .

Considera-se que uma fração x positiva da população começa o jogo com a estratégia T , enquanto a fração restante $1 - x$ dos indivíduos utiliza S . Nesse caso, admite-se que S é uma ESS e que T é a estratégia dos indivíduos invasores, uma vez que eles representam um grupo pequeno em face a uma população, também é admitido que $x \ll 1 - x$.

Tabela 2.4: Um exemplo de jogo genérico em TJE (adaptado de [17]).

		Jogador β	
		S	T
Jogador α	S	(a, a)	(b, c)
	T	(c, b)	(d, d)

Para se analisar o *payoff* esperado desse jogo, considera-se primeiramente a possibilidade de um indivíduo i_S (ou seja, que adota S como estratégia) encontrar outros indivíduos da população. A chance de i_S encontrar outro indivíduo que joga S é $(1 - x)$, e o *payoff* desse encontro é a . A possibilidade de i_S encontrar um indivíduo que joga T é de x , e seu *payoff* seria b . Dessa forma, o *payoff* esperado p_S do indivíduo i_S é representado pela Equação 2.6 [47].

$$p_S = a(1 - x) + bx. \quad (2.6)$$

Utilizando-se desse raciocínio de forma similar, um indivíduo i_T que joga a estratégia T teria como *payoff* esperado p_T conforme mostrado na Equação 2.7 [47].

$$p_T = c(1 - x) + dx. \quad (2.7)$$

No entanto, se a estratégia S é ESS, seu *payoff* ou adaptabilidade deve ser maior que o adaptabilidade de outras estratégias conforme apresentado na Inequação 2.8.

$$p_S > p_T. \quad (2.8)$$

Substituindo-se as Equações 2.6 e 2.7 na Inequação 2.8, a Inequação 2.9 deve ser mantida.

$$a(1 - x) + bx > c(1 - x) + dx. \quad (2.9)$$

Como $x \ll (1 - x)$, ao menos uma das condições a seguir deve ser satisfeita para que a estratégia S seja de fato considerada ESS:

- $a > c$, ou seja, o *payoff* do um indivíduo que joga a estratégia S e encontra com outro que joga a mesma estratégia deve ser maior que o *payoff* do indivíduo que joga a estratégia T e encontra um indivíduo que joga a estratégia S ; ou

- $a = c$ e $b > d$. Em outras palavras, os *payoffs* do item anterior podem ser equivalentes, porém o *payoff* do indivíduo que joga S e encontra um indivíduo que joga T deve ser maior que os *payoffs* do encontro de indivíduos que jogam T .

Resumidamente, a Inequação 2.9 mostra que a população invasora não deve possuir uma estratégia que possua adaptabilidade maior que a da população supostamente estável. Caso contrário, os invasores poderão estar melhor adaptados ao cenário em que a população geral se encontra, e assim, tenderão a crescer e desestabilizar o equilíbrio. Caso tanto a população invasora seja tão bem adaptada quanto a supostamente estável, ou seja, ambas adaptabilidades possuam o mesmo valor, a população local deve possuir melhor valor de adaptação quando encontrar um invasor do que quando um invasor encontra outro invasor [47].

Note que $a > c$ na Inequação 2.9 implica em um Equilíbrio de Nash, uma vez que os indivíduos S não teriam motivações para trocar de estratégia em face às estratégias de outros indivíduos da população, independentemente de suas estratégias. Se $a = c$, não há garantia que S é a única melhor resposta do jogo, mas a situação ainda é um ESS, uma vez que os indivíduos de estratégia S possuem melhor *payoff* contra indivíduos da estratégia T que indivíduos da estratégia T mutuamente [47].

Replicação Populacional

O estudo de estratégias estáveis em TJE é tão importante quanto a compreensão da dinâmica de variação populacional. Deseja-se conhecer o progresso societal de um conjunto de indivíduos com base na adaptação, nas estratégias e na frequência de tipos de indivíduos na população dos jogos evolucionários. Para isso, utilizam-se Equações de Replicação Evolucionária que ajudam a explicar e a trazer *insights* a respeito desses processos. Elas auxiliam na análise de problemas sobre crescimento populacional e trocas de estratégia, por exemplo.

Considera-se novamente o jogo simétrico apresentado na Tabela 2.4. Nele há duas estratégias, S e T , com seus respectivos *payoffs*. Admite-se as seguintes notações, considerando α e β possíveis estratégias:

- w_α é a adaptabilidade esperada da população de estratégia α ;
- x_α é a proporção de indivíduos da população de estratégia α , com $x_\alpha \geq 0$;
- N_α é a quantidade de indivíduos que utiliza α ;
- $W_{\alpha,0}$ é a adaptabilidade inicial da população α ;
- $\Delta w(\alpha, \beta)$ é a variação na adaptabilidade de um indivíduo s_α por um indivíduo s_β .

A seguir, são listadas as Equações 2.10, 2.11 e 2.12 na determinação da adaptabilidade esperada das populações estratégicas [47]:

$$w_S = W_{S,0} + x_S \Delta w(S, S) + x_T \Delta w(S, T), \quad (2.10)$$

$$w_T = W_{T,0} + x_T \Delta w(T, T) + x_S \Delta w(T, S), \quad (2.11)$$

$$\bar{w} = x_S w_S + x_T w_T. \quad (2.12)$$

As Equações 2.10 e 2.11 relacionam a adaptabilidade esperada de cada estratégia com base na adaptabilidade inicial e nos encontros dos indivíduos com outros multiplicado pelo *payoff* da interação. A Equação 2.12 mostra a adaptabilidade média da população geral. A partir delas, pode-se obter a equação de replicação para a população S conforme Equação 2.13 [38].

$$\dot{x}_S = \frac{x_S(w_S - \bar{w})}{\bar{w}}. \quad (2.13)$$

Em que $\frac{(w_S - \bar{w})}{\bar{w}}$ será a taxa de variação por tempo da proporção da população. De forma geral, a equação de replicação pode ser expressa pela Equação 2.13 [38].

$$\dot{x}_i = x_i[w_i(X) - \bar{w}]. \quad (2.14)$$

Na Equação 2.14, a taxa de crescimento depende tanto da população atual x_i quanto das outras populações $X = (x_1, x_2, \dots, x_n)$, e sobre elas é aplicada a adaptabilidade resultante do encontro da população x_i conforme apresentado na Equação 2.15, onde $w_{i,j}$ é o *payoff* de i na interação com j :

$$w_i = \sum_j x_j w_{i,j}. \quad (2.15)$$

2.3.3 Força do Dilema

Um tópico de grande relevância em trabalhos de TJ e TJE é a presença de dilemas em situações estratégicas e a sua força. Dilemas podem ser definidos como situações em que desviar de uma resposta cooperativa pode ser uma resposta preferível sobre outras [69]. Sendo assim, um dilema pode possuir força ou substância variáveis de acordo com as ações e os *payoffs* disponíveis, apresentando motivações maiores ou menores para que os jogadores desviem ou não de uma resposta cooperativa que beneficie o grupo. Wang et al. (2015) [75] propuseram um conjunto de regras simples para realizar a classificação da força de dilemas, que consiste em tomar como ponto de partida um jogo parametrizado em *payoffs* R, S, T, P , baseado no dilema dos prisioneiros (Tabela 2.5).

Tabela 2.5: A parametrização do dilema dos prisioneiros.

		Jogador β	
		<i>Cooperar</i>	<i>Trair</i>
Jogador α	<i>Cooperar</i>	R	S
	<i>Trair</i>	T	P

Na parametrização da Tabela 2.5, os *payoffs* referem-se ao Jogador α em face ao Jogador β . Se ambos cooperarem, α recebe o prêmio R (**R**eward), caso tivesse cooperado mas β se tivesse traído recebe o "*payoff* do enganado" S (**S**ucker's *payoff*). Se α trair mas β cooperar, α recebe o *payoff* pela tentação T (**T**emptation). Se ambos traírem, α recebe a punição P (**P**unishment). Sendo o dilema dos prisioneiros um jogo simétrico

de dois jogadores e duas estratégias, ele é considerado como um bom arquétipo para a representação da parametrização encontrada em vários outros jogos em TJ e TJE [75].

Tendo os parâmetros definidos, Tanimoto e Sagara (2007) [69] definiram que jogos de dois jogadores e duas estratégias podem ser classificados em intencionados à aposta - *Gamble-Intending Dilemma* (GID) -, ou com aversão ao risco - *Risk-Averting Dilemma* (RAD). O critério de classificação geral é dado por duas variáveis, $D_g = T - R$ e $D_r = P - S$. Se D_g é positivo, o jogo é GID, em que os jogadores são motivados a explorar um ao outro. Se D_r é positivo, o jogo é RAD, onde os agentes tentam afastar-se de situações de exploração. Wang et al. (2015) [75] propõem sub-arquétipos para quantificar as forças de dilemas considerando D_g e D_r , conforme segue:

- Se $D_g > 0$ e $D_r > 0$, o jogo é equivalente ao dilema dos prisioneiros, em que a estratégia equivalente a trair domina fracamente cooperar.
- Se $D_g < 0$ e $D_r < 0$, o jogo não possui dilema, uma vez que os jogadores não possuem motivação para desviar da estratégia equivalente à cooperar, logo cooperar domina trair.
- Se $D_g > 0$ e $D_r < 0$, o jogo equivale ao jogo de *Chicken* ou *Hawk-Dove*, onde existe um equilíbrio assimétrico, em que a punição P é muito alta mas a tentação T é maior que P e o prêmio R .
- Se $D_g < 0$ e $D_r > 0$, o jogo equivale a *Stag Hunt*, onde existe uma estabilidade mútua entre cooperar-cooperar e trair-trair.

Tais classificações de jogo e mensuração de força de dilemas podem ser estendidos para situações em TJE onde os jogadores fazem parte de uma população que disputa recursos para sobrevivência. Dependendo das ações disponíveis e do valor dos recursos obtidos, um dos quatro sub-arquétipos podem ser estabelecidos para oferecer um modelo para o entendimento da evolução da população no cenário.

Neste Capítulo foram vistos os conceitos de SMA, Modelagem e Simulação no contexto de Ecologia de Paisagens e de MBA, que são bastante adjacentes uns aos outros no contexto da proposta deste trabalho. Além disso, diretamente ligados ao problema de conflitos de recursos, conceitos básicos de TJ e TJE foram apresentados como sustentação do modelo de interação. No Capítulo 3 serão apresentados os trabalhos correlatos, os quais desenvolveram estudos e ferramentas no mesmo direcionamento desta pesquisa.

Capítulo 3

Trabalhos Correlatos

Existem diversos trabalhos relacionados a esta pesquisa, seja envolvendo ferramentas de SMA com aspectos de TJ/TJE ou aplicações de MBA em cenários ambientais e LUCC. Neste capítulo serão apresentados alguns trabalhos correlatos adjacentes ao modelo proposto e à ferramenta MASE-EGTI desenvolvidos nesta pesquisa.

3.1 Modelos Espaciais e Ecológicos

Nesta seção são apresentados trabalhos correlatos com modelos em sistemas ambientais utilizando TJ/TJE. Esses trabalhos foram escolhidos por possuírem motivações e direcionamentos adjacentes ao objetivo desta pesquisa. Jogos em Espaços Celulares (Seção 3.1.1) explora o uso de TJE em modelos espaciais, mostrando como o distanciamento entre agentes e sua distribuição por um conjunto de células pode influenciar o equilíbrio final da sociedade. Já o trabalho apresentado na Seção 3.1.2 faz a aplicação de conceitos em TJ em um modelo ambiental de uso da água. Por mais que esse não seja um trabalho em LUCC, ele se encaixa em simulações ambientais e concorrência por recursos, mostrando como o comportamento dos agentes pode trazer consequência para toda a sociedade.

3.1.1 Jogos em Espaços Celulares

Ribeiro et al.(2009) [19] em seu trabalho *Games on Cellular Spaces: How mobility Affects Equilibrium* introduziram um novo paradigma para ABM espacialmente explícitos. Nesse paradigma, agentes possuem capacidade de movimentação por um *grid* de células e jogam estratégias mistas para competir por espaço. O artigo é resultado da tese de Pedro Ribeiro de Andrade, que explorou questões envolvendo modelos espaciais com dados georreferenciados e TJ [18]. Para os autores, tão importante quanto estudar a evolução de espécies pela adaptabilidade em seus comportamentos é entender como a mobilidade dos indivíduos pode afetar relações já bem estabelecidas em TJ e TJE, como o Equilíbrio de Nash em jogos não-cooperativos. A dinamicidade dos jogos que modelam a evolução de agentes em uma sociedade não se resume à replicação populacional, mas também a possibilidade de indivíduos de serem capazes de se mover pelo espaço em que vivem, competindo por recursos com diversificados tipos de oponentes.

Os autores desenvolveram um modelo básico que utilizava o jogo *Chicken Game* (em que $D_g > 0$ e $D_r < 0$, conforme ilustrado na Seção 2.3.3) para fins de experimentação. A

partir desse modelo, eles realizaram diferentes configurações iniciais dos agentes quanto à localização, uso de estratégias mistas e puras e satisfação dos agentes, executando simulações com a ferramenta TerraME ([21]). Por meio dessas variações, foi possível perceber que diferentes configurações levavam a configurações espaciais resultantes divergentes do Equilíbrio de Nash esperado em um jogo em que os agentes não possuem mobilidade.

Essa publicação é importante para trabalhos subsequentes na área, incluindo esta pesquisa em particular, uma vez que estabelece um modelo em que recursos espacialmente localizados tem ligação direta com as estratégias utilizadas pelos agentes e consequentemente seus *payoffs* recebidos. Essa publicação se correlaciona a este trabalho por ambas pesquisas relacionarem modelos em TJ e TJE a modelos espacialmente explícitos. Suas principais diferenças são que *Games on Cellular Spaces: How mobility Affects Equilibrium* busca um modelo de amplo uso em sistemas espaciais, enquanto esta pesquisa utiliza regras em TJ e TJE para representar a interação entre os agentes em modelos em LUCC. Além disso, a interação proposta nesta pesquisa busca integrar regras a nível de agente e regras a nível de sociedade por meio de regras entre agentes coexistindo no mesmo espaço.

3.1.2 Irrigação e Depleção de Aquíferos Subterrâneos

Huang et al. (2016) [41] apresentam um SMA para a investigação de depleção de aquíferos subterrâneos em decorrência da irrigação de cultivo de três tipos de grãos: milho, sorgo¹ e trigo. O problema da escassez de água e secagem de rios, lagos e outros elementos hidrográficos tem como uma das fontes o consumo direto de água de nascentes e freios aquáticos subterrâneos. Esse trabalho utiliza TJ para a modelagem de estratégias de agentes irrigadores, o cálculo de suas utilidades acumuladas esperadas e situações onde é possível existir o Equilíbrio de Nash entre os jogadores.

Como prova de conceito é utilizada a região geográfica do aquífero de Ogallala, na cidade de Garden, localizada no sudoeste do estado de Kansas, Estados Unidos. Cinco agentes são posicionados sobre uma grade representativa do espaço, e possuem determinadas áreas que eles devem manter irrigadas. São consideradas características sociais e econômicas no contexto, o custo e o preço das culturas plantadas no espaço, consultado a partir do Serviço de Estatística Agrícola Nacional dos Estados Unidos. O nível de água do aquífero é resultante do uso acumulado dos agentes ao longo do período estudado, somado à variação de precipitação e evaporação ano a ano.

Como objetivo da pesquisa, variaram-se os parâmetros de demanda de grãos pelo mercado, o preço da produção, o custo associado à produção e distribuição dentre outros aspectos socioeconômicos, e verificou-se as utilidades acumuladas sob forma de lucro monetário dos agentes ao longo de 20 anos, bem como o nível de água disponível no aquífero. Averiguou-se que determinadas culturas, como a de milho, eram mais rentáveis que a de sorgo, porém necessitavam de mais água. No entanto, a produção exagerada de uma cultura determinava a diminuição nos preços, motivando os agentes a trocarem de estratégia e cultivarem outros tipos de cultura. Padrões de troca de cultura e irrigação confirmaram o declínio da água disponível no aquífero, o que consequentemente diminuía a disponibilidade de água para a irrigação e a diminuição de chuvas.

Em um segundo cenário, foi integrado ao modelo uma política pública que define grupos locais de preservação denominados LEMA (*Local Enhanced Management Areas*). Essa

¹ *Sorghum bicolor*, conhecido também como milho-zaburro

política foi aprovada em 2012 no estado de Kansas com o intuito de melhorar a proteção dos lençóis freáticos e aquíferos, dentre outros aspectos do meio ambiente. Simulações executadas sob esse cenário retornaram resultados muito mais favoráveis à longevidade do Ogallala, porém com diminuição da utilidade acumulada dos agentes em comparação ao experimento anterior.

O trabalho em questão correlaciona-se a este por se tratar do uso de conceitos em TJ e TJE no domínio de modelagem ambiental. Ambos trabalhos possuem diversos pontos de interseção como o estudo de estratégias no uso de recursos naturais entre os agentes, e a influência de estratégias mais ou menos agressivas podem mudar o resultado dos modelos em termos de disponibilidade de fundos ecossistêmicos.

3.2 Ferramentas de Simulação

Nesta seção são apresentadas ferramentas correlatas ao MASE-EGTI orientadas a agentes, destinadas a modelos espacialmente explícitos ou outras ferramentas destinadas à construção de modelos ecológicos e à análise de cenários e resultados. Tais ferramentas correlatas foram escolhidas por serem bastante conhecidas na comunidade científica e por possuírem grande número de trabalhos publicados com seu apoio [35]. Além disso, é possível a implementação de regras baseadas em jogos, tornando assim possível a comparação com a ferramenta que apoiou este trabalho. Por isso, ao final dessa Seção apresenta-se a tabela comparativa 3.1 com as ferramentas listadas e o , destacando as diferenças e similaridades entre as soluções.

3.2.1 Cormas

Cormas² (*COmmon-Pool and Multi-Agent System*) [7], desenvolvido por *French Agricultural Research Center for International Development* (CIRAD), é uma ferramenta baseada em SMA focada em simulação para o manejo de recursos naturais. Cormas utiliza a plataforma *VisualWorks* para o desenvolvimento, execução e depuração de seus modelos, além de possuir uma biblioteca com alguns exemplos de uso de suas classes internas e de outras funcionalidades, como a interface de visualização e o agendador de *steps*. Os agentes do Cormas podem ser classificados em três categorias básicas, a saber:

- Agentes Espaciais: unidades de células decorrentes da divisão do ambiente por uma grade celular. Suas ações são mapeadas a eventos externos e internos fixos, como por exemplo, ocupação física de sua representação por outro agente (evento externo) ou mudança de estado (evento interno).
- Agentes Comunicantes: entidades utilizadas para a comunicação por mensagens entre dois agentes.
- Agentes Espaciais-Comunicantes: a combinação dos dois agentes anteriores, com capacidades adicionais de movimentação pelo espaço.

Modelos são implementados no Cormas pela extensão de suas classes de agentes e outros artefatos, com a determinação de regras de simulação e atualização de estados. Modelos

²<http://cormas.cirad.fr/>

complexos podem ser implementados com o auxílio das funções pré-definidas e com a linguagem de programação *Smalltalk* [32]. Essa ferramenta continua a ser aperfeiçoada, com sua versão mais recente lançada em julho de 2021³.

3.2.2 GAMA

GAMA⁴ [23] é um ambiente de desenvolvimento de modelos espacialmente explícitos para simulações baseadas em agentes. Dentre suas características, destaca-se a possibilidade de integração de dados georreferenciados, interface visual 2D e 3D e a linguagem de programação *GAMA Modeling Language* (GAML), utilizada para a construção de modelos na ferramenta. GAMA não possui o uso restrito a modelos em Ecologia, podendo ser aplicada em diversas áreas em que modelagem espacialmente explícita é adequada, como Ciências Sociais, análise de tráfego e segurança pública. GAMA também destaca-se por possuir solucionador numérico, empregado na resolução de equações diferenciais e outros artefatos matemáticos, o que auxilia a integração de modelos analíticos à modelagem. GAMA possui integração com BDI por meio de *plugin* [3]. Essa ferramenta possui código aberto⁵ e atualmente se encontra na versão 1.8.1⁶ [2].

3.2.3 MASS

MASS⁷ (*Multi-agent Simulation Suite*) [43] é uma suíte de simulação baseada em SMA composta por três módulos construídos sobre um *core* de simulação comum. A motivação para o estabelecimento dessa arquitetura modular é a disponibilização de diversas perspectivas aos usuários para que eles possam implementar de seus modelos de forma flexível e integrada. Os módulos provêm, individualmente: i) visualização da simulação e de gráficos do modelo, por meio do módulo *charting package*; ii) integração com páginas web, para prover interfaces para múltiplos usuários, permitindo a criação de simulações participatórias por meio do módulo *participatory extension* (PET); e iii) interação das variáveis e resultados com o usuário, permitindo o ajuste de parâmetros, cálculo e filtragem de resultados personalizados e outros tipos de projetos avançados que requerem a interação direta do modelador com o código, por meio do módulo *model exploration module* (MEME). MASS também disponibiliza uma linguagem de modelagem própria, denominada *Functional Agent-Based Language for Simulation* (FABLES), otimizada para a ferramenta e capaz de gerar código Java próprio para a execução no core do simulador. Essa ferramenta⁸ não possui modelos de raciocínio ou de interação explicitamente implementados nos módulos, mas por meio da linguagem FABLES é possível construir mecanismos avançados para suprir essa necessidade.

³<http://cormas.cirad.fr/en/outil/outil.htm>

⁴<http://gama-platform.org/>

⁵<https://github.com/gama-platform>

⁶<http://gama-platform.org/download>

⁷<http://mas.cs.umass.edu/>

⁸<http://mas.cs.umass.edu/download.html>

3.2.4 NetLogo

NetLogo⁹, um ambiente programável para modelagem e simulação de fenômenos ambientais e sociais, é umas das ferramentas para modelos baseados em agentes mais popular da atualidade. Produzida originalmente por Tisue e Wilensky (2004) [71], NetLogo vem sendo desenvolvida pelo Centro de Aprendizado Conectado e Modelagem Computacional da *Northwestern University*, em Evanston, Illinois, Estados Unidos. Usuários podem dar instruções a milhares de agentes independentes, todos agindo concorrentemente, e explorar tanto os comportamentos em nível individual quanto os padrões emergentes gerados da ação de vários agentes em um mesmo domínio. O NetLogo possui uma interface gráfica para construção de modelos e outras ferramentas integradas, além da possibilidade de criação e publicação de extensões pelos próprios usuários. A ferramenta oficialmente oferece mapeamento direto de eventos e ações dos agentes, similar ao Cormas, mas extensões de usuário podem adicionar formas mais complexas de raciocínio, como o BDI [1], e modelagem social com TJE [4]. A linguagem de programação do NetLogo é baseada em Logo, um dialeto de Lisp, que é de fácil uso e permite a prototipação rápida de modelos. Seu código é livre e aberto¹⁰, e existe extensiva documentação a respeito do ambiente, incluindo fóruns de discussão e uma grande comunidade ativa de usuários.

3.2.5 TerraME

TerraME¹¹ é um conjunto de ferramentas livres que oferece suporte a múltiplos paradigmas em um ambiente multiescalar na modelagem das interações homem-ambiente e suas decorrências [21]. Nesse conjunto de ferramentas, é possível utilizar duas abordagens de forma integrada como automatos celulares com SMA, o que o torna bastante flexível, e com mais possibilidades de criação de modelos pelo usuário. TerraME também conta com ferramentas de integração com Dados Georreferenciados e utiliza Lua [42] em sua programação. Na construção do modelo, as características comportamentais, temporais e espaciais podem ser inseridas separadamente, facilitando projetos de larga-escala, um dos grandes desafios para simulações baseadas em agentes. Na especificação dos comportamentos, são permitidos apenas mapeamentos diretos de eventos-ação, tornando todos os agentes da simulação exclusivamente reativos.

TerraMe se destaca por ter sido desenvolvido no Brasil, pelo Instituto Nacional de Pesquisas Espaciais (INPE), em São José dos Campos, São Paulo. Ele foi utilizado para o desenvolvimento do primeiro trabalho correlato listado neste Capítulo, por Ribeiro et Al. (2009) [19]. Ele é de código livre e aberto¹², e utilizado amplamente em pesquisas do INPE relacionados a interações entre o homem e o ambiente natural e seus impactos.

3.2.6 ABED

ABED¹³. é uma ferramenta de simulação baseada em agentes com interações em TJE desenvolvida por Izquierdo, Segismundo e Sandholm [44]. De código aberto, ela foi de-

⁹<http://ccl.northwestern.edu/netlogo/>

¹⁰<https://ccl.northwestern.edu/netlogo/download.shtml>

¹¹<http://www.terrame.org/>

¹²<http://www.terrame.org/doku.php?id=download130>

¹³<https://luis-r-izquierdo.github.io/abed-2pop>

se desenvolvida com o conjunto de ferramentas oferecido pelo NetLogo (Seção 3.2.4) para a simulação de populações finitas em jogos de duas estratégias e dois jogadores. ABED permite então que a evolução da sociedade de agentes seja observada quanto a sua evolução, a partir de parâmetros pré-configuráveis pelo usuário, como taxa de encontros e adaptabilidade de cada estratégia.

ABED se destaca por ser uma ferramenta em SMA com o uso intrínseco de TJ e TJE para simulações de evolução computacional. Mesmo que seus modelos não sejam espacialmente explícitos, ela é adjacente a este trabalho por explorar possibilidades de troca de estratégia e replicação populacional em populações finitas de agentes.

3.2.7 Dynamo

Dynamo¹⁴ (*Diagrams for evolutionary game dynamics*) é um software de código aberto que utiliza a plataforma *Mathematica* para a geração de diagramas de evolução computacional em [25]. Ele utiliza modelos matemáticos e definições de jogos para a geração de diagramas de fase que podem sublinhar propriedades-chave em sistemas dinâmicos cuja população é envolvida em situações estratégicas e evolucionárias.

Tabela 3.1: Tabela comparativa com MASE-EGTI e as ferramentas apresentadas na Seção 3.2.

	Tipo de modelo	Modelo espacialmente explícito	Agentes móveis	Políticas públicas	Uso de jogos	Agentes BDI cognitivos	Modelo com dados reais e TJE
MASE-EGTI	MBA	✓	✓	✓	✓	✓	✓
Cormas	MBA	✓	✓	✓	✓		
GAMA	MBA	✓	✓	✓	✓	✓	
NetLogo	MBA	✓	✓				
TerraME	MBA	✓	✓	✓	✓		
ABED	MBA			✓			
Dynamo	Modelos matemáticos				✓		

Neste Capítulo foram apresentados trabalhos correlatos adjacentes ao modelo proposto nessa pesquisa. Dois projetos de pesquisa foram apresentados na Seção 3.1, com o primeiro direcionado ao estudo do equilíbrio de agentes estratégicos localizados em uma grade espacial, e o segundo utilizando TJ para sublinhar como as ações dos agentes podem causar consequências a comunidade de agentes, como uma situação estratégica definida no jogo. Na Seção 3.2 foram apresentadas ferramentas correlatas ao MASE-EGTI. A Tabela 3.1 apresenta lacunas em trabalhos na área quanto a ferramentas que fazem o uso de modelos com dados reais e interações modeladas com TJ/tje. O Capítulo 4 apresenta o modelo de simulação definido neste projeto, bem como seus desdobramentos que buscam soluções em resolução de conflitos e tomada de decisão.

¹⁴<http://www.ssc.wisc.edu/~whs/dynamo>.

Capítulo 4

Proposta

Neste Capítulo é introduzido um modelo para simulações M em LUCC o qual inclui dentro de si o modelo de interação proposto para o alcance dos objetivos desse trabalho. O modelo de interação I possui um sistema de decisão D e um sistema de regras G baseado em TJE. Eles também serão apresentados neste Capítulo. A ferramenta MASE-EGTI, já introduzida na Seção 1.3, é descrita ao final com mais detalhes, incluindo a caracterização das mudanças feitas para que experimentações com o modelo pudessem ser executadas e os resultados produzidos nas simulações.

4.1 Modelo de Simulação

A proposta de modelo de LUCC M explorada neste trabalho envolve 5 dimensões principais: $M = S, T, A, I, P$, em que:

- S é o espaço celular (*Space*),
- T é o tempo (*Time*),
- A é o conjunto de agentes (*Agents*),
- I é o modelo de interação entre os agentes (*Interaction*), e
- P é a política pública (*Public Policy*).

Por isso, modelos M neste trabalho passarão a ser chamados como STAIP. Do ponto de vista do usuário, as características do modelo são representadas como parâmetros de simulação que podem ser configurados de acordo com a descrição do cenário a ser representado. A seguir, serão apresentadas cada uma das dimensões do STAIP.

4.1.1 Espaço

O espaço é representação da área física regional ou global estudada, reconstituída por um conjunto de células (Ce) interconectadas. Esse conjunto forma um grafo em que uma célula conecta-se a células imediatamente acima, abaixo, à direita, à esquerda e às diagonais dela (com exceção das bordas). O conjunto de células é um mapeamento direto de cada posição do espaço a ser representado, como se cada segmento quadrado de 1x1 do espaço representasse uma célula (Figura 4.2).

Cada célula, além da sua posição cartesiana x e y , tem cinco atributos principais: o potencial de exploração S_{PE} , o estado S_E , a atratividade S_A , o proprietário Ow e a

lista de interesse IL . Os atributos S_{PE} e S_E são diretamente interligados, e o usuário determina numericamente o quanto de recursos da terra aquele espaço é capaz de oferecer com base em seu estado. Os estados são compostos por uma máquina finita de estados possíveis, como vegetação remanescente, agricultura, pecuária, urbanização, entre outros.

A Figura 4.1 mostra um exemplo de máquina de estado baseada na classificação apresentada por Sano et al. em 2008 [61]. Nessa imagem, vegetação remanescente pode ser um ponto inicial de uma área, a qual pode ser convertida para o estado final de área de conservação. É possível também converter uma área de vegetação remanescente para agricultura, pecuária ou urbanização. Enquanto a área de urbanização é final, as áreas de pecuária e agricultura podem ser intercambiáveis dependendo das técnicas de manejo utilizadas, podendo ser convertidas para uma área final de urbanização ou recuperadas para vegetação remanescente.

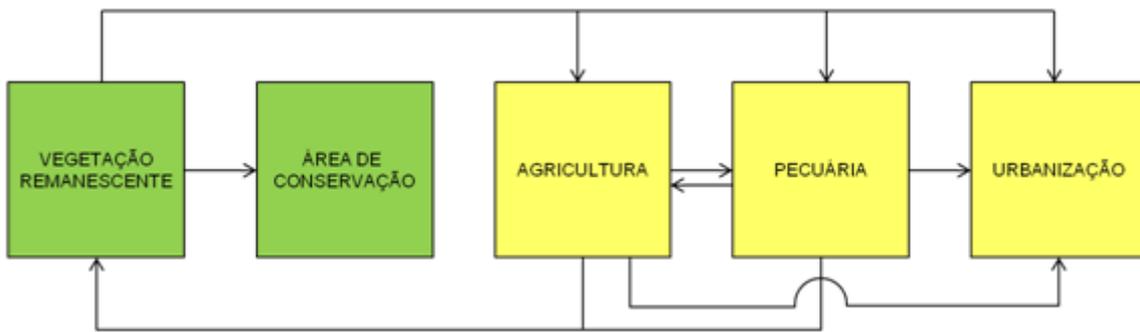


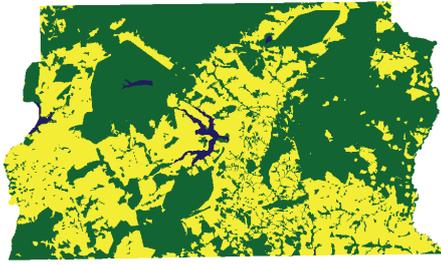
Figura 4.1: Um exemplo de máquina de estados para a representação das células no espaço. Fonte: Sano et al. (2008) [61]. Adaptado pelo autor.

Atratividade é um índice calculado que indica o quanto uma célula é desejável pelos agentes. Quanto maior esse índice, mais provável é a chance da célula ser ocupada. Proprietário é o agente que atualmente ocupa ou já ocupou determinada célula - se a célula nunca foi ocupada, então este atributo é nulo. Por fim, lista de interesse é um registrador de agentes que possuem a intenção de mudar para a célula em questão, sendo utilizado para a resolução de conflitos do modelo de interação atrelado ao STAIP.

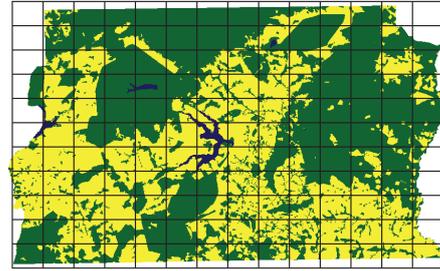
Sendo assim, o espaço S de largura n e altura m , além de poder se enxergado como um grafo de células Ce , também pode formalmente ser representado como uma matriz $M_S = \{\{Ce_{0,0}, Ce_{0,1}, \dots, Ce_{0,n-1}\}, \dots, \{Ce_{m-1,0}, Ce_{m-1,1}, \dots, Ce_{m-1,n-1}\}\}$, em que cada $Ce_{i,j} = \{S_{PE}, S_E, S_A, Ow, IL\}$, com $0 \leq i < n$ e $0 \leq j < m$ e é uma célula com potencial de exploração, estado, atratividade, proprietário e lista de interesse próprios.

4.1.2 Tempo

Os modelos STAIP são dinâmicos e temporalmente discretos. Então, o tempo é representado por um conjunto de passos (ou *steps*) sequenciais, discretos e finitos que compõem a simulação em si. Um passo de simulação é um intervalo de tempo t_k , com $0 \leq k < T$ em que todos os agentes que compõem a simulação completam seu objetivo principal uma única vez. A quantidade de tempo T é a quantidade de passos escolhida pelo usuário - uma vez que T passos de simulação são completados com sucesso, a simulação acaba.



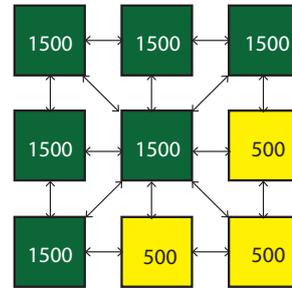
(a) Espaço original



(b) A segmentação do espaço

1500	1500	1500
1500	1500	500
1500	500	500

(c) Células adjacentes



(d) Células interconectadas

Figura 4.2: A representação do espaço e respectivos detalhamentos. Fonte: elaborado pelo autor (2021).

Alternativamente, se a quantidade de células disponíveis para serem ocupadas acaba antes de T passos, a simulação termina prematuramente por falta de recursos espaciais. A Figura 4.3 demonstra de forma simples um *step* qualquer de simulação, em que um evento inicial (início de *step*) inicia os agentes, que executam seus objetivos principais. Uma vez que todos alcançaram, um evento de término de *step* é emitido (fim de *end*), e um outro *step* é iniciado, até o fim da simulação.

4.1.3 Agentes

Agentes são entidades do modelo que representam as forças transformativas da sociedade sobre o meio ambiente e o meio urbano. Sua quantidade é configurável pelo usuário, e ela não muda durante a simulação - nenhum agente nasce, morre, emigra ou imigra. Além disso, seus espaços iniciais podem ser aleatoriamente decididos ou fixados no espaço.

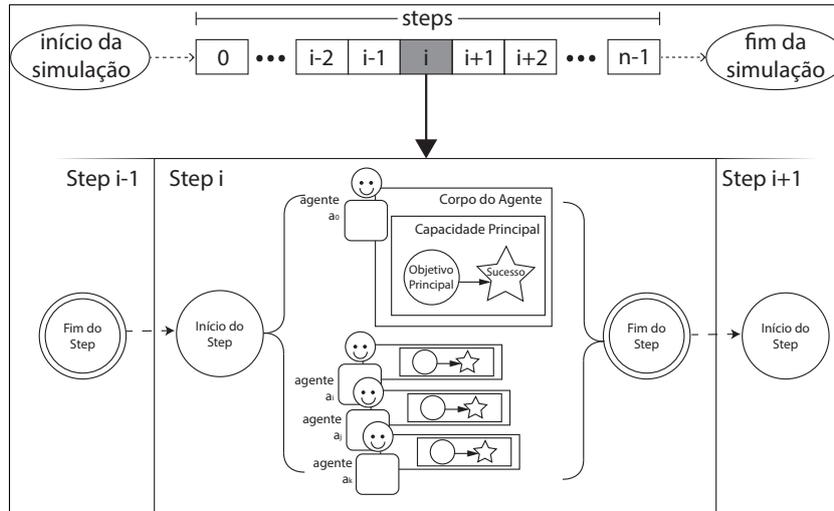


Figura 4.3: A representação simplificada de um step i do tempo. Fonte: elaborado pelo autor (2021).

Agentes no STAIP possuem cognição baseada em raciocínio prático BDI (Seção 2.1). Sendo assim, suas capacidades podem ser parametrizadas para melhor descrevê-los. Os agentes possuem quatro capacidades básicas, a saber em ordem de prioridade:

- Explorar (Ca_e): capacidade de extrair os recursos do solo, composta pelo objetivo “Explorar espaço”, a ação “Extrair recursos” e a crença “Créditos de exploração” (também referenciada como Cr). O objetivo “Explorar espaço” é o objetivo principal dos agentes do STAIP - citado no tópico anterior, Tempo. Ele deve ser cumprido por completo para que o agente possa passar para o próximo *step*. A condição para que isso aconteça é que o crédito de exploração Cr seja completamente utilizado;
- Mover (Ca_m): capacidade de mudar de posição no espaço, composta pelo objetivo “Mudar-se de célula”, as ações “Encontrar novo espaço” e “Mover-se para novo espaço”, e a crença “Vizinhança”;
- Resolver Conflitos (Ca_r): capacidade de determinar quem é o dono de uma célula em uma situação de competição por recurso espacial. O objetivo associado é “Resolver conflito de espaço”, as ações são “Registrar interesse”, “Aguardar interessados”, “Verificar lista”, “Abrir comunicação de conflito”, “Resolver comunicação de conflito”, “Obter recurso” e “Desistir de recurso”. Mais detalhes sobre essa capacidade serão descritos no modelo de interação (Seção 4.1.4).
- Alterar Perfil (Ca_a): capacidade utilizada em situações específicas após a Ca_r ser ativada. Envolve o objetivo: “Avaliar perfil atual”, as ações “Adicionar payoff”, “Avaliar melhor resposta” e “Mudar de perfil” e a crença “perfil estratégico” ps . Mais detalhes sobre essa capacidade também serão descritos no modelo de interação (Seção 4.1.4).

Agentes, além das capacidades citadas, possuem mais três crenças próprias a eles: seu identificador único id , sua célula atual Ce_{AT} e sua classe de exploração. O usuário define a quantidade de agentes na simulação e quais classes de exploração são possíveis.

Cada agente do STAIP possui um crédito de exploração Cr próprio e ligado ao sua classe definida pelo usuário, e cada agente é instanciado em uma célula $Ce_{i,j}$ do espaço ao início da simulação. O perfil estratégico ps pertinente à capacidade “Alterar perfil” também está atrelado à classe de exploração e aos créditos de exploração. Sendo assim, o usuário, ao definir que classes de exploração participarão do modelo, deve também definir quais os créditos de exploração são inerentes às classes, bem como quais são os perfis estratégicos.

Para melhor ilustrar classes de exploração, créditos de exploração e perfis estratégicos, exemplifica-se com um modelo em que o usuário quer representar agentes realizando dois tipos de atividades socioeconômicas: mineração e extrativismo vegetal. Sendo assim, o usuário define duas classes de exploração: mineração e extrativismo. Agentes mineradores extraem 100 unidades de potencial do solo de células por vez, enquanto extrativistas extraem apenas 75. Portanto, o Cr de agentes mineradores é 100, e o de extrativistas é 75. Algumas áreas podem atrair tanto mineradores quanto extrativistas, criando conflitos. Nesses conflitos, mineradores são agressivos e extrativistas evitam conflitos. Logo, o perfil estratégico de mineradores é agressivo, e de extrativistas, pacífico. O perfil estratégico será utilizado para a resolução de conflitos (Seção 4.1.4).

Ao início de cada passo de simulação, Cr dos agentes é renovado ao seu valor original definido. O agente então aciona seu objetivo principal Ca_e , que consiste em gastar todo seu crédito Cr para extrair recursos da terra. Sendo assim, ele gasta cada unidade do seu crédito de exploração para tirar cada unidade de potencial de exploração da célula atual com a ação “Extrair recursos”. Se a célula atual Ce_{AT} em que ele está localizado tem mais potencial de exploração S_{PE} do que ele é capaz de extrair com seu crédito Cr , o objetivo “Explorar espaço” é completado com sucesso. Nessa situação, o agente gasta seu crédito por completo, e a célula em que ele está fica com o novo potencial de exploração $S'_{PE} = S_{PE} - Cr$. O agente então fica aguardando que todos os outros agentes da simulação também completem seus objetivos com sucesso, para que o controle da simulação encerre o step atual e inicie o próximo step, reiniciando o ciclo de simulação - conforme apresentado no tópico Tempo.

No entanto, caso a célula possua menos potencial de exploração S_{PE} que a quantidade de créditos do agente que nela reside, seu potencial de exploração é zerado e o agente ainda retém $Cr' = Cr - S_{PE}$ de créditos de exploração. O objetivo “Explorar espaço” então falha, e o agente ativa a capacidade de mover-se. Ao acessar essa capacidade, o agente assume o objetivo “Mudar-se de célula”. A ação “Encontrar novo espaço” é realizada com base na crença “Vizinhança”, em que o agente analisa as n células livres dos espaços adjacentes à célula CE_{AT} em que ele se encontra para descobrir quais ele poderia se mudar. Ele ignora células que já possuem proprietário ou que possuem atratividade negativa, reunindo apenas as células livres e com atratividade igual ou maior a zero. Ao obter a lista das n células, ele acessa o valor de atratividade de cada uma, somando-as em um registrador auxiliar denominado SS_A , em que:

$$SS_A = \sum_{i=0}^{n-1} S_{Ai}, \quad (4.1)$$

onde S_{Ai} é a atratividade da i -ésima célula da vizinhança. A seguir, o agente acessa novamente a atratividade de cada célula da vizinhança, somando-as cumulativamente mas registrando os subtotais de cada um das $n - 1$ somas e armazenando-as numa lista

auxiliar L . A seguir, ele divide cada valor de L por SS_A , obtendo uma distribuição de probabilidade de 0 a 1 ao longo das n células. Em sequência, ele obtém um número aleatório do sistema entre 0 e 1, e o primeiro valor da lista L que for maior ou igual ao valor aleatório obtido corresponde à posição da célula em que ele vai escolher para mover-se. Por esse motivo, células com atratividade mais alta possuem maior probabilidade de serem escolhidas para a mudança de um agente - uma vez que elas estabelecem um intervalo de probabilidade maior na distribuição calculada pela vizinhança.

Após a ação de “Encontrar novo espaço”, o agente exerce “Mover-se para novo espaço”. Para isso, ele ativa a capacidade Ca_R de resolução de conflitos, assumindo “Resolver conflito de espaço” como subobjetivo. Caso a célula não possua outro agente interessado em se mover para ela, o agente a toma para si e considera tanto o objetivo de Ca_r quanto o objetivo de Ca_m como sucessos. Ao obter a célula, o agente torna-se proprietário (Ow) da célula e retoma a capacidade Ca_e até que Cr torne-se zero - cumprindo o objetivo principal para o passo de simulação. Pode haver necessidade do agente precisar mudar mais vezes de célula, dependendo da sua quantidade de Cr restante.

No entanto, se a célula possuir mais agentes interessados nela, os agentes precisam resolver o conflito e decidir quem é o ganhador do recurso ambiental. O ganhador do conflito obtém a célula, e os perdedores tentam outras células da vizinhança. A forma de resolver os conflitos é abordada na Seção a seguir.

4.1.4 Interação

Como já mencionado no STAIP, o modelo de interação I é utilizado para resolver conflitos por recursos entre agentes do modelo. Ele afeta o resultado de uma situação estratégica em que dois ou mais agentes tem a intenção de se mover para uma célula com potencial de exploração a ser utilizado. Como células possuem um índice de atratividade relativo umas as outras, há células em que conflitos entre agentes ocorrem com maior probabilidade que outras em diferentes localizações.

O modelo de Interação I é composto por um sistema de decisão D e um sistema de regras G baseado em Teoria dos Jogos Evolucionários. Agentes trabalham de forma autônoma com diferentes ações e objetivos ativos dentro de um espaço compartilhado - por isso precisam de certos pontos de sincronização quando precisam modificar recursos comuns. Neste trabalho, a sincronização é feita por meio de conflitos que exigem a interação entre agentes. Sendo assim, o sistema de decisão D diz respeito a como os agentes irão se organizar para fazer a deliberação coletiva do conflito, enquanto o sistema de regras G define os critérios de decisão em si, incluídos na mensagem trocada entre os agentes envolvidos. O sistema de regras também influencia a troca de estratégia do agente, ligada à sua quarta capacidade definida. Ambos D e G são configuráveis pelo usuário, e as possibilidades para eles são listadas a seguir. Uma vez que a capacidade do agente de trocar de perfil estratégico depende do modelo de interação, ele será melhor explorado ao final dessa Seção.

Sistema de decisão

O sistema de decisão D pode ser centralizado ou distribuído, e diz a respeito a quem os agentes envolverão na decisão de quem é o ganhador da célula.

No sistema centralizado, há um agente auxiliar - o gerente - que recebe requisições de conflito para resolvê-las. Esse agente tem o conhecimento de quantos agentes compõem a simulação, bem como quais as células que eles ocupam no momento, mantendo um registro do espaço como todo. O gerente possui uma fila de requisição, em que mensagens de agentes são automaticamente organizadas por ordem de chegada assim que são recebidas.

Agentes do STAIP, após escolherem qual célula eles desejam se mover, enviam uma mensagem para o Gerente informando seu *id* e a posição (x, y) da célula desejada. O Gerente então começa a processar a fila em ordem de chegada - *First In, First Out* (FIFO) -, e verifica em seu registro interno se há algum agente ocupando a célula desejada. Se não houver, o Gerente atualiza seu registro de espaço nomeando o proprietário da célula para o agente interessado e responde a mensagem concedendo a célula. Se houver, o Gerente apenas responde a mensagem negando o recurso ao agente.

Entre as ações dos agentes de “Encontrar novo espaço” e “Registrar interesse” e o processamento das mensagens por parte do Gerente, a célula de interesse pode continuar com o registro de proprietário *Ow* nulo - por mais que já existam agentes que manifestaram seu interesse nela. Por isso outros agentes podem acabar considerando o recurso espacial válido, decidindo interessar-se por ele e enviando mensagem para o Gerente, criando um conflito nesse intervalo de tempo. No entanto, o Gerente processa as mensagens sequencialmente, o que garante a vitória do primeiro agente que escolher a célula e informar o Gerente sua intenção, impedindo que outros agentes obtenham o recurso espacial. Sendo assim, o sistema de regras G que compõe o modelo de interação I não é utilizado nessa situação, uma vez que o critério é direto.

Esse sistema de decisão foi utilizado nos modelos de validação de trabalhos com o MASE [56] e com o MASE-BDI [11], em que ainda não havia um modelo baseado em Jogos sendo integrado à resolução de conflitos. O sistema de decisão centralizado foi integrado ao STAIP para comparação com os novos sistemas de decisão distribuídos, desenvolvidos neste trabalho junto com o sistema de regras.

Quanto aos sistemas de decisão distribuídos, eles são apresentados como *First Takes All* (FTA) e *Stop and Go* (SNG). Ambos dispensam a necessidade do gerente do sistema centralizado, permitindo que os agentes do STAIP se auto-gerenciem por meio de registros em célula e troca de mensagens. São comuns a ambos sistemas de decisão distribuídos o uso da lista de interesse IL da célula que registram os agentes interessados nela. A lista permite a escrita de um agente por vez, e não permite que um agente altere o registro do outro. Assim, agentes registram seu *id* em ordem de chegada em IL , e em seguida verificam qual foi o lugar que eles conseguiram obter. Adicionalmente, enquanto a lista IL só permite uma escrita por vez para manter a consistência, a leitura pode ser feita a qualquer momento sem mecanismo de consistência, uma vez que não altera o dado registrado.

O sistema de decisão FTA é caracterizado pelo seu método de decisão em si: o agente cujo *id* é o primeiro da lista de interesse imediatamente ganha a célula. Como pode acontecer um breve intervalo entre verificar se a célula já possui proprietário e escrever o interesse na lista, outros agentes podem tentar registrar suas intenções ao mesmo tempo, criando outras entradas na lista IL em uma situação de conflito. No entanto, apenas o agente que conseguir escrever primeiro ganha o recurso. Isso é possível graças à propriedade da lista, que só permite um agente escrever por vez. Em caso de empate, o primeiro a escrever é decidido aleatoriamente. Uma vez que o critério de decisão é definido pelo pri-

meio agente a conseguir escrever na célula, o sistema de regras G também não é aplicável a FTA, de forma similar ao sistema centralizado.

O sistema de decisão SNG possui um mecanismo diferente. Primeiramente, todos os agentes que precisam se mudar registram seus interesses nas listas das respectivas células e pausam suas execuções (*stop*). Assim que todos os agentes registraram suas intenções, os conflitos começam a ser resolvidos dois a dois por meio do sistema de regras. Logo, o sistema de regras G apenas se aplica no sistema de decisão SNG. O sistema centralizado e FTA ignoram essas regras por sempre escolher o primeiro a registrar seu interesse.

De forma geral, no sistema SNG, a decisão é feita por um ciclo interativo. O agente cujo id é o primeiro da lista IL verifica se o id dele é o único da lista. Se sim, ele conquista a célula. Se não, ele verifica quem é o segundo da lista, e então utiliza o sistema de regras definido no modelo de interação para decidir quem é o ganhador. O perdedor do conflito retira seu id da lista IL , e o ganhador verifica se ele é o único da lista, conquistando a célula se sim, ou iniciando a conversação com o próximo da lista, reiniciando o ciclo até que haja apenas um ganhador dos conflitos.

Sistema de regras

O sistema de regras, como já frisado anteriormente, é modelado a partir de um jogo sob o ponto de vista de TJ/TJE, em que as estratégias são equivalentes aos perfis estratégicos ps atrelados às classes de exploração e créditos de exploração definidos pelo usuário. Sendo assim, o jogo deve possuir a mesma quantidade m de estratégias de classes de exploração. Os *payoffs* são definidos pelo usuário, e são utilizados como critério para definir o ganhador da célula. É importante destacar que tais regras são utilizadas apenas quando o sistema de decisão é SNG.

Por exemplo, na Seção 4.1.3 utilizou-se o exemplo de duas classes de exploração: mineradores e extrativistas, em que o primeiro apresentava um perfil agressivo e o segundo, pacífico. É possível propor, por exemplo, que os mineradores assumam o papel de *hawk* e os extrativistas de *dove* do jogo *hawk-dove*. O resultado de um conflito é baseado nos *payoffs* sugeridos pela Tabela 4.1.

Tabela 4.1: Os *payoffs* dos encontros de mineradores e extrativistas como um jogo de Hawk-Dove

		Jogador β	
		<i>Minerador</i>	<i>Extrativista</i>
Jogador α	<i>Minerador</i>	$(-1/2, -1/2)$	$(1, 0)$
	<i>Extrativista</i>	$(0, 1)$	$(1/2, 1/2)$

Os *payoffs* do jogo são então comparados entre os jogadores, e o critério de resolução do conflito é que o agente que possuir maior valor ganha o recurso espacial. Em caso de *payoffs* iguais, um dos jogadores é escolhido como vencedor aleatoriamente.

Sendo assim, na resolução de conflitos em SNG, quando o primeiro agente resolve um conflito com o segundo, ele envia uma mensagem informando dois valores: qual é seu perfil estratégico e um número aleatório entre 0 e 1, denominado número de desempate b_1 . Ao receber a mensagem o segundo agente também gera um número de desempate b_2 entre 0 e 1, e então lê seu conteúdo, obtendo o perfil estratégico do oponente e o número

b_1 . Ele então consulta o jogo definido no sistema de regras para obter os payoffs p_1 e p_2 , e assim averiguar quem ganhou o jogo.

- Se $p_1 > p_2$, o primeiro agente torna-se vencedor e o segundo, perdedor;
- Se $p_2 > p_1$, o segundo agente torna-se vencedor e o primeiro, perdedor;
- Se $p_1 = p_2$ e $b_1 > b_2$, o primeiro agente torna-se vencedor e o segundo, perdedor; e por fim,
- Se $p_1 = p_2$ e $b_1 < b_2$, o segundo agente torna-se vencedor e o primeiro, perdedor.

O segundo agente informa o resultado do jogo ao primeiro e atualiza sua crença própria de quem ganhou e quem perdeu o conflito. Então, o agente considerado perdedor retira sua intenção da célula em questão e procura outro espaço, enquanto o vencedor comunica-se com o terceiro agente na fila (se houver), até que somente um agente vencedor na fila de intenção.

Troca de Estratégia

Agentes envolvidos no conflito podem ao final da resolução acessar sua quarta capacidade - “Alterar perfil” (Seção 4.1.3). Dessa forma, em um próximo conflito por recursos, eles podem simular a transformação não apenas da paisagem, mas também da sociedade a qual eles pertencem, alterando sua classe de exploração como consequência de ganhos ou perdas de recursos. A troca é configurável pelo usuário e pode ser representada por um comportamento reativo ou por um comportamento baseado em registros de memória.

Para melhor ilustrar ambos comportamentos, considere que o jogo utilizado em G (sumarizado na Tabela 4.2) possui apenas duas estratégias - i e j - e que seus *payoffs* são representados pela função u . Além disso, considere que existem N agentes do STAIP presentes na simulação, em que N_i possuem o perfil estratégico $ps = i$ e N_j possuem o perfil estratégico $ps = j$. As variáveis η_i e η_j são a representação das proporções de agentes de perfis estratégicos i e j , tal que $\eta_i = \frac{N_i}{N}$, $\eta_j = \frac{N_j}{N}$ e $\eta_i + \eta_j = 1$. Para fins de clareza, agentes que possuem $ps = i$ serão referenciados como agentes i , e agentes com $ps = j$, agentes j .

Tabela 4.2: Um jogo genérico utilizado para a construção do sistema de regras G .

		Agente β	
		i	j
Agente α	i	$u(i, i)$	$u(i, j)$
	j	$u(j, i)$	$u(j, j)$

Seja θ a probabilidade do acontecimento de um conflito em uma célula, com $0 \leq \theta \leq 1$. Define-se então função U_i e U_j , que representa o *payoff* esperado de agentes i e j após um conflito por uma célula, com base na Equação 2.13 (Seção 2.3.2). Essas funções dependem de θ , dos *payoffs* definidos na Tabela 4.2 e das probabilidades η_i e η_j , que podem ser entendidas como probabilidades do agente encontrar agentes i ou agentes j :

$$U_i = \theta(\eta_i u(i, i) + \eta_j u(i, j)); \quad (4.2)$$

e

$$U_j = \theta(\eta_i u(j, i) + \eta_j u(j, j)). \quad (4.3)$$

Com base na Equação 2.14 (Seção 2.3.2) e nas Equações 4.2 e 4.3, pode-se definir as equações de variação populacional de agentes i e j :

$$\dot{N}_i = N_i[U_i - \bar{U}_{i,j}]; \quad (4.4)$$

e

$$\dot{N}_j = N_j[U_j - \bar{U}_{i,j}], \quad (4.5)$$

em que $\bar{U}_{i,j}$ é o *payoff* médio da população, representado por:

$$\bar{U}_{i,j} = \frac{N_i U_i + N_j U_j}{N} \rightarrow U_{i,j} = \eta_i U_i + \eta_j U_j. \quad (4.6)$$

Sendo assim, dividindo as Equações 4.4 e 4.5 por N em ambos lados e realizando a substituição de $\bar{U}_{i,j}$ pela Equação 4.6, obtém-se:

$$\dot{\eta}_i = \eta_i \eta_j \theta[\eta_i (u(i, i) - u(j, i)) + \eta_j (u(i, j) - u(j, j))]. \quad (4.7)$$

$$\dot{\eta}_j = \eta_i \eta_j \theta[\eta_i (u(j, i) - u(i, i)) + \eta_j (u(j, j) - u(i, j))]. \quad (4.8)$$

Ambas Equações serão utilizadas para entender os mecanismos de troca de estratégia a seguir.

Comportamento Reativo

De forma simples, no comportamento reativo o perdedor do conflito troca sua perfil estratégico ps para o perfil que poderia ganhar a última situação estratégica perdida. Esse comportamento foi projetado a partir da lógica do jogo *Tit-for-tat*, em que o um jogador copia a estratégia que o outro utilizou de forma reativa. No entanto, agentes do STAIP que comportam-se reativamente quanto à mudança de estratégia escolhem o comportamento que seria preferencialmente melhor ao do oponente numa situação de perda.

Tabela 4.3: O jogo Hawk-Dove com custo de recompensa $V = 2$ e custo de conflito $C = 4$

		Jogador 2	
		<i>Hawk</i>	<i>Dove</i>
Jogador 1	<i>Hawk</i>	(-1, -1)	(2, 0)
	<i>Dove</i>	(0, 2)	(1, 1)

Considere por exemplo o jogo *Hawk-Dove* com os valores de *payoff* determinados na tabela 4.3. Sejam A_1 e A_2 dois agentes do STAIP que podem ser agentes *hawk* ou *dove*. A distribuição de probabilidade $p(A_1, A_2 | A_1 \text{ vence } A_2)$ de A_1 ganhar de A_2 é dada por quatro valores possíveis, com base nas seguintes condições:

1. A_1 é *hawk* e A_2 é *hawk*: $p(A_1, A_2 | A_1 \text{ vence } A_2) = 0.5$ porque há um empate e os agentes decidem na sorte;
2. A_1 é *hawk* e A_2 é *dove*: $p(A_1, A_2 | A_1 \text{ vence } A_2) = 1$ porque $u(\text{hawk}, \text{dove}) > u(\text{dove}, \text{hawk})$;

3. A_1 é *dove* e A_2 é *hawk*: $p(A_1, A_2|A_1 \text{ vence } A_2) = 0$ porque $u(\text{dove}, \text{hawk}) < u(\text{hawk}, \text{dove})$;
4. A_1 é *dove* e A_2 é *dove*: $p(A_1, A_2|A_1 \text{ vence } A_2) = 0.5$ porque há um empate e os agentes decidem na sorte;

Com esses resultados e considerando o comportamento reativo, é possível calcular a probabilidade $\rho(A_1, A_2|A_1 \rightarrow A_1)$ de A_1 permanecer com seu perfil estratégico após conflitar com A_2 , conforme Tabela 4.4.

Tabela 4.4: Probabilidade do Agente α permanecer em sua estratégia após conflitar com Agente β

		Agente β	
		<i>Hawk</i>	<i>Dove</i>
Agente α	<i>Hawk</i>	$\rho(\text{hawk}, \text{hawk} \text{hawk} \rightarrow \text{hawk}) = 1$	$\rho(\text{hawk}, \text{dove} \text{hawk} \rightarrow \text{hawk}) = 1$
	<i>Dove</i>	$\rho(\text{dove}, \text{hawk} \text{dove} \rightarrow \text{dove}) = 0$	$\rho(\text{dove}, \text{dove} \text{dove} \rightarrow \text{dove}) = 0.5$

As situações em que *dove* perde de *hawk* sempre implicam em *dove* trocando de estratégia para *hawk*, uma vez que apenas *hawk* teria chance de ganhar de outro *hawk*. No entanto, em ocasiões em que um *hawk* perde de outro *hawk* (por empate de *payoff* e decisão com base no número de desempate), o perdedor não tem incentivo para trocar de estratégia, já que ele já está na estratégia que poderia ganhar de outro *hawk* em um conflito futuro. Sendo assim, chance de ele permanecer como *hawk* é 1. Por fim, no caso de empate entre *doves*, o número de desempate faz com que 50% das vezes um agente *dove* ganhe de outro. O *dove* perdedor então troca para *hawk*, pois seria a estratégia que teria 100% de ganhar de outro *dove* em um próximo conflito. Sendo assim, no final, a chance de um *dove* permanecer como *dove* é 0.5.

Fazendo um paralelo entre a probabilidade ρ de permanência e a função de utilidade u presente nas Equações 4.7 e 4.8, poderia-se investigar a variação nas populações de *hawks* e *doves* fazendo as substituições respectivas de u e ρ para o jogo da Tabela 4.3:

$$\dot{\eta}_{dove} = \eta_{dove}\eta_{hawk}\theta[\eta_{dove}(0.5-1)+\eta_{hawk}(0-1)] \rightarrow \dot{\eta}_{dove} = -0.5\eta_{dove}^2\eta_{hawk}\theta - \eta_{hawk}^2\eta_{dove}\theta, \quad (4.9)$$

e

$$\dot{\eta}_{hawk} = \eta_{dove}\eta_{hawk}\theta[\eta_{dove}(1-0.5)+\eta_{hawk}(1-0)] \rightarrow \dot{\eta}_{hawk} = 0.5\eta_{dove}^2\eta_{hawk}\theta + \eta_{hawk}^2\eta_{dove}\theta, \quad (4.10)$$

o que demonstra que a proporção η_{hawk} tende a aumentar enquanto a η_{dove} diminui quando há um comportamento reativo. Intuitivamente, tal predição faz sentido, uma vez que *hawk* sob esse sistema tem uma maior probabilidade obter o recurso contra *dove*, que só ganha de outros *doves* em 50% das vezes. Uma vez que a quantidade de *doves* na população tende a diminuir, os agentes *dove* tendem a ter menos chance de ganhar um conflito contra um agente aleatório e permanecer como *dove*, acelerando ainda mais a extinção desse perfil estratégico.

Por mais que o jogo referenciado tenha sido *Hawk-Dove*, em termos de classificação desse exemplo quanto à força do dilema, a Tabela 4.4 sugere que o subarquétipo (Seção 2.3.3) mais adequado seria o de Dilema dos Prisioneiros, uma vez que $D_g > 0$ e $D_r < 0$.

Isso se torna ainda mais notável quando percebe-se que a tendência é de agentes *Hawk* aumentarem e *dove* diminuírem, sugerindo uma população que prefere explorar uns aos outros (GID) que amenizar riscos provenientes por conflito (RAD).

Comportamento Baseado em Registros de Memória

Nesse comportamento, agentes do STAIP possuem duas crenças auxiliares sob forma de n registradores de *payoff* de acordo com a quantidade de perfis estratégicos disponíveis. Em um sistema de regras construído sob um jogo como *hawk-dove* (Tabela 4.3), todos os agentes possuem dois registradores: R_{hawk} e R_{dove} , que são iniciados registrando zero. Quando os agentes estão jogando uma dessas estratégias, todos os *payoffs* recebidos dos conflitos são acumulados no registrador correspondente, independentemente do ganho ou da perda do recurso espacial. Por exemplo, um agente *Hawk* ao conflitar com um agente *dove* recebe $u(hawk, dove) = 2$. Esse valor é acumulado no R_{hawk} . Ao final de um conflito, os agentes vencedores e perdedores avaliam seus registradores R_{hawk} e R_{dove} , e permanecem ou mudam para a estratégia equivalente ao registrador que possua maior valor - em contraponto ao comportamento reativo, em que os agentes buscam imediatamente mudar de estratégia para que poderia ganhar o último conflito.

Sendo assim, para melhor ilustrar os possíveis desdobramentos desse comportamento, considere um jogo de dois jogadores e duas estratégias i e j , com agentes possuindo então registradores R_i e R_j . Considera-se um agente com perfil estratégico $ps = i$. Após envolver-se em um conflito, ele irá atualizar o registrador R_i somando a ele $u(i, i)$ se o encontro foi com um outro agente i , e $u(i, j)$ se foi com um j . O mesmo é válido para um agente j com seu respectivo registrador R_j . As somas acumuladas presentes nesses registradores dependem da taxa de conflitos percebidos no modelo. No entanto, em vez de tratar a probabilidade de conflito de forma generalizada como θ especifica-se a chance de conflitos i com i como α , i com j como β , j com i como γ e j com j como δ . Sendo assim, o estado dos registradores R_i e R_j após um único movimento de um agente pode ser representado como:

$$R_i^0 = \alpha\eta_i u(i, i) + \beta\eta_j u(i, j) \quad (4.11)$$

e

$$R_j^0 = \gamma\eta_i u(j, i) + \delta\eta_j u(j, j), \quad (4.12)$$

em que, conforme já explorado no comportamento reativo, η_i e η_j são as proporções de agentes i e j no *step* atual. Sendo assim, após n *steps* de simulação, a soma acumulada registrada seria:

$$R_i^{n-1} = \sum_{s=0}^{n-1} R_i^s, \quad (4.13)$$

$$R_j^{n-1} = \sum_{s=0}^{n-1} R_j^s \quad (4.14)$$

Por simplicidade e clareza, referencia-se nos próximos parágrafos R_i^n e R_j^n genericamente como R_i e R_j . Após um conflito e após a atualização dos registradores, o agente então escolhe uma estratégia $x \in (i, j)$ tal que $R_x = \max(R_i, R_j)$. Por mais que α, β, γ e δ sejam mais específicos que θ , eles também dependem da topologia do espaço e da matriz proximal, e por isso são determinados empiricamente a cada *step*. Ainda assim, é possível

analisar situações de ganhos e perdas de indivíduos nas respectivas populações por trocas de estratégia.

Considera-se novamente o agente i após um conflito. Se, após atualizar seu registrador R_i , a inequação $R_i < R_j$ é verdadeira, então o agente irá mudar seu perfil estratégico para R_j . De forma simétrica, se os valores de registradores foram tais que $R_i \geq R_j$, então ele permanecerá com $ps = i$. Tais mecanismos são válidos para agentes j com as respectivas adaptações das relações. Nessas condições, a variação de η_i e η_j depende da probabilidade dos estados dos registradores de cada agente. Por isso, estabelece-se uma função ξ que empiricamente registra qual a probabilidade de um agente trocar ou mudar de estratégia, dado o fato de um dos registradores estar maior que o outro após um conflito:

- $\xi(R_i \geq R_j|i, i)$ e $\xi(R_i \geq R_j|i, j)$ implicam que i irá permanecer em i após um conflito com i ou com j , respectivamente;
- Similarmente, $\xi(R_j \geq R_i|j, i)$ e $\xi(R_j \geq R_i|j, j)$ implicam que j irá permanecer em j após um conflito com i ou com j , respectivamente;
- No entanto, $\xi(R_i < R_j|i, i)$ e $\xi(R_i < R_j|i, j)$ implicam que i irá mudar para j após um conflito com i ou com j , respectivamente;
- Por fim, $\xi(R_j < R_i|j, i)$ e $\xi(R_j < R_i|j, j)$ implicam que j irá mudar para i após um conflito com i ou com j , respectivamente;

Sendo assim, considere as Equações 2.10 e 2.11 (Capítulo 2, Seção 2.3.2) com os ajustes de variável necessários (perfil estratégico i corresponde à estratégia S , e j à T). Uma vez que a quantidade de agentes do STAIP não varia - pois não há nascimento, morte, imigração e emigração de agentes -, a forma de ganho ou perda populacional é por meio de trocas de perfis estratégicos. Portanto, dados os possíveis valores de ξ e as Equações 2.10 e 2.11, temos a representação da variação populacional de i e j dadas por:

$$\dot{\eta}_i = \eta_i[\xi(R_i \geq R_j|i, i) + \xi(R_i \geq R_j|i, j)] + \eta_j\xi(R_i > R_j|j, i) - \eta_i\xi(R_j > R_i|i, j), \quad (4.15)$$

$$\dot{\eta}_j = \eta_j[\xi(R_j \geq R_i|j, j) + \xi(R_j \geq R_i|j, i)] + \eta_i\xi(R_j > R_i|i, j) - \eta_j\xi(R_i > R_j|j, i). \quad (4.16)$$

As Equações 4.15 e 4.16 mostram que o comportamento baseado em registros de memória destaca a estratégia que consegue manter seu registrador respectivo maior que o outro registrador, assumindo que as proporções $\eta_i, \eta_j \neq 0$. Para isso, a soma acumulada relacionada a estratégia vencedora deve ser maior que a soma da outra estratégia - porém ambas dependem tanto da taxa de encontros com outros agentes e dos *payoffs* recebidos. Por exemplo, se um agente j transformou-se em i em um k -ésimo *step*, então a seguinte inequação é válida:

$$R_i^{k-1} > R_j^{k-1} \rightarrow \sum_{s=0}^{k-1} R_i^s > \sum_{s=0}^{k-1} R_j^s \rightarrow$$

$$\alpha_0 \eta_{i,0} u(i, i) + \beta_0 \eta_{j,0} u(i, j) + \dots + \alpha_{k-1} \eta_{i,k-1} u(i, i) + \beta_{k-1} \eta_{j,k-1} u(i, j) >$$

$$\gamma_0 \eta_{i,0} u(j, i) + \delta_0 \eta_{j,0} u(j, j) + \dots + \gamma_{k-1} \eta_{i,k-1} u(j, i) + \delta_{k-1} \eta_{j,k-1} u(j, j).$$

Essa inequação sugere que $\alpha, \beta, \gamma, \delta, \eta_i$ e η_j podem possuir um valor diferente para cada *step*. Apesar disso, o jogo definido no sistema de regras do modelo de interação não muda uma vez que é definido - logo os *payoffs* também não mudam. Isso significa que os valores α, β, γ e δ são o maior fator variável de influência de η_i e η_j . Sob outra perspectiva, η_i e η_j também influenciam indiretamente α, β, γ e δ e variam ao longo dos *steps* de simulação do STAIP.

Admitindo que o jogo em questão é tal que i é um perfil estratégico equivalente a cooperar e j é equivalente a trair, podemos aproveitar a parametrização R, S, T, P introduzida na Seção 2.3.3 para caracterizá-lo. Assim, algumas conclusões podem ser obtidas a respeito da dinâmica da população:

- Se $u(i, i) > u(j, i)$ com $D_g < 0$; ou $u(i, i) = u(j, i)$ com $D_g = 0$ e $u(i, j) > u(j, j)$ com D_r , então os agentes não tem incentivo para desviar da estratégia cooperativa i . Por causa disso, $R_i > R_j$ permanecerá válido independentemente das taxas de encontro dos agentes. Essa é uma situação de ausência de dilema, em que toda a população caminha para um objetivo cooperativo de forma trivial;
- No entanto, considere que $u(i, i) < u(j, i)$ com $D_g > 0$; ou $u(i, i) \leq u(j, i)$ e $u(i, j) < u(j, j)$, com $D_g \geq 0$ e $D_r < 0$. Se $\sum_{y=c}^d \alpha_y > \sum_{y=c}^d \gamma_y$ com $D_g < 0$; ou $\sum_{y=c}^d \alpha_y \approx \sum_{y=c}^d \gamma_y$ com $D_g \approx 0$ e $\sum_{y=c}^d \beta_y > \sum_{y=c}^d \delta_y$ com $D_r < 0$, com $c, d \in 0, \dots, n-1$ para um grupo de agentes i , pode existir uma área do espaço em que encontros cooperativos tornaram-se preferíveis ao longo dos *steps*. Mesmo em um jogo em que exista dilema, agentes que possuem *payoffs* positivos entre si podem ter se aproximado pela movimentação no espaço e criado um conjunto de agentes cooperativos, criando um espaço em que não há exploração de outra estratégia sobre a outra.
- Dentro das mesmas premissas de *payoffs* do item anterior, se $\sum_{y=c}^d \alpha_y < \sum_{y=c}^d \gamma_y$ com $D_g > 0$; ou $\sum_{y=c}^d \alpha_y \approx \sum_{y=c}^d \gamma_y$ com $D_g \approx 0$ e $\sum_{y=c}^d \beta_y < \sum_{y=c}^d \delta_y$ com $D_r > 0$, com $c, d \in 0, \dots, n-1$, há uma preferência pela estratégia j . Essa situação pode ser explicada pelo subarquétipo Dilema do Prisioneiro (Seção 2.3.3), na ocasião em que um grupo invasor de agentes j encontrou uma área dominada por agentes i . Então, agentes j são motivados a explorar i , aumentando o valor de seus registradores R_j . Essa condição pode ser temporária, uma vez que os registradores R_i dos agentes i tenderão a diminuir devido à exploração dos agentes j , transformando-os em agentes j também;
- Outra possibilidade é que $\alpha_k \eta_{i,k} u(i, i) > \gamma_k \eta_{i,k} u(j, i)$ ou $\beta_k \eta_{j,k} u(i, j) > \delta_k \eta_{j,k} u(j, j)$ com $D_g < 0$ e $D_r < 0$ ou $D_g \geq 0$ e $D_r < 0$ para algum $k \in \{0, \dots, n-1\}$. então uma estabilidade foi percebida favorecendo i no k -ésimo *step*. Os parâmetros $D_g < 0$ e

$D_r < 0$ sugerem uma ausência de dilema, enquanto $D_g \geq 0$ and $D_r > 0$ sugere o subarquétipo *Stag Hunt*;

- Por fim, caso $\alpha_k \eta_{i,k} u(i, i) < \gamma_k \eta_{i,k} u(j, i)$ or $\beta_k \eta_{j,k} u(i, j) < \delta_k \eta_{j,k} u(j, j)$ with $D_g > 0$ or $D_r > 0$ para algum $k \in \{0, \dots, n-1\}$, então há estabilidade para agentes j , porém dentro do subarquétipo Dilema dos Prisioneiros.

Essas condições e consequência demonstram que a localização dos agentes é tão importante quanto o sistema de regras definido no modelo de interação, pois influenciam a evolução da população. Uma vez que no STAIP os perfis estratégicos estão ligados à quantidade de créditos de exploração possíveis por *step*, então o sistema de decisão e o sistema de regras pode influenciar em como o espaço será explorado.

4.1.5 Política Pública

A Política Pública é um conjunto de regras que afeta a população de agentes independentemente do seu perfil estratégico. Essas regras são representadas por polígonos no espaço, em que cada polígono afeta a atratividade das células contidas em sua área. Dessa forma, qualquer agente que considerar uma nova área com base na matriz proximal também deve considerar as mudanças de atratividade feitas pelos polígonos da Política Pública - ambos direcionam ou proibem espaços disponíveis para a exploração. A política pública é facultativa ao usuário. Caso o usuário não deseje implementá-la, ele pode considerá-la nula. Neste caso, os agentes serão guiados apenas pela matriz proximal.

4.2 Simulador

Projetar e implementar uma ferramenta de simulação em LUCC é uma tarefa complexa, uma vez que modelos de transformação do meio ambiente possuem processos além dos diretamente envolvidos em fenômenos de uso e transformação do solo. Em especial, processos relativos à sociedade humana são ainda mais complexos pela manifestação de propriedades emergentes causadas por uma miríade de motivos. Assim sendo, estudiosos em modelagem e simulação utilizam de técnicas diversas na tentativa de melhor compreender sistemas dinâmicos ligados à transformação do meio ambiente.

Conforme apresentado na Seção 1.3, o MASE-EGTI é a ferramenta utilizada para o apoio à validação tanto do modelo STAIP (Seção 4.1), quanto especificamente do modelo de interação (Seção 4.1.4). Nesta Seção, o MASE-EGTI será brevemente caracterizado quanto a arquitetura e detalhes relevantes de implementação para a compreensão deste projeto.

4.2.1 Arquitetura

O MASE-EGTI possui uma arquitetura de três níveis - Usuário, Controle e Simulação (Figura 4.4). Por meio da camada do usuário, o utilizador pode configurar modelos STAIP e processá-los por meio da interface gráfica (*GUI Interface*, Figura 4.5) - em que há a demonstração visual da simulação em tempo de execução - ou pela linha de comando, em que é possível configurar a execução contínua de várias rodadas do mesmo modelo.

Tal funcionalidade é importante para a realização de estatísticas de resultados gerados pelas simulações.

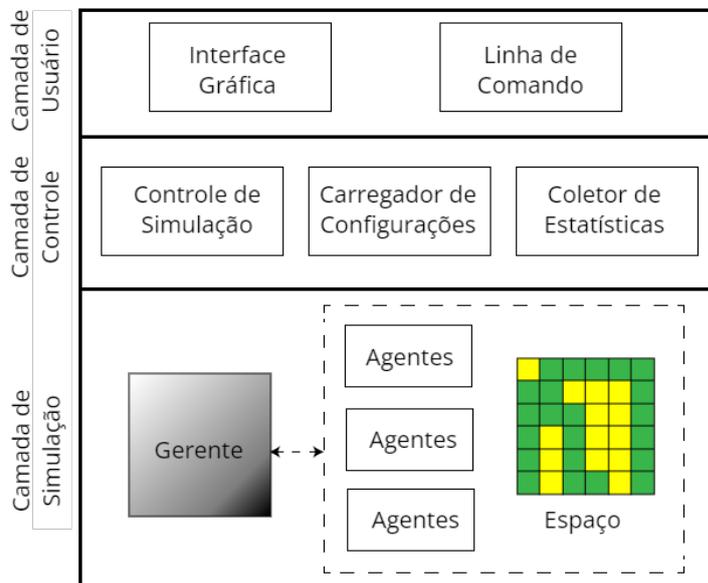


Figura 4.4: A visão geral da arquitetura do MASE-EGTI. Fonte: elaborado pelo autor (2020).

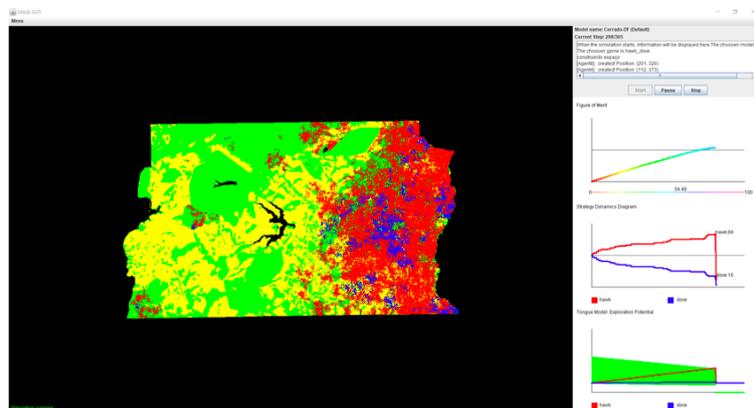


Figura 4.5: A interface gráfica do MASE-EGTI com uma simulação em execução. Fonte: elaborado pelo autor (2020).

A camada de controle possui os módulos que administram a execução da simulação. O carregador de configurações (*Config Loader*) é o módulo responsável pela interpretação do modelo e a instanciação física de seus objetos. Nesse módulo são obtidas a imagem do espaço inicial do modelo, a quantidade de *steps*, a quantidade de agentes e outras propriedades descritas na Seção 4.1. O controle de simulação é responsável pela instanciação da simulação com base nas informações obtidas pelo módulo de carregamento das configurações. O controle de simulação também traz funcionalidades úteis para que os agentes consigam realizar sua administração de conflitos com base no sistema de decisão definido.

Ainda na camada de controle, o módulo de estatísticas (*Stats Collector*) registra atributos relacionados ao espaço e aos agentes de simulação, para a produção de resultados de simulação listados na Tabela 4.5.

Tabela 4.5: Resultados sintetizados módulo de estatística do MASE-EGTI.

Resultado	Descrição
Imagem do espaço final simulado	Representação do espaço final simulado de acordo com as cores das classes de células e da exploração dos agentes definidos no STAIP
Quantidade de espaços explorados por classe de exploração	Quantidade de células de floresta original ou de espaço antropizado explorado por agentes de diferentes classes de exploração
Tempo de simulação	Tempo entre o <i>step</i> inicial até o fim do último ou então até a quantidade de recursos espaciais disponíveis acabarem.
Quantidade de mensagens	Quantidade de mensagens trocadas entre os agentes por <i>step</i> .
Quantidade de agentes por perfil estratégico	Contagem de agentes agrupados pelos perfis estratégicos por <i>step</i> .
<i>Payoff</i> médio	<i>Payoff</i> calculado dinamicamente de acordo com a quantidade de agentes por perfil estratégico.

Por fim, na camada de simulação (*Simulation Layer*) residem os agentes e os objetos compartilhados entre eles. Há a presença de um agente gerente (*Manager*) que é instanciado apenas quando o sistema de decisão do modelo de interação é centralizado (conforme Seção 4.1.4). Como frisado anteriormente, o gerente não possui acesso aos recursos espaciais nem explora as células, mas possui registros de onde os agentes estão localizados e que células estão disponíveis ou sendo utilizadas. Os agentes, também residentes dessa camada, tem quatro capacidades básicas e possuem acesso ao espaço e outras variáveis comuns auxiliares (Seção 4.1.3).

4.2.2 Implementação

MASE-EGTI, assim como sua versão antecessora MASE-BDI, foi contruído com em linguagem Java 8 com a utilização do framework JADEX 2.4 ([9]) para o suporte do raciocínio BDI em seus agentes. É notável nesse modelo cognitivo que o agente possui dois grandes módulos: o Interpretador de raciocínio prático, capaz de deliberar objetivos e selecionar planos, e o Módulo BDI em si, que inclui as crenças, objetivos e planos do agente (Figura 4.6, traduzido de [9]). Ainda nesse modelo cognitivo, eventos são responsáveis pela ativação do módulo de raciocínio meios-fim, que escolhe um novo plano de ações ou executa o próximo passo de um plano já escolhido. Mensagens e trocas de estado ou de atributos são os principais geradores de novos eventos em um agente.

Interação dos Agentes

Aperfeiçoamentos realizados na versão anterior MASE-BDI para a versão atual MASE-EGTI incluem dois grandes tópicos: arquitetura (já abordada na Seção 4.2.1) e modelo de interação. No modelo de interação, a evolução da comunicação entre os agentes e a criação

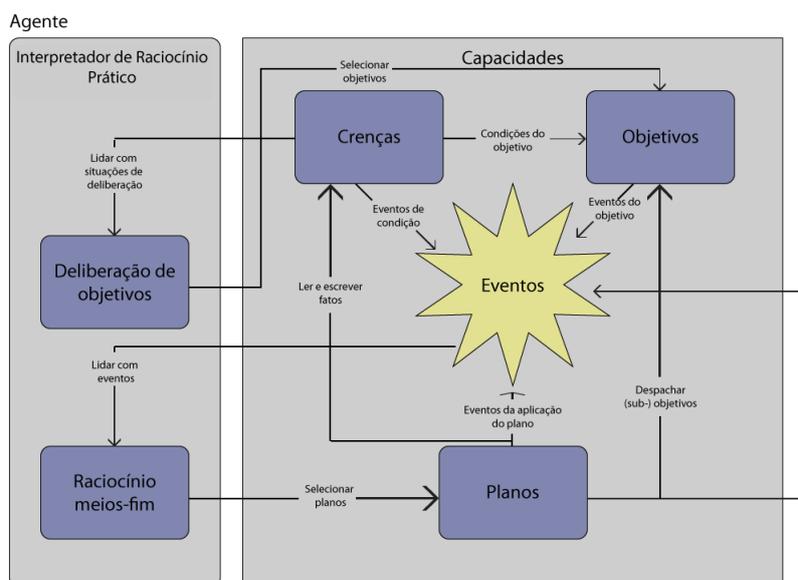


Figura 4.6: A representação de um agente BDI implementado com o *framework* JADEX. Fonte: Braubach e Pokahr (2011) [9]. Traduzido pelo autor.

de uma classe para a implementação de regras baseadas em jogos foram fundamentais para o funcionamento tanto do sistema de decisão quanto para o sistema de regras.

Agentes no MASE-BDI eram necessariamente ligados a gerentes que controlavam tanto o espaço quanto os agentes em si, distribuindo recursos espaciais e resolvendo conflitos, respectivamente [11]. Sendo assim, sua única comunicação era estabelecida com esses gerentes, que eram responsáveis pela orquestração do SMA, tornando os agentes menos autônomos. Isso é relevante, uma vez que a emergência da cooperação (Capítulo 1, Seção 1.2) é condicionada à participação de gerentes alheios ao processo direto de transformação do espaço. No MASE-EGTI, o usuário tem a opção de configurar o STAIP com um sistema de interação com decisão centralizada ou distribuída para a resolução de conflitos espaciais (Figura 4.7).

Deliberação Centralizada

No MASE-EGTI, o sistema de decisão centralizado foi implementado para comparação com o sistema de deliberação distribuído. Ele é uma implementação sumarizada do esquema de resolução de conflitos do MASE-BDI, uma vez que usa apenas um gerente. Esse único gerente possui uma única capacidade: Gerenciar conflito.

Em Gerenciar Conflitos há o Objetivo contínuo “Administrar espaço” com os planos “Receber mensagem”, “Alocar recurso”, “Registrar Término” e “Responder agente”. As crenças associadas são três vetores de valores: fila de mensagens, registro do espaço e registro de agentes. Ao início da simulação, o gerente recebe uma cópia do espaço compartilhado para si, que é armazenado em sua crença de registro de espaço, e verifica o número de agentes na simulação, para reservar um espaço para cada um no vetor de valores registro de agentes. A cada início de *step*, o gerente assume o objetivo “Administrar espaço” e espera mensagens dos agentes.

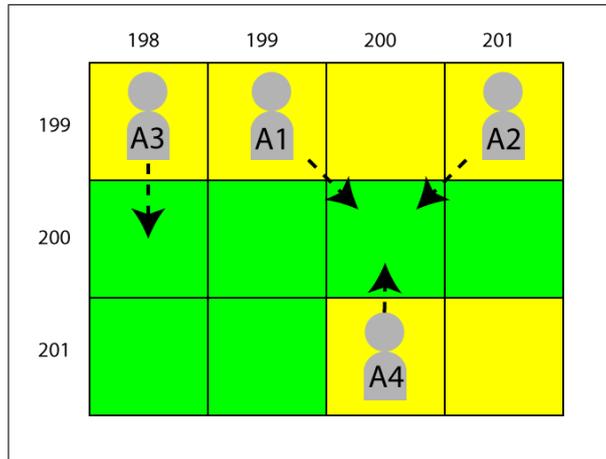


Figura 4.7: Amostra do espaço em que quatro agentes coincidentemente desejam trocar de célula. Enquanto o agente 3 (A3) não tem concorrentes, agentes 1, 2 e 4 (A1, A2 e A4) terão que resolver seus conflitos por meio do gerente ou entre si, de acordo com o sistema de decisão definido. Fonte: elaborado pelo autor (2021).

Se alguns agentes terminaram seus objetivos principais sem a necessidade de se mudar, eles enviam uma mensagem informando seus *ids* e que terminaram suas execuções para o *step* para o gerente. O gerente então atualiza sua crença de registro de agentes a cada mensagem de término, inserindo em seus lugares um registro de término. Caso agentes precisem se mudar, eles enviam mensagens com seus *ids* e a posição da célula que eles possuem intenção de mudança. O gerente então recebe as mensagens de agentes e verifica no espaço se a célula já está ocupada ou não. Se não, ele confirma a concessão do espaço respondendo a mensagem do agente. Se sim, ele nega a célula, também por meio de uma resposta à mensagem (Figura 4.8).

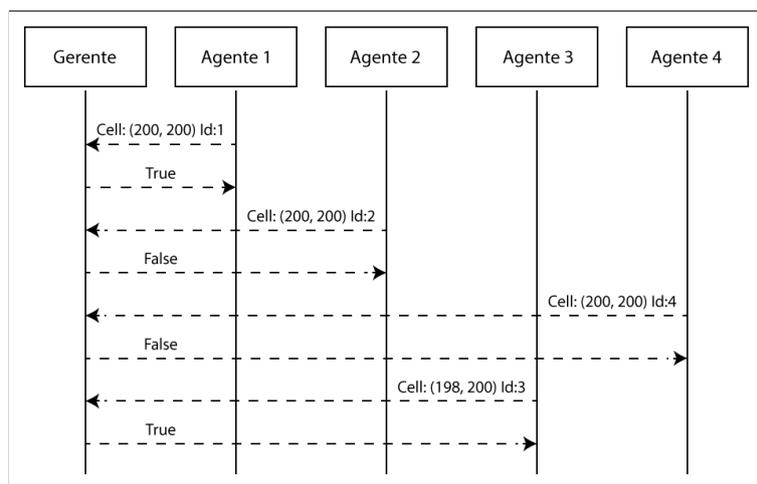


Figura 4.8: Um exemplo de troca de mensagens entre quatro agentes e o gerente, baseado nas intenções de mudança registradas na Figura 4.7. Fonte: elaborado pelo autor (2021).

Os agentes quando estão decidindo para que célula se mudar conseguem perceber se uma célula da vizinhança já possui proprietário, excluindo-a caso positivo. Sendo assim,

questiona-se: por que o agente precisa averiguar com o gerente se ela ainda está disponível antes de efetivamente mover-se? Isso é necessário porque agentes não são capazes de perceber se outros agentes ao redor também estão considerando uma célula em comum entre suas vizinhanças para a mudança. Se ambos se moverem sem consultar antes se a célula permaneceu vazia entre os momentos de verificação, decisão e mudança, a simulação pode permitir um estado inválido em que dois agentes ocupam o mesmo recurso espacial indivisível ao mesmo tempo. O gerente então se encarrega de conceder ou negar recursos, evitando inconsistências.

Deliberação Distribuída

A deliberação distribuída utiliza a fila de interesse das células para o registro de intenções dos agentes que desejam mudar-se a elas. Como já apresentado na Seção 4.1.4, há dois tipos de deliberação distribuída - FTA e SNG. Além disso, não há a presença de um gerente de simulação - os agentes deliberam quem é o vencedor da célula sozinhos. Para que a implementação da deliberação distribuída deste trabalho seja possível, algumas premissas devem ser assumidas:

- Agentes possuem um *id* único e ordenável;
- O número de agentes não muda ao longo da simulação;
- Agentes são benevolentes e capazes de se comunicar em um meio sem perdas de mensagens;
- Células podem ser acessadas por potencialmente qualquer agente da simulação. No entanto, os agentes possuem um alcance limitado à sua percepção de vizinhança.
- Uma célula só pode ser explorada pelo seu proprietário. Uma célula que não possui proprietário não pode ser explorada até que um agente torne-se seu proprietário.
- Células possuem um sistema de acesso à sua lista de intenção que só permite a escrita de um valor por vez e que só permite a exclusão de um valor pelo autor da escrita. Além disso, só um agente de cada vez pode escrever e deletar nessa lista, mantendo-a sempre consistente.

A linguagem Java, utilizada para a implementação do MASE-EGTI, possui mecanismos de sincronização que permitem que apenas uma *thread* acesse um trecho de código por vez. Enquanto uma *thread* entra na área protegida de acesso exclusivamente, as outras esperam pela sua vez até que a área seja liberada. Como agentes são construídos com base em *threads* para que possam executar autonomamente, esses mecanismos se aplicam a eles. A implementação de FTA então torna-se bastante simples sob essas premissas - o primeiro agente que entrar na área protegida de escrita em que a lista de interesse da célula se encontra ganha o recurso. Por isso todos os agentes envolvidos checam quem deles realmente foi o primeiro a escrever, para fins de averiguação.

A implementação de SNG é mais complexa, pois envolve tanto a escrita da intenção na lista da célula quanto espera por todos os agentes que precisam se movimentar registrarem suas intenções, e por fim a troca de mensagem entre os envolvidos para a resolução do conflito. Um registrador auxiliar acessível a todos os agentes é disponibilizado pelo módulo

de controle de simulação - nele, todos os agentes que precisam se mudar registram essa condição. Em seguida, eles escolhem a célula, registram a intenção na lista utilizando o mecanismo de controle e esperam (*stop*) para que todos os agentes façam o mesmo. Uma vez que todos realizaram essa etapa, eles percebem que o registrador auxiliar de agentes que precisam se mover está completo com as intenções registradas e saem do estado de espera (*go*), partindo para o momento de resolução de conflito.

Agentes então verificam a lista de interesse da célula que desejam. Se seus *ids* forem os únicos nas listas das suas células intencionadas, não há conflito e eles tornam-se proprietários delas. Se não, o primeiro agente a registrar sua intenção inicia a conversação com o segundo enviando uma mensagem que contém seu *id*, seu perfil estratégico e seu número de desempate aleatoriamente gerado pela função *Math.random()* de Java, conforme mostrado na Seção 4.1.4. O segundo agente calcula o ganhador da disputa comparando os *payoffs* dos perfis estratégicos e as regras do jogo, e envia uma mensagem para o primeiro agente indicando quem é o vencedor e quem é o perdedor. O perdedor remove seu registro da lista de interesse e o ganhador inicia a conversação com o terceiro agente se ele existir, até que apenas um agente permaneça na lista de interesse como vencedor.

Neste capítulo foi apresentado a proposta do modelo de interação para simulações de uso e cobertura da terra. O modelo é composto por um sistema de decisão e outro de regras, os quais podem possuir desdobramentos complexos por meio de regras simples. No Capítulo 5, o modelo será verificado através de experimentos com uma discussão que reúne os conceitos fundamentais, a proposta e os resultados alcançados.

Capítulo 5

Caso de Uso

Neste capítulo, introduz-se o Cerrado-Mapbiomas, sendo este um MBA em LUCC utilizado para a validação do modelo de interação proposto neste trabalho (Capítulo 4, Seção 4.1.4). Para isso, utiliza-se o protocolo *Overview, Design and Details* (ODD), introduzido por Grimm et al. (2006) [33], que possuiu atualizações em 2010 [34] e 2020 [35]. O ODD é bastante utilizado na caracterização de modelos em MBA, especialmente em trabalhos envolvendo a área de Ecologia de Paisagens e LUCC [35]. Por isso, ele foi empregado na caracterização do modelo de validação deste trabalho.

Adicionalmente, foram definidos submodelos variantes do Cerrado Mapbiomas, e executou-se diversas rodadas de experimentações para a V&V modelo de interação. Os resultados experimentais são descritos neste Capítulo. A seguir, uma breve discussão realiza uma reflexão sobre os resultados alcançados, fechando este capítulo.

5.1 Caracterização do Modelo

Esta seção apresenta a descrição ODD do modelo Cerrado-MapBiomas, incluindo a visão geral (*Overview*), os conceitos de projeto (*Design Concepts*) e detalhes (*Details*), conforme caracterização apresentada na Tabela 5.1 [35]. O STAIP do Cerrado-MapBiomas é incluso nesta seção como Visão Geral na Seção 5.1.1, no tópico Entidades, no subtópico Variáveis de Estado e Escalas.

Como já mencionado, foram implementados submodelos neste modelo. O modelo Cerrado Mapbiomas base é definido com o modelo de interação com sistema de decisão centralizado e sem sistema de regras. Por outro lado, seus submodelos apresentam variações, implementando o sistema de decisão distribuído e o sistema de regras baseado em dois jogos de TJ/TJE.

5.1.1 Visão Geral

Cerrado-MapBiomas é um aperfeiçoamento do modelo Cerrado-DF que foi utilizado para validar o MASE e o MASE-BDI [11, 56]; Sua característica principal é o uso de imagens *raster* provenientes da coleção 4 de dados do Projeto de Mapeamento de Uso e Cobertura da Terra no Brasil (MapBiomas) [67]. Essas imagens foram utilizadas para caracterização do espaço e dos atributos espaciais no lugar das imagens de satélite do IBAMA utilizadas

no Cerrado-DF. Além disso, a coleção 4 do MapBiomias contempla um período maior de dados, de 2000 a 2018, em vez de 2002 a 2007 no modelo anterior.

Tabela 5.1: A visão geral do protocolo ODD. Fonte: Grimm et al. (2020) [35]. Traduzido e adaptado pelo autor.

Visão Geral	1. Propósito e padrões
	2. Entidades, variáveis de estado e escalas
	3. Visão geral do processo e agendamento 3.1. Submodelo A 3.2 Submodelo B ...
Conceitos de Projeto	4.1. Interação
	4.2. Estocasticidade
	4.3. Emergência
	4.4. Adaptação ...
Detalhes	5. Inicialização
	6. Dados de entrada
	7. Submodelos
	8. Métricas e validação do modelo

Propósito e Padrões

Cerrado-MapBiomias é um modelo que investiga a influência da agricultura no bioma Cerrado localizado no Distrito Federal entre os anos de 2000 e 2018. Esse modelo é empregado para evidenciar os resultados de diferentes modelos de interação entre os agentes agricultores - os quais podem possuir diferentes perfis entre si - buscando os efeitos percebidos nos espaços finais de simulação.

Entidades, Variáveis de Estado e Escalas

Uma vez que o Cerrado-MapBiomias foi desenvolvido para ser executado no MASE-EGTI, Espaço, Tempo, Agents, Interações e Política Pública (variáveis do STAIP) são as principais dimensões do modelo.

Espaço No Cerrado MapBiomias, o espaço é representado pelo bioma Cerrado no Distrito Federal nos anos 2000. A foto de satélite coletada naquele ano do Distrito Federal foi transformada em dado georreferenciado para compor a coleção 4 do MapBiomias, e em seguida foi convertida para uma imagem *raster* cujos pixels representam as células do espaço.

A seguir, a imagem em questão foi configurada para possuir apenas três possíveis estados, a saber: floresta original/mata bruta (representada pela cor verde), espaço antropizado (representado pela cor amarela) e espaço não utilizável (representado por espaços de cores brancas e pretas). Cada classe possui potencial de exploração específico: células de floresta original possuem 1500 de potencial de exploração; espaço antropizados, 500; espaços não utilizáveis, 0.

A matriz proximal é construída a partir de seis atributos espaciais pertencentes ao espaço do Distrito Federal: i)corpos d'água, ii)cursos d'água, iii)rodovias, iv)ferrovias, v)edificações e vi)unidades de conservação. As quatro primeiras variáveis são atrativas e duas últimas são repulsivas. O processo de criação da matrix proximal envolve a transformação das imagens para *grayscale*. A seguir, elas são duplicadas, e cada pixel das cópias é diminuído de 255 e multiplicado por -1 se o valor obtido for negativo - assim gerando a inversão da imagem. Depois desse processo de inversão, cada uma das cópias é borrada com a aplicação de um filtro gaussiano, que dispersa os pixels que definem o atributo, criando um gradiente de pixels cinzentos em volta de um conjunto de pixels brancos. Cada cópia então tem então seus valores diminuídos da imagem original, assim excluindo os valores de pixel de conjuntos de pixels brancos. Esse processo cria uma imagem resultante que possui pixels ao redor dos atributos proximais, que ficam cada vez mais claro o mais próximo é do atributo em si. Ao final, as imagens resultantes são somadas, se o atributo for atrativo, ou diminuídas, se repulsivo, criando uma matriz de valores proximais denominado matriz proximal (Figura 5.1).

Como já explicado na Seção 4.1.3 no Capítulo 4, os agentes usam a matriz proximal para calcular qual a próxima célula que eles terão de intenção de se mover quando acabarem os recursos em suas células atuais e eles ainda possuírem créditos de exploração. O cálculo desse modelo envolve uma vizinhança maior que as oito células conectadas ao redor da célula atual - ela considera um formato losangular considerando 3 células para cima, para abaixo e aos lados da célula em questão.

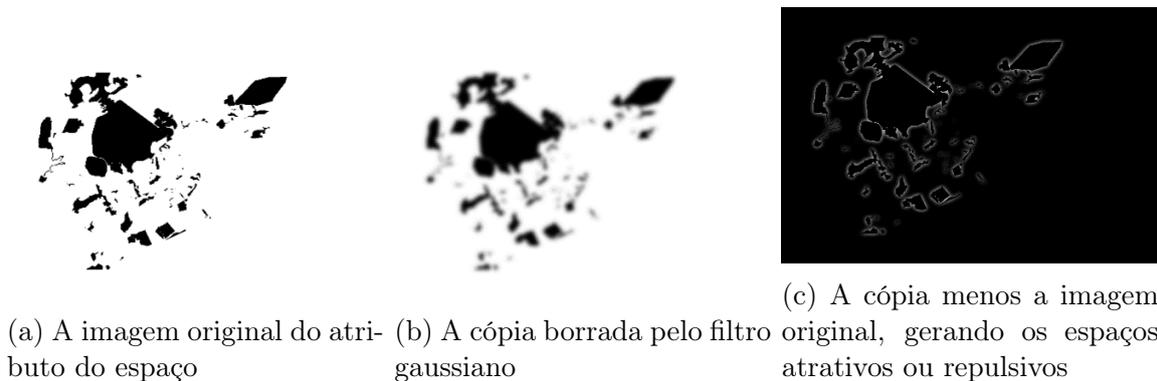


Figura 5.1: Os estágios de formação da matriz proximal. Fonte: elaborado pelo autor (2021).

Tempo O tempo é representado por 1000 *steps* de simulação, os quais os agentes devem consumir todo o crédito de exploração que lhes foi concedido a cada *step*. Conforme a descrição da Seção 4.1.3, ao início do *step* o crédito é renovado para que os agentes possam executar seu objetivo principal novamente.

Agentes Agentes podem pertencer a uma das duas classes de exploração: agricultor de grande porte ou agricultor de subsistência. Agricultores de grande porte possuem 1500 de crédito de exploração e são representados no espaço pela cor laranja; já agricultores de subsistência possuem 500 de crédito de exploração e são representados pela cor azul. Agricultores de grande porte possuem recursos e força suficiente para conquistar espaço

de agricultores menores. Por isso agricultores de grande porte são configurados com um perfil estratégico agressivo ou combativo, enquanto os de subsistência são pacíficos e cooperativos. Agentes neste modelo não se reproduzem nem morrem, e não imigram nem emigram. Sendo assim, seu número definido na inicialização (Seção 5.1.3) não muda ao longo da simulação.

Modelo de Interação Para fins de comparação, o modelo de interação foi construído com o sistema de decisão centralizado e sem sistema de regras. Foram gerados submodelos que serão explorados dentro do tópico submodelos, na Seção Detalhes (Seção 5.1.3).

Política Pública A política pública determinada foi o Plano Diretor de Ordenamento Territorial do Distrito Federal (PDOT) de 2006 [29]. Ela é representada pela Figura 5.2 que possui três polígonos: vermelho, que correspondente à área onde a exploração da terra é proibida; azul, onde a exploração é permitida; e verde, onde ela é incentivada. Sendo assim, esses valores são combinados com os valores da matriz proximal da seguinte forma: nos espaços vermelhos, a matriz possui seus valores configurados para -1, impossibilitando a movimentação dos agentes; nos azuis, os valores da matriz proximal são mantidos; nos verdes, eles são multiplicados por 1.1, aumentando a atração em 10%.



Figura 5.2: A política pública do PDOT. Fonte: Secretaria de Habitação, Regularização e Desenvolvimento Urbano do Distrito Federal (2009) [29]. Adaptado pelo autor.

Visão Geral do Processo e Agendamento

O modelo começa sua execução com o pré-processamento da suas variáveis e a criação dos objetos de espaço e matriz proximal, dentre outros recursos compartilhados. Os agentes são então instanciados, com metade deles configurados para serem da classe de agricultores de grande porte, com crédito de exploração 1500 e perfil agressivo, e a outra metade como agricultores de pequeno porte, com crédito de 500 e perfil pacífico. Os agentes são então posicionados arbitrariamente no espaço nas posições mais atrativas da matriz proximal. Como este modelo-base possui sistema de decisão centralizado, o agente gerente é instanciado assim como os outros agentes da simulação, e recebe uma cópia do espaço e a quantidade de agentes, bem como onde eles estão posicionados.

Após essa etapa inicial, o Controle de Simulação abre o primeiro *step*. Os agentes exploram seus espaços e, se conseguem gastar todo o seu crédito de exploração, eles informam ao gerente que concluíram seus objetivos e estão esperando pelo próximo passo de simulação. Caso precisem se mudar, eles analisam a vizinhança e informam o gerente qual o espaço que desejam se mudar. O gerente processa as informações em sequência e concede ou nega espaços de acordo com sua administração interna. Agente continuam explorando e mudando de célula até conseguirem todos terminar seus objetivos. O *step* então finalizado, e o módulo Estatístico registra as variáveis observadas para compor os resultados. Um novo *step* é aberto pelo Controle de Simulação. Esse ciclo continua até que 1000 *steps* sejam atingidos, ou os espaços disponíveis acabem.

Ao final de todos os *steps*, os objetos são destruídos e o módulo estatístico gera a imagem final simulada, bem como um arquivo .CSV com os resultados observados por *step*. A simulação então termina.

5.1.2 Conceitos de Projeto

Dentro da lista de conceitos sugeridos por Grimm et al. (2006) [33], interação, estocasticidade, emergência e adaptação são os mais relevantes para este modelo. Eles são apresentados a seguir.

Interação Células podem ser ocupadas e exploradas por um agente por vez. Além disso, agentes não são capazes de prever qual é o próximo movimento dos agentes ao redor. Por esse motivo, eles devem se comunicar com uma entidade fora do conflito (o gerente) ou entre si (submodelos com decisão distribuída) para decidir quem será o proprietário de uma célula livre.

Estocasticidade Agentes movimentam-se de maneira estocástica, e por isso suas células escolhidas e seus conflitos também são inerentemente fortuitos. A matriz proximal provê uma indicação de lugares onde conflitos são mais propensos a ocorrer, mas ainda assim ela age apenas como um guia de lugares mais ou menos prováveis para movimentação.

Emergência O modelo de interação depende de quais agentes serão envolvidos e das regras estabelecidas por um jogo, e os agentes possuem suas estratégias atreladas ao potencial de explorar mais ou menos o espaço. Esses dois fatores podem produzir diferentes espaços de simulação final, dependendo não apenas da movimentação dos agentes - que é estocástica, como já mencionado - mas da interação dos agentes - necessária para a resolução de conflitos por espaço.

Adaptação Nos submodelos deste modelo os agentes podem trocar de estratégia de acordo com regras específicas após conflitos por recursos. Isso influencia em como a sociedade irá se configurar ao longo dos *steps* de simulação.

5.1.3 Detalhes

Inicialização

Como já visto na Seção 5.1.1, há uma etapa de pré-processamento e uma etapa de criação da simulação que envolve o pré-processamento das variáveis do modelo e a criação dos agentes. Além disso, os agentes são alocados nas células mais atrativas do espaço e possuem seus créditos de exploração renovados a cada *step*. Como agentes possuem diferentes créditos de exploração atrelados às suas classes de exploração, alguns podem precisar se mover mais vezes que outros para cumprirem seus objetivos principais.

Dados de entrada

Os dados de entrada são:

- Espaço: Imagem de entrada (Figura 5.3) proveniente da versão 4 da coleção Cerrado do MapBiomas, processada em quatro cores: amarelo, verde, preto e branco. Elas correspondem respectivamente ao espaço antropizado, floresta original, espaço inutilizável e bordas da imagem (também inutilizáveis); Imagens dos atributos do espaço atrativos - corpos d'água, cursos d'água, rodovias e ferrovias; e imagens dos atributos do espaço repulsivos - espaços urbanos e unidades de conservação (Figura 5.4).
- Tempo: 1000 steps de simulação;
- Agentes: 300 agentes, com 150 pertencendo à classe de exploração de agricultores de grande porte e 150 pertencendo a agricultores de subsistência;
- Modelo de Interação: Modelo centralizado;
- Política pública: Imagem do PDOT com a classe vermelha configurando a matriz proximal para -1 e a classe verde multiplicando os valores por 1.1.

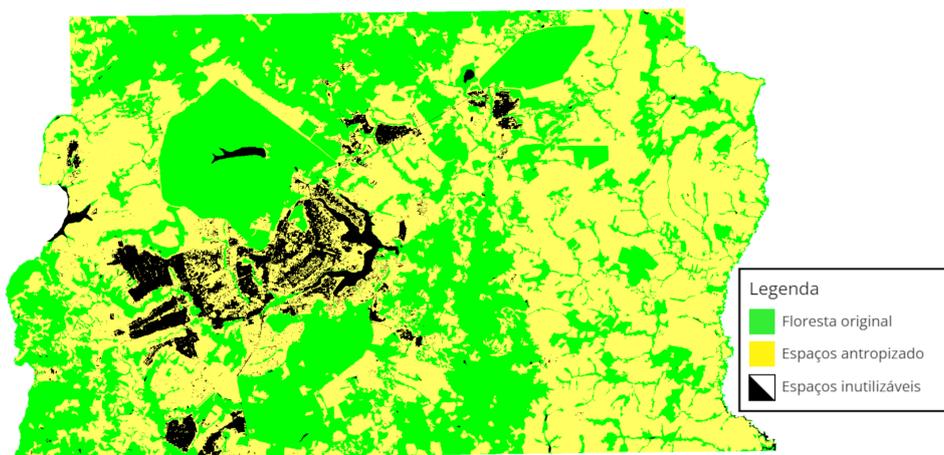


Figura 5.3: O espaço inicial do modelo. Fonte: Souza et al. (2020) [67]. Adaptado pelo autor.

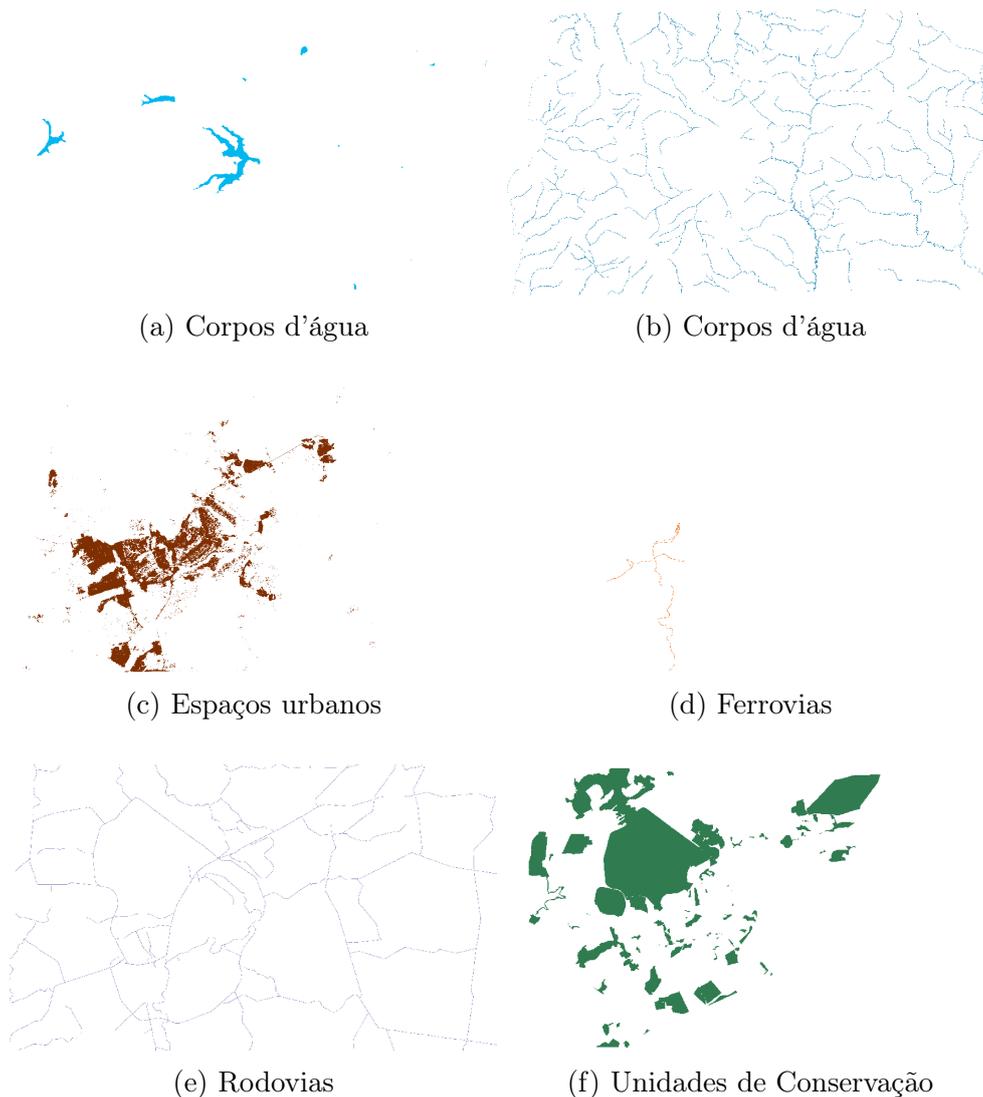


Figura 5.4: Os atributos proximais do modelo. Fonte: Souza et al. (2020) [67]. Adaptado pelo autor.

Submodelos

Submodelos nesse modelo foram projetados como variações do modelo de interação. Eles sobrescrevem o modelo de decisão centralizado e o modelo de regras nulo. Além disso, há a opção dos agentes acessarem sua capacidade de trocar de estratégia, evoluindo a configuração da sociedade, ou não, mantendo a distribuição inicial de 50%/50%. Os submodelos então são:

1. Modelo de interação com sistema de decisão descentralizado FTA sem sistema de regras;
2. Modelo de interação com sistema de decisão descentralizado SNG, com jogo Hawk-Dove como sistema de regras e sem troca de estratégia;
3. Modelo de interação com sistema de decisão descentralizado SNG, com jogo Dilema dos Prisioneiros como sistema de regras e sem troca de estratégia;

4. Modelo de interação com sistema de decisão descentralizado SNG, com jogo Hawk-Dove como sistema de regras e com troca de estratégia por comportamento reativo;
5. Modelo de interação com sistema de decisão descentralizado SNG, com jogo Hawk-Dove como sistema de regras e com troca de estratégia por comportamento baseado em registros de memória;
6. Modelo de interação com sistema de decisão descentralizado SNG, com jogo Dilema dos Prisioneiros como sistema de regras e com troca de estratégia por comportamento reativo;
7. Modelo de interação com sistema de decisão descentralizado SNG, com jogo Dilema dos Prisioneiros como sistema de regras e com troca de estratégia por comportamento em registros de memória;

Para os *payoffs* dos jogos utilizados nos submodelos 2 a 7, as Tabelas 5.2a e 5.2b mostram os possíveis *payoffs* das interações dos agentes.

Tabela 5.2: *Payoffs* utilizados para os jogos de Dilema dos Prisioneiros e *hawk-dove*

		Jogador β				Jogador β	
		<i>trair</i>	<i>cooperar</i>			<i>hawk</i>	<i>dove</i>
Jogador α	<i>trair</i>	(-8, -8)	(0, -10)	Jogador α	<i>hawk</i>	(-1, -1)	(2, 0)
	<i>cooperar</i>	(-10, 0)	(-1, -1)		<i>dove</i>	(0, 2)	(1, 1)

Por causa dessas variações, o dado de entrada “Modelo de Interação” foi adaptado para cada um dos submodelos listados. Agentes tiveram suas classes de exploração ligadas a um perfil estratégico para resolução de conflitos de acordo com o seguinte mapeamento:

- Agricultor de grande porte \rightarrow *hawk* (submodelos 2, 4, 6)
- Agricultor de subsistência \rightarrow *dove* (submodelos 2, 4, 6)
- Agricultor de grande porte \rightarrow *trair* (submodelos 3, 5, 7)
- Agricultor de subsistência \rightarrow *cooperar* (submodelos 3, 5, 7)

Outros dados de entrada como espaço, tempo e política pública mantiveram-se iguais aos definidos no modelo base.

Métricas e Validação do Modelo

As métricas utilizadas para a avaliação do modelo são intencionalmente selecionadas para a comparação entre o modelo-base, com sistema de decisão centralizado, e os submodelos, com sistemas centralizados. Resultados obtidos são gerados pela ferramenta conforme listados na Tabela 4.5 na Seção 4.2.1.

Como o modelo gera uma imagem do espaço final obtido, utilizou-se duas métricas de comparação de imagens: *Root Mean Square Error* (RMSE) [12] e *Structural Similarity*

Index Measurement (SSIM) [39]. De forma geral, o RMSE mensura o desvio padrão dos erros de predição de um conjunto de dados em relação à regressão linear obtida. No contexto de processamento de sinais, RMSE é comumente utilizado para mensurar quão diferentes dois sinais digitais são. Uma vez que imagens digitais são sinais multi-dimensionais, essa métrica pode considerar uma imagem A no lugar da regressão linear e uma imagem B como o conjunto de dados na aplicação dessa métrica. Ainda no contexto de imagens digitais, SSIM investiga a qualidade de uma imagem gerada a partir de um processamento de sinais - tratada ou transmitida por exemplo - em comparação a sua imagem original.

O processo de avaliação do RMSE é feito pixel a pixel entre duas imagens X, Y de mesma largura w e altura h por meio da Equação 5.1. Essa Equação mede a diferença de valores de pixel nas mesmas posições de imagens diferentes. Sendo assim, quanto mais próximo de 0 for o resultado de $RMSE(X, Y)$, menor é a diferença entre elas.

$$RMSE(X, Y) = \sqrt{\frac{1}{wh} \sum_{j=1}^w \sum_{i=1}^h (x_{i,j} - y_{i,j})^2} \quad (5.1)$$

Quanto ao SSIM, a metrificação da qualidade é feita por meio de três componentes: luminância (l , Equação 5.2b), contraste (c , Equação 5.2c) e estrutura (s , Equação 5.2d) entre as janelas deslizantes de duas imagens de tamanho arbitrário a e b . Nas Equações 5.2b, 5.2c e 5.2d as variáveis μ calculam o valor médio dos pixels, enquanto σ calcula a variância dos valores dentro das janelas. As constantes c_1, c_2, c_3 são estabilizadoras para evitar a divisão por zero. A Equação 5.2a então calcula a soma desses valores encontrados potencializados pelas variáveis arbitrárias α, β, γ , que foram todas definidas como 1.

$$SSIM(a, b) = [l(a, b)^\alpha + c(a, b)^\beta + s(a, b)^\gamma] \quad (5.2a)$$

$$l(a, b) = \frac{2\mu_a\mu_b + c_1}{\mu_a^2 + \mu_b^2 + c_1} \quad (5.2b)$$

$$c(a, b) = \frac{2\sigma_a\sigma_b + c_2}{\sigma_a^2 + \sigma_b^2 + c_2} \quad (5.2c)$$

$$s(a, b) = \frac{\sigma_{ab} + c_3}{\sigma_a\sigma_b + c_3} \quad (5.2d)$$

A inclusão de RMSE e SSIM nas métricas desse modelo avalia, respectivamente, o erro e a estrutura geral da imagem final simulada. Assim, é produzido um critério objetivo de crítica entre o formato das áreas exploradas pelos agentes. Assumindo que a imagem gerada pelo modelo-base seja a imagem-base, as métricas utilizadas são aplicadas às imagens dos submodelos para comparação de diferença entre as simulações.

Sob essa perspectiva, Chai et al. (2014) argumenta que o uso de RMSE é relevante porque quanto maior a quantidade de amostras comparadas com a imagem-base, melhor é a distribuição de erros obtida em comparação com o erro médio absoluto [12]. Isso é positivo porque métricas estatísticas devem não apenas medir a performance da imagem simulada, mas também a representação da distribuição de erros. Além disso, RMSE possui uma degradação maior de seu resultado quando há erros grandes na comparação de duas

imagens, assim sublinhando imagens com áreas muito diferentes [12]. Isso é desejável na comparação do modelo-base executado neste projeto com os submodelos, para esclarecer a veracidade da hipótese investigada.

Por outro lado, SSIM possui degradações em sua métrica quando há distorções de contraste, luminância e estrutura, compondo seu índice de similaridade estrutural por meio de três dimensões [39]. Para este trabalho, a dimensão estrutural é a mais importante para a detecção de distorções, pois mostra onde os agentes obtiveram recursos. É estabelecido que o sucesso de uma estratégia sob o contexto das interações definidas pelo STAIP é dado ligado ao sucesso na obtenção de recursos. Sendo assim SSIM demonstra objetivamente se houve variações nas adaptabilidades dos agentes pela análise das imagens obtidas.

Tanto RMSE quanto SSIM não possuem uma dimensão física, mas um valor absoluto que mede a qualidade ou, no caso dos experimentos comparativos realizados nesse trabalho, a similaridade entre duas imagens. RMSE pode variar entre 0, quando as duas imagens são iguais, até potencialmente $+\infty$, quando duas imagens são absolutamente desiguais. Na prática é impossível obter $RMSE \rightarrow \infty$ em um ambiente computacional, então para fins comparativos, quanto mais próximo de zero forem duas imagens, mais similares elas são. SSIM no entanto possui um contradomínio bem definido: $-1 \leq SSIM \leq 1$, em que -1 é o valor de SSIM entre duas imagens totalmente dissimilares e 1 é o valor entre duas imagens iguais.

Também foi avaliado o quanto cada classe de exploração consumiu de espaços de floresta original e espaço antropizado para a aferição de quanto do espaço foi convertido. No entanto, a matriz proximal e o PDOT não apenas guiam a movimentação dos agentes como afetam a competição pelo espaço por meio da atratividade das células. Obteve-se então o mapa das localizações mais atrativas, em que lugares mais próximos de variáveis atrativas ou na área incentivada do PDOT possuíam um valor de pixel maior, enquanto as menos atrativas eram possuíam um valor menor (Figura 5.5a). Com base nesse mapa, classificou-se o espaço com base nos valores mais comuns de atratividade e dividiu-se o espaço nas áreas i) mais valiosas (verdes) ii) regulares (amarelas); e iii) menos valiosas (vermelhas) (Figura 5.5b). Com base nas imagens geradas das simulações, aferiu-se quanto cada classe ocupou áreas por valiosidade.

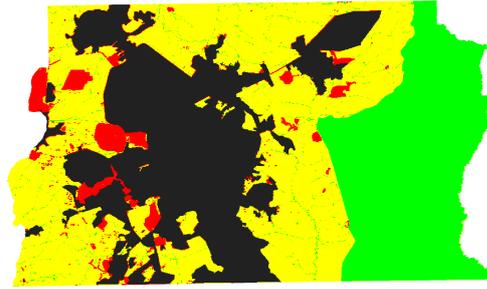
5.2 Resultados Experimentais

Oito rodadas de experimentos foram executadas no total com o modelo Cerrado Mapbio-mas - uma com o modelo-base e as outras sete com os submodelos (Seção 5.1.3) - listados e identificados na Tabela 5.3. Cada rodada envolveu a execução de 20 experimentos com as entradas definidas para o modelo ou submodelos; Seus resultados foram somados e divididos pela quantidade de experimentos, obtendo-se um resultado médio para cada rodada de experimento. Eles são apresentados na Figura 5.6.

Nos espaços finais simulados obtidos dos experimentos com o modelo base e os submodelos (Figuras 5.6a, 5.6b, 5.6c, 5.6d, 5.6e, 5.6f, 5.6g e 5.6h) as cores azuis representam onde os agentes agricultores de subsistência ocuparam e exploraram, enquanto os laranjas são onde os de grande porte realizaram suas atividades. Os espaços amarelos, verde e brancos foram onde os agentes não realizaram nenhuma atividade ao longo dos *steps*.



(a) A matriz proximal combinada com os valores do PDOT, onde pixels mais verdes são mais atrativos e mais pretos são menos. A área vermelha é área proibida pelo PDOT.



(b) A classificação da valiosidade das áreas de acordo com a Figura 5.5a, em que verde são as áreas mais valiosas, amarelas são regulares e vermelhas são menos valiosas.

Figura 5.5: As imagens utilizadas para a avaliação da atratividade e valiosidade. Fonte: elaborado pelo autor (2021).

Tabela 5.3: Os experimentos realizados com o Modelo Cerrado MapBiomias.

Número Experimento	Código Experimento	Sistema de Decisão	Sistema de Regras	Comportamento de Troca de estratégia
0	BASE	Centralizado	Não há	Não há
1	FTA	Distribuído	Não há	Não há
2	SNG/HD	Distribuído	Hawk-Dove	Não há
3	SNG/DP	Distribuído	Dilema dos Prisioneiros	Não há
4	SNG/HD/REAT	Distribuído	Hawk-Dove	Reativo
5	SNG/HD/MEM	Distribuído	Hawk-Dove	Registro de Memória
6	SNG/DP/REAT	Distribuído	Dilema dos Prisioneiros	Reativo
7	SNG/DP/MEM	Distribuído	Dilema dos Prisioneiros	Registro de Memória

Foram aplicadas métricas de RMSE e SSIM (Seção 5.1.3 - Métricas e Validação do Modelo) considerando o experimento base como a imagem referência e os submodelos como a imagem de comparação. Os resultados obtidos são apresentados na Tabela 5.4.

Tabela 5.4: Os resultados das métricas de RMSE e SSIM.

Experimento A	Experimento B	RMSE	SSIM
BASE	FTA	7.67	0.448
	SNG/HD	7.64	0.4467
	SNG/DP	7.66	0.4484
	SNG/HD/REAT	7.17	0.4614
	SNG/HD/MEM	8.32	0.4432
	SNG/DP/REAT	7.20	0.4591
	SNG/DP/MEM	8.01	0.4434

Além da mensuração de similaridade visual, para cada experimento mediu-se o quanto de espaços de área de floresta original e de áreas antropizadas cada classe de exploração obteve. Os resultados são apresentados em porcentagem nos gráficos da Figura 5.7, em que espaços verde-escuros e amarelo-escuros são os espaços de floresta original e áreas antropizadas obtidos pelos agentes de grande porte, enquanto verde-claro e amarelo-claro são as obtidas pelos de subsistência.

Obteve-se, a seguir, a quantidade de espaços por classe de exploração e por valiosidade, métrica realizada com a classificação feita com o mapa das localizações mais atrativas (Figura 5.5b). Os resultados são expostos nos gráficos da Figura 5.8. Nesses gráficos, verde-escuro, amarelo-escuro e vermelho-escuro são respectivamente as posições valiosas, regulares e não valiosas obtidas pelos agentes de grande porte, enquanto as cores claras são as áreas equivalentes aos de subsistência.

A seguir, obteve-se os registros de tempo de execução de cada experimento por *step* para a aferição do tempo total de execução, e os resultados obtidos são mostrados na Figura 5.9. A quantidade de mensagens trocadas, seja entre os agentes do STAIP com o gerente no experimento base, seja entre os agentes entre si, também foi mensurada e é apresentada nos gráficos da Figura 5.10h.

Por fim, para os experimentos com troca de perfil estratégico, mensurou-se a quantidade de agentes de cada tipo e o *payoff* médio da população. Os resultados obtidos são mostrados nos gráficos das Figuras 5.11 e 5.12.

Discussão

Pela quantidade de experimentos gerados e pela quantidade de métricas aferidas, muito resultados experimentais foram obtidos. A princípio, a análise do espaço final simulado possui grande importância porque ela representa onde os agentes decidiram ocupar as áreas e transformar o ambiente, tendo em vista as regras definidas no ODD. No entanto, a análise visual não é suficiente para que conclusões possam ser tomadas. Visualmente, os resultados apresentados na Figura 5.6 possuem algum grau de proximidade entre si, o que é compreensível já que os agentes foram iniciados todos nas mesmas posições e foram guiados pela matriz proximal. No entanto, se individualmente considerarmos as localizações azuis e laranjas, podemos perceber que as simulações produziram espaços finais distintos. As métricas de RMSE e SSIM obtidas (Tabela 5.4) confirmam que as imagens não são iguais - todas elas possuem dissimilaridades menores ou maiores entre si. No entanto, é preciso reafirmar alguns fatos que podem ter influenciado a divergência dos resultados dos experimentos antes de conclusões serem inferidas.

Primeiramente, é notável que os agentes agricultores de grande porte ocuparam mais o espaço na maior parte dos experimentos, já que seus créditos de exploração os motivavam a obter mais espaço - em especial nos experimentos base, FTA, SNG/HD e SNG/DP em que não havia troca de estratégia. Já nos experimentos com mudança de estratégia, os comportamentos diferentes e o sistema de decisão são perceptíveis por meio das maiores diferenças visuais e de métricas obtidas. Nos experimentos com comportamento reativo, os agentes de grande porte quase dominaram o espaço inteiro, enquanto houve um cenário de maior equilíbrio entre as classes nos experimentos com registro de memória.

Além disso, a capacidade "mover-se" dos agentes baseia-se em uma distribuição de probabilidade que faz com que a aquisição de células seja um processo estocástico e contribua

para a diversidade dos resultados. Por mais que a matriz proximal e os espaços livres disponíveis guiem a movimentação, ela ainda é decidida por um fator probabilístico. Por fim, os agentes e o gerente são construídos com base em *threads* - que são processos leves que rodam concorrentemente no ambiente de execução. Sem um escalonamento explícito, seu funcionamento concorrente também pode causar a introdução de variações nos resultados.

Por mais que esses fatores possam ter introduzido variabilidade nos resultados, ainda assim certos padrões são perceptíveis nos resultados, a começar pela comparação entre experimentos feitos com diferentes sistemas de decisão. No Capítulo 4, na Seção 4.1.4, apresentou-se os sistemas de decisão centralizado e distribuído. O sistema centralizado e sistema de decisão FTA não utilizam do sistema de regras baseados em TJE, pois ambos possuem um algoritmo de decisão simples - o primeiro agente que enviar a mensagem ou que registrar sua intenção na célula, respectivamente, obtém o recurso. Mesmo comparando do mesmo método de decisão, eles não foram os experimentos que produziram os espaços simulados finais mais similares.

Questiona-se: porque esses experimentos geraram resultados que são visualmente e analiticamente distintos? A resposta dessa indagação está, em partes, no sistema de decisão em si. Mesmo que os fatores de aleatoriedade possam ter criado diferentes configurações do espaço de experimento para experimento, o sistema centralizado pode produzir resultados diferentes do sistema distribuído.

Partindo da comparação entre o sistema centralizado e o sistema distribuído FTA, os resultados gerados por esses modelo e submodelo deveriam ser mais similares entre si. No entanto, por mais que a lógica de decisão seja a mesma ("o primeiro pega o recurso"), a implementação da forma como o gerente processa as mensagens e resolve os conflitos não é necessariamente equivalente à resolução distribuída, por mais simples que seja - o que pode explicar a variedade dos resultados. As mensagens que chegam para que o gerente processe são sequencialmente tratadas, o que pode gerar um intervalo de tempo maior entre, por exemplo, três competidores por uma mesma célula. O primeiro competidor a ter sua mensagem processada adquire o recurso; o segundo tem o recurso negado, mas já pode imediatamente procurar outro recurso livre, enquanto o terceiro ainda está aguardando para ter sua requisição atendida.

Por outro lado, numa abordagem distribuída tanto o segundo quanto o terceiro colocados já podem verificar imediatamente seu sucesso ou falha e competir por outro recurso sem um intervalo de tempo tão grande - uma vez que a escrita da fila na célula é exclusiva, mas não a leitura. Isso faz com que o terceiro colocado tenha mais chances de competir justamente com o segundo, num possível futuro conflito entre eles.

Sendo assim, o argumento de que sistemas de decisão distintos podem trazer resultados diferentes é verificável pela comparação do método centralizado com os distribuídos. No centralizado, a fila de requisições pode atrasar a execução de agentes, criando atrasos que causam desvantagens a alguns agentes; No FTA, os agentes são rapidamente liberados do conflito, mas não há sistema de regra porque a decisão é simples; No SNG, os agentes param para aguardar a resolução de conflitos em ordem, até que somente um vencedor seja estabelecido. No entanto, SNG cria o potencial de desvantagem para os agentes que registraram-se por último no célula de interesse, especialmente os que não possuem perfil agressivo, uma vez que eles tem mais possibilidade de perder o recurso no final.

Portanto, essas conclusões observadas empiricamente diferenciam os resultados gerados pelos sistemas de decisão apresentados na Seção 4.1.4 - A desvantagem criada pela

espera de uma resolução de conflito pode criar diferenças no espaço final simulado.

Uma propriedade interessante percebida nos resultados é que o percentual de espaços de floresta original e de áreas antropizadas (Figura 5.7 em todos os experimentos sem troca de estratégia (base, FTA, SNG/HD e SNG/DP - Figuras 5.7a, 5.7b, 5.7c e 5.7d) possuem uma distribuição muito parecida entre si. Em outras palavras, a quantidade de floresta original consumida no experimento base e no experimento FTA pelos agentes de grande porte, por exemplo, foi praticamente a mesma. Tal afirmação é válida para outras combinações de tipo de célula e classe de exploração nesse conjunto de experimentos.

Isso significa que, empiricamente, mesmo que os agentes produzam espaços simulados diferentes pelos seus métodos de decisão distintos, as distribuições de exploração são as mesmas. Essa propriedade então mostra que os agentes se organizaram autonomamente para consumir os recursos de acordo com suas necessidades e de acordo com os potenciais disponíveis de célula, como um quebra-cabeças que pode ser montado de várias formas dentro das possibilidades do espaço.

Tal propriedade pode ter sua razão explicada sob a forma como os agentes são posicionados no espaço no início da simulação e como eles possivelmente preferem ocupar determinadas células primeiro. Os montantes de exploração por classe de exploração por valiosidade/atratividade das células (Figura 5.8) é similar entre os experimentos base, FTA, SNG/HD e SNG/DP, conforme mostram os gráficos nas Figuras 5.8a, 5.8b, 5.8c e 5.8d.

É razoável o entendimento de que os agentes primeiramente preferem os espaços mais valiosos e atrativos, e em seguida os regulares. A maior variação entre os experimentos acontece entre os espaços não valiosos, como se eles fossem a última opção possível de aquisição, independentemente do sistema de decisão.

Observando agora os experimentos em que há troca de estratégia, observa-se uma similaridade grande entre os espaços simulados finais gerados pelos experimentos com comportamento reativo: SNG/HD/REAT (Figura 5.6e) e SNG/DP/REAT (Figura 5.6f). Ambas imagens de espaço finais possuem uma quantidade muito maior de áreas dominadas pelos agentes de grande porte do que por agentes de subsistência. Tais resultados correlacionam-se com os *payoffs* médios encontrados ao longo da simulação (gráficos nas Figuras 5.12a e 5.12c, respectivamente), que demonstram que não apenas o *payoff* de *hawk*/trair eram melhores que os *payoffs* de *dove*/cooperar, mas quem o *payoff* médio da população tendia para as estratégias dominantes. Além disso, as quantidade de agentes por perfil estratégico registrado nos gráficos das Figuras 5.11a e 5.11c mostram que as populações de *hawk* e trair aumentaram consideravelmente ao longo da simulação.

Essa situação para o comportamento reativo já era prevista para o sistema de regras baseado no jogo *hawk-dove*, uma vez que ela foi utilizada para ilustração na Seção 4.1.4. Como observado, um resultado muito similar foi encontrado com um sistema de regras que usa Dilema dos Prisioneiros, que possui *payoffs* diferentes do *Hawk-dove*. A justificativa para esse acontecimento é simples - em ambos jogos, a estratégia não-cooperativa ganha da estratégia cooperativa, motivando os agentes a trocarem em quase todas as situações seus perfis estratégicos para *hawk*/trair. Em outras palavras, mesmo com sistemas de regras distintos, ambos experimentos são equivalentes.

Quanto aos experimentos com o comportamento baseado em registro de memória, é notório que nas imagens finais simuladas a ocupação de células por agricultores de subsistência é maior em ambos experimentos SNG/HD/MEM (Figura 5.6f) e SNG/DP/MEM

(Figura 5.6h). Tais percepções são confirmadas quando afere-se a quantidade de espaços de floresta original e área antrópica os agentes de subsistência adquiriram nesses experimentos (Figuras 5.7f e 5.7h), bem como espaços valiosos/atrativos e regulares (Figuras 5.8f e 5.8h) - de fato, houve os agentes *dove*/cooperar transformaram mais áreas do espaço original do modelo.

O experimento SNG/HD/MEM possui um conjunto de resultados surpreendente. Ao analisar o *payoff* médio da população, percebe-se que o *payoff* dos *hawks* é muito melhor que os dos *doves*, porém o *payoff* médio de todos os agentes tende mais para o lado dos *doves* (Figura 5.12b). Além disso, o gráfico de variação da quantidade de indivíduos nessa estratégia mostra um aumento contínuo de *doves*, com a quase extinção de *hawks* (Figura 5.11b) - quase o contrário da evolução populacional percebida nos experimentos reativos.

Para melhor entender o porquê dessas tendências deve-se analisar dois fatos: i) os registrador R_{dove} e R_{hawk} são iniciados em 0, independentemente do perfil estratégico dos agentes; ii) os registradores acumulam os *payoffs* recebidos das interações tanto para o lado de quem ganhou quanto de quem perdeu o conflito. Sendo assim, ambos *doves* envolvidos no conflito recebem *payoffs* positivos e iguais a 1, de acordo com a Tabela 5.2b. Por outro lado, ambos *hawks* recebem *payoffs* igual a -1. Portanto, *doves* são incentivados a criar espaços cooperativos próximos uns dos outros, enquanto *hawks* diminuem sua motivação de permanecer nesse perfil estratégico quando estão próximos.

No entanto, um único *hawk* pode explorar *doves* em um espaço cooperativo, o que explica porque seus *payoffs* continuam altos, mas seu nível populacional é baixo. Os poucos *hawks* restantes sobrevivem isolados ou explorando *doves* que, cumulativamente, não possuem incentivo para trocar de estratégia mesmo quando explorados. *Doves* quando conflitam com *hawks* perdem o recurso mas recebem *payoff* igual a 0, mantendo seus R_{dove} inalterados. Logo, eles não trocam seus perfis estratégicos.

O experimento SNG/DP/MEM diferencia-se do SNG/HD/MEM por causa dos seus *payoffs*, que são todos menores ou iguais a 0. Interações tanto de trair com trair e cooperar com cooperar geram *payoffs* negativos (Tabela 5.2a), o que faz com que inicialmente os envolvidos sejam motivados a trocar de estratégia. Agentes Trair que encontram agentes cooperar passam por uma breve estabilidade, pois recebem *payoff* zero. Porém, sob essas mesmas condições, agentes cooperar recebem o pior *payoff* do jogo, motivando-os rapidamente a trocar. Essa tendência faz com que a população de agentes trair aumente ao longo da simulação mas apresentando alguns pontos breves de encolhimento, quando agentes trair muito próximos interagem e se motivam a voltar a ser *doves* (Figura 5.11d). Os *payoffs* de trair são melhores que os de cooperar, mas o *payoff* médio da população sofre diversos ruídos ao longo da simulação.

Apesar do foco deste trabalho não ser direcionado à computação de alta performance nem a eficiência de sistemas distribuídos, foram incluídos nos resultados os gráficos de tempo de simulação (Figura 5.9) e de quantidade de mensagens trocadas (Figura 5.10). É esperado que o tempo de simulação com o experimento base seja o maior de todos, uma vez que o processamento das mensagens de forma sequencial pelo gerente é um processo mais lento do que se fosse feito de forma distribuída, como nos sistemas FTA e SNG. Outro fato interessante é que as simulações mais rápidas são as realizadas com FTA, já que não há tanta comunicação envolvida, nem tempos de espera de resolução de conflitos. SNG é mais demorada que FTA, mas mais rápida que o sistema centralizado.

Esses fatos se correlacionam em partes com a quantidade de mensagens trocadas. No experimento base há uma quantidade muito grande de mensagens trocadas com o gerente, alcançando picos de mais de 2000 mensagens em um único *step* de simulação. De forma oposta, a quantidade de mensagens em FTA é constante e igual a 300. A explicação para isso é que como agentes precisam da validação do gerente para trocar de lugar no sistema centralizado, a quantidade de mensagens naturalmente será muito grande. Além disso, o tempo de espera na fila de processamento cria desvantagens para os agentes do fim da fila, como já discutido nesta Seção. Por outro lado, os agentes FTA não precisam trocar mensagens entre si para descobrir quem ganhou a célula - eles apenas verificam a lista de interesse que preencheram. A única mensagem que eles enviam é com o Controle de Simulação para avisarem quando eles completaram seus objetivos principais com sucesso. Por isso o número de mensagens é fixo em 300 - exatamente o número de agentes participantes configurados no modelo.

Um fato interessante que foi percebido nos gráficos de quantidade de troca de mensagens é que o formato de todos eles possuem uma certa similaridade, com exceção de FTA. Eles sugerem que há uma grande quantidade de mensagens no início da simulação, com uma queda na quantidade de mensagens por volta do *step* 400, e uma suave subida e descida por volta do *step* 800. Isso pode estar correlacionado ao número de conflitos ocorridos em tempos específicos do modelo. No início, os agentes competem pelos espaços mais valiosos e mais atrativos. Quando esses espaços se tornam mais escassos ou extintos, eles passam a explorar espaços regulares. Espaços regulares são mais abundantes, por isso a quantidade de conflitos cai significativamente. No entanto, quando esses espaços vão se tornando escassos e somente os espaços não valiosos restam, há o breve aparecimento de conflitos novamente.

Este capítulo mostrou a caracterização ODD do modelo Cerrado MapBiomass, bem como a enumeração dos seus submodelos derivados. Os submodelos aqui foram adaptados para mostrar variações no modelo principal - que utiliza sistema de decisão centralizado - para comparação de possibilidades de combinação de sistemas de decisão e de regras. Os resultados alcançados pelos experimentos demonstram que o modelo de interação causa não apenas mudanças visuais no espaço simulado final, mas também diferenças que podem ser objetivamente metrificadas e comparadas. Isso mostra, empiricamente, que a forma como os agentes interagem é capaz de estabelecer a atividade socioeconômica mais adaptada aos sistemas de decisão e de regras implementados. No Capítulo 6 será apresentada a conclusão deste trabalho, bem como ideias e caminhos para futuras investigações.

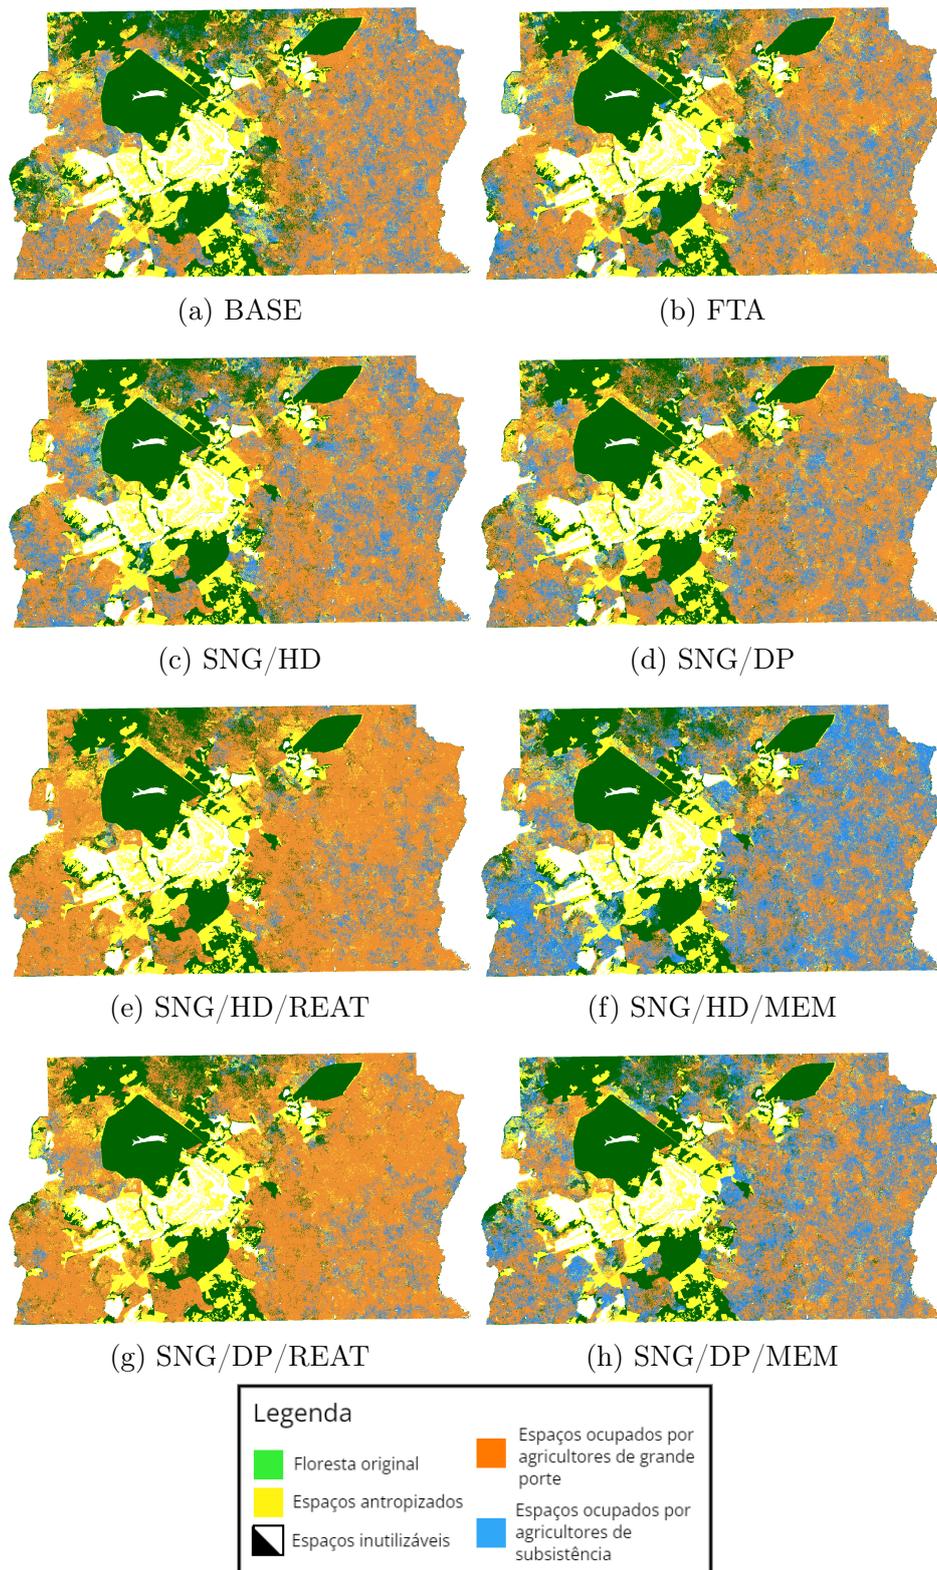


Figura 5.6: Os resultados das oito rodadas de experimentos, em que as áreas laranjas foram ocupadas e exploradas por agentes de grande porte e as azuis, subsistência. Fonte: elaborado pelo autor (2021).

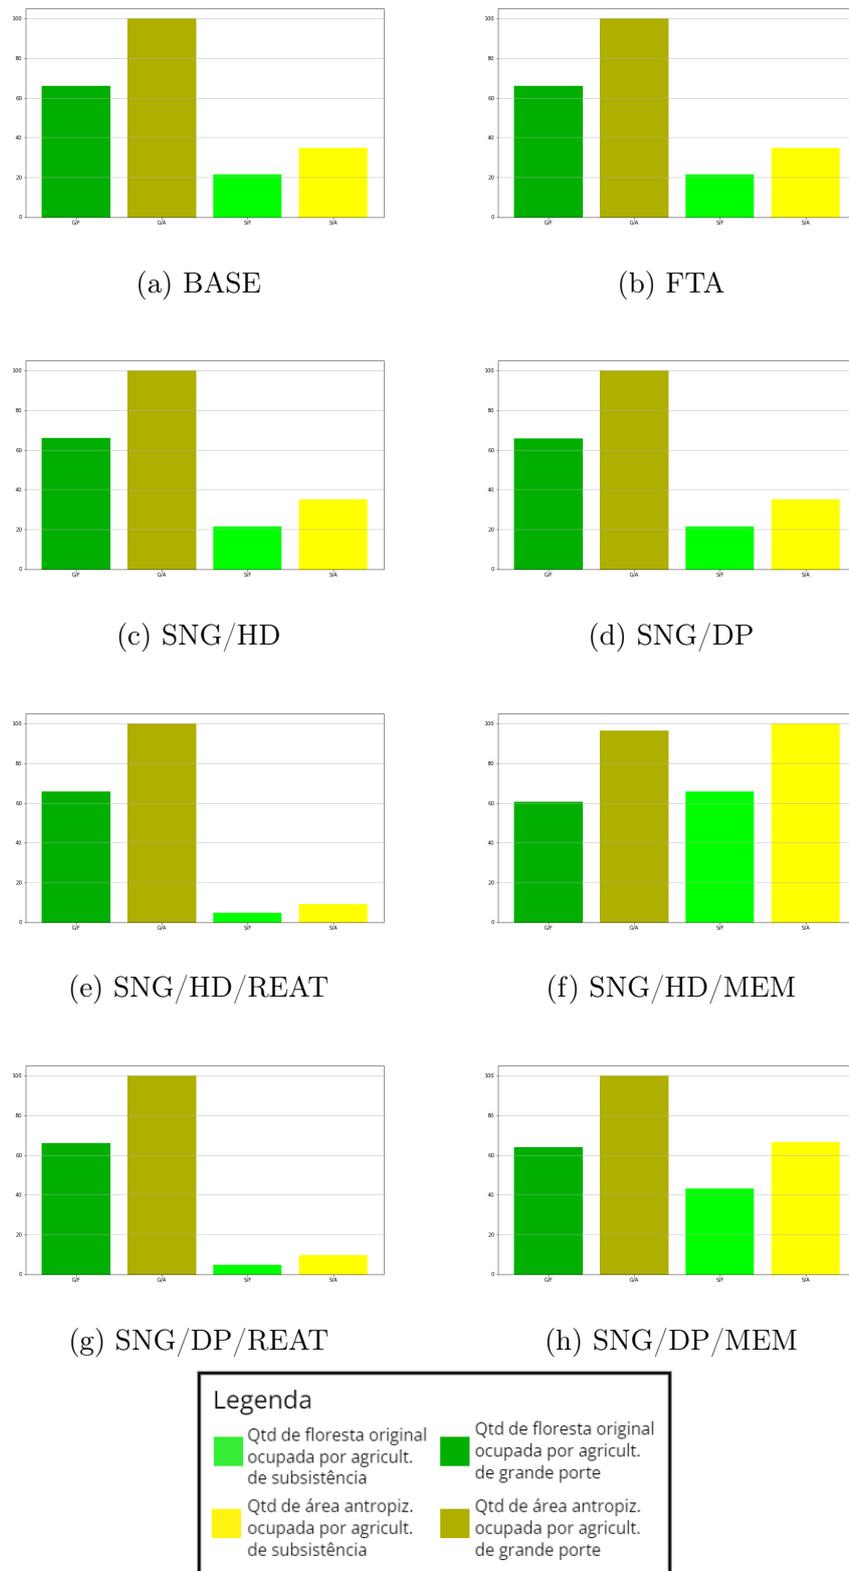


Figura 5.7: A quantidade de espaços dos tipos de floresta original e de espaço antropizado obtidas por classe de exploração por experimento. Fonte: elaborado pelo autor (2021).

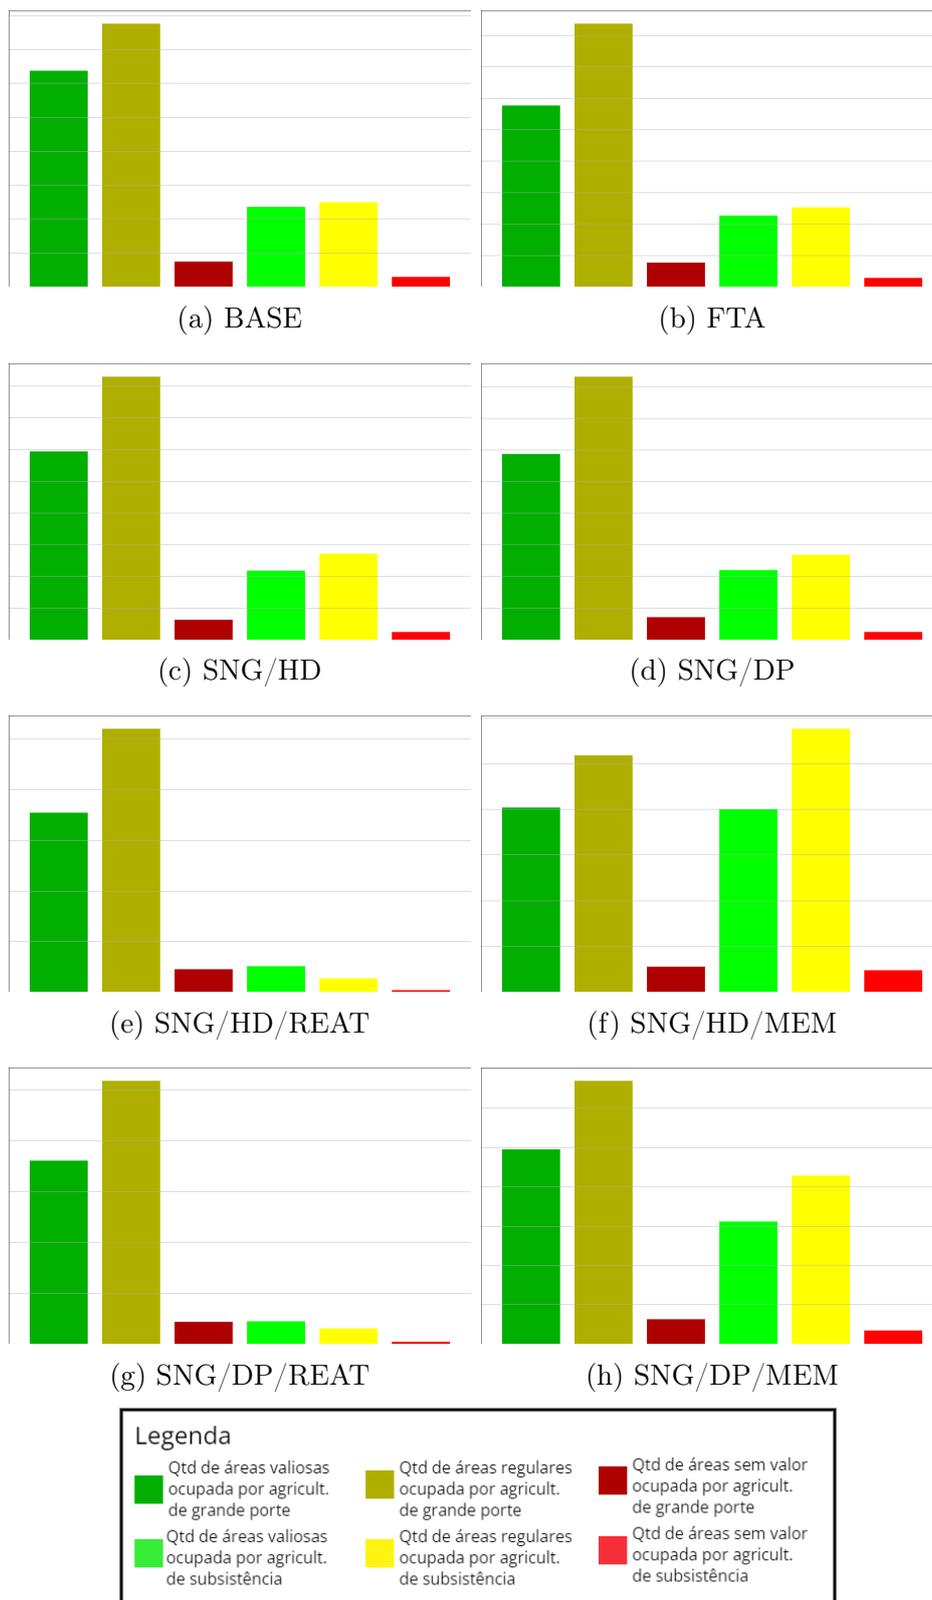
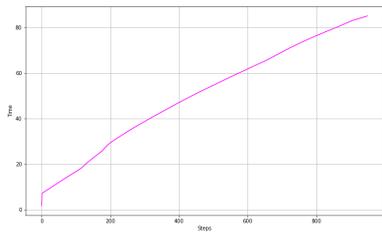
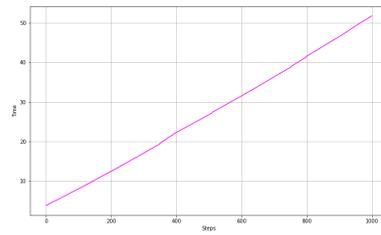


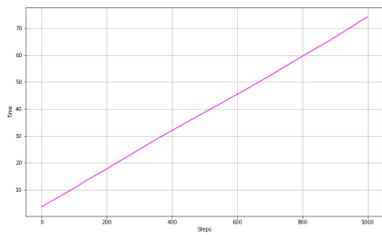
Figura 5.8: A quantidade de espaços dos tipos valioso, regular e não valioso obtidas por classe de exploração por experimento. Fonte: elaborado pelo autor (2021).



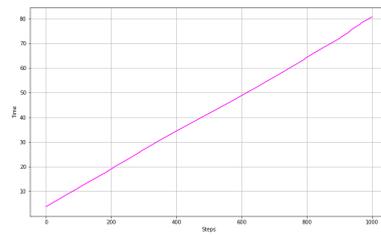
(a) BASE



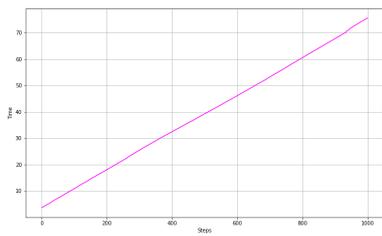
(b) FTA



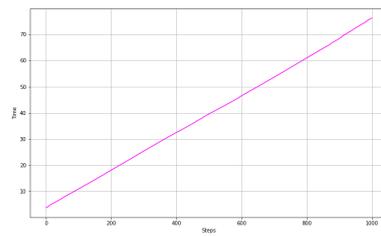
(c) SNG/HD



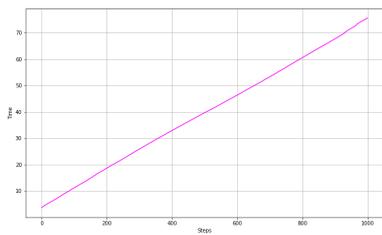
(d) SNG/DP



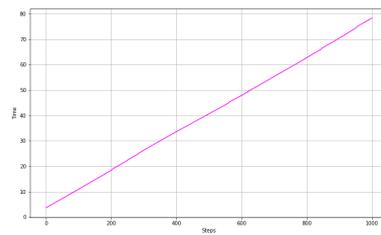
(e) SNG/HD/REAT



(f) SNG/HD/MEM



(g) SNG/DP/REAT



(h) SNG/DP/MEM

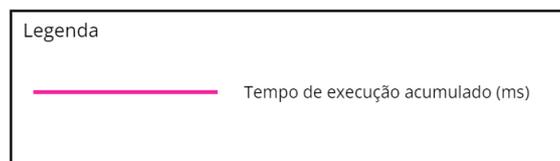
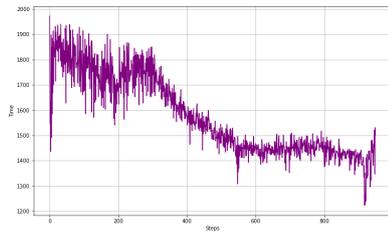
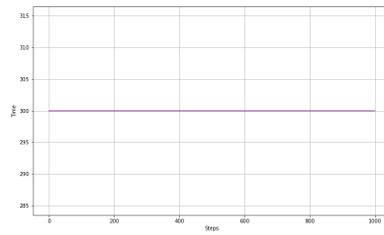


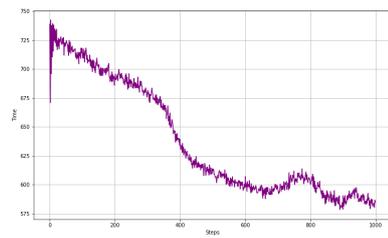
Figura 5.9: O tempo de execução dos *steps* de simulação de cada experimento. Fonte: elaborado pelo autor (2021).



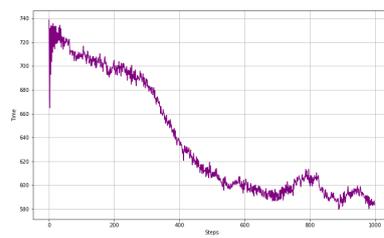
(a) BASE



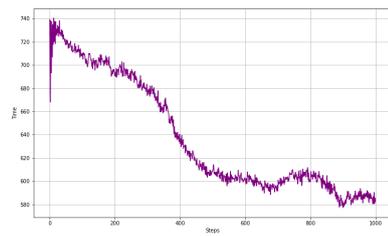
(b) FTA



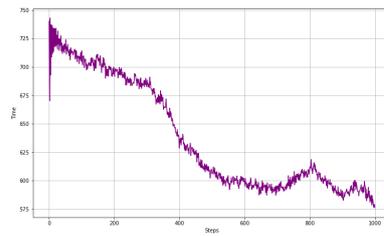
(c) SNG/HD



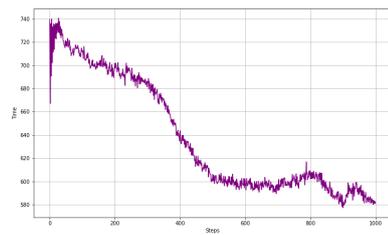
(d) SNG/DP



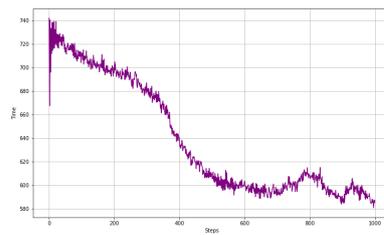
(e) SNG/HD/REAT



(f) SNG/HD/MEM



(g) SNG/DP/REAT



(h) SNG/DP/MEM

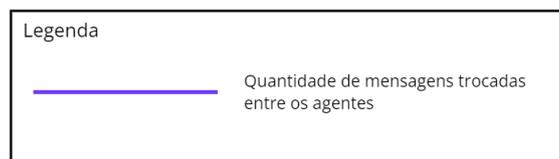
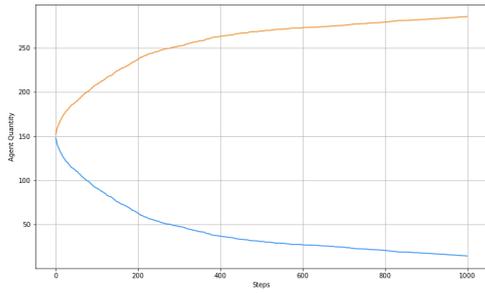
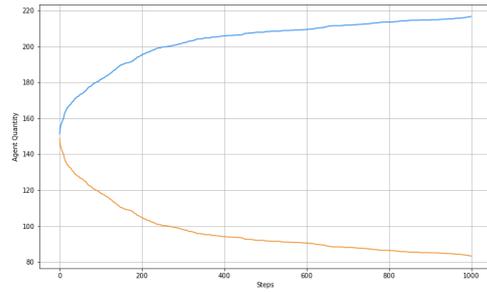


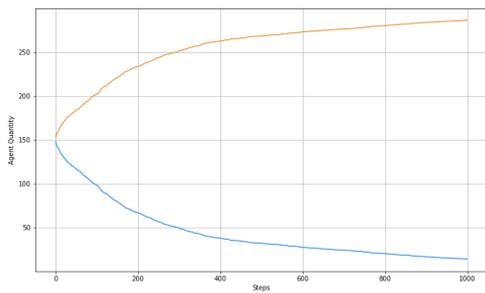
Figura 5.10: A quantidade de mensagens trocadas durante a simulação de cada experimento. Fonte: elaborado pelo autor (2021).



(a) SNG/HD/REAT



(b) SNG/HD/MEM



(c) SNG/DP/REAT



(d) SNG/DP/MEM

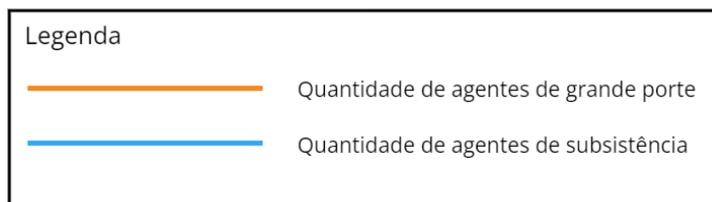
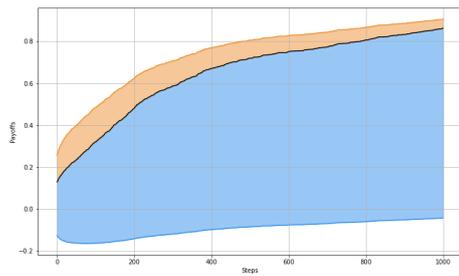
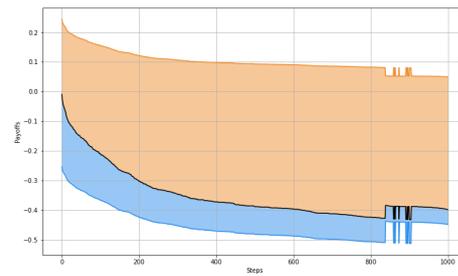


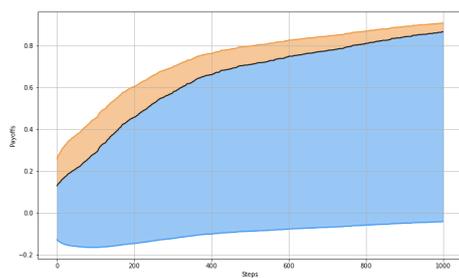
Figura 5.11: A quantidade de agentes de cada tipo por *step* em cada simulação. Fonte: elaborado pelo autor (2021).



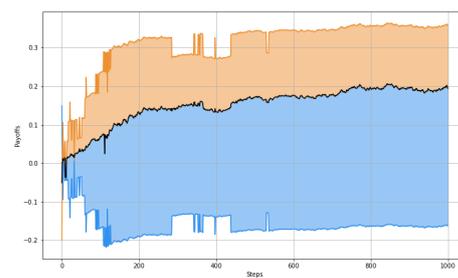
(a) SNG/HD/REAT



(b) SNG/HD/MEM



(c) SNG/DP/REAT



(d) SNG/DP/MEM



Figura 5.12: As diferenças de *payoffs*. Fonte: elaborado pelo autor (2021).

Capítulo 6

Conclusão

Neste trabalho foi concebido, implementado e validado um modelo de simulação baseado em agentes interativos com TJE para Lucc. O modelo é utilizado para definir interações entre os agentes quando eles competem por recursos espaciais comuns ou quando estão em busca de novos espaços para realizarem suas atividades socioeconômicas. O modelo de interação foi integrado a um modelo em Lucc denominado STAIP, ambos apresentados neste trabalho. O modelo é composto por dois sistemas: um de decisão e outro de regras. O sistema de decisão caracteriza se os agentes são apoiados por um mediador, sob a figura de um gerente, para resolver um conflito, ou se são capazes de resolvê-lo sozinhos. O sistema de regras define que jogo será associado para a resolução das situações estratégicas causadas pelos conflitos de recursos espaciais. Além disso, o sistema de regras pode influenciar a evolução da sociedade, transformando os agentes de um tipo em outro. Esse processo sugere quais atividades são mais adaptadas ao cenário explorado, tendo em vista as regras definidas no modelo para Lucc.

Modelagem e simulação possuem um relacionamento próximo com Ecologia de Paisagens [72], e MBA apresenta diversos pontos em comum com Lucc. Uma vez que atualmente processos antrópicos de conversão e uso da terra são responsáveis pelos maiores impactos no meio ambiente, é adequada a utilização de MBA no entendimento de cenários em Lucc. Além disso, a representatividade de sistemas complexos, bem como a possibilidade da integração de modelos cognitivos e modelos de interação entre agentes [20] torna MBA uma técnica muito oportuna e efetiva na representação de modelos em Lucc.

Nesta pesquisa, considerou-se como ponto de partida do modelo a representação do espaço em células que não podem ser exploradas por mais de um agente. Além disso, atribuiu-se atratividade às células próximas de atributos do espaço específicos, como rios e rodovias, e a áreas ligadas ao PDOT. Com isso, incentivou-se a ocorrência de conflitos como forma de evidenciar a efetividade do modelo de interação introduzido. Por isso, foi possível verificar que variações nas interações dos agentes podem causar mudanças visuais e quantitativas nos resultados obtidos da simulações.

Como hipótese deste trabalho, afirmou-se que interações multilaterais entre agentes modeladas a partir de jogos em TJE influenciam como o espaço simulado final será organizado em MBA para Lucc. Além disso, por meio da definição dessa influência da interação sobre o espaço simulado, seria possível sugerir que atividades socioeconômicas são mais preponderantes em determinados cenários. Como citado no parágrafo anterior, os resultados empíricos mostram que, de fato, a forma como os conflitos são resolvidos

pode mudar a configuração espacial de forma visual e por meio de estatísticas dos resultados, o que confirma que a hipótese investigada é correta em sua asserção. Por mais que alguns fatores inerentes ao modelo possam ter gerados ruídos que sugerem espaços finais diferentes, é possível ainda assim perceber que os agentes interagindo e se comportando diferentemente causam mudanças no espaço de simulação. Tais mudanças já eram previstas pelo desenvolvimento matemático das equações que analisavam como a população poderia evoluir de acordo com as diferentes variações do modelo de interação; as simulações do modelo confirmaram essa realidade. Além disso, a conquista de espaços mais atrativos por uma classe de exploração sobre a outra evidencia que as regras do modelo podem demonstrar que tipo de atividade é preponderante no espaço investigado.

Revisitando os objetivos desta pesquisa, por meio de um modelo de simulação em LUCS foi possível explorar diversas variações de interações entre agentes, e assim demonstrar que elas podem produzir organizações do espaço distintas. Sendo assim, o objetivo principal foi alcançado. Outrossim, os objetivos secundários também foram cumpridos: um cenário-base no modelo foi definido e comparado com submodelos; um protocolo de interação foi definido tanto para agentes em um sistema de decisão centralizado quanto distribuído; jogos foram integrados ao sistema de regras e de evolução dos agentes; e um conjunto de métricas foi definido e utilizado para a aferição dos resultados.

Os resultados obtidos evidenciaram processos ligados a comportamentos de troca de estratégia de agentes. Nos experimentos que envolvem a evolução da sociedade, o entendimento é aprofundado em como as interações entre os agentes influenciam o resultado final das simulações. Uma vez que a sociedade possui grupos que transformam o espaço de maneiras diferentes e esses grupos perdem ou ganham influência dinamicamente, suas interações possuem pesos variados sobre a transformação do espaço. Isso foi especialmente destacado nas diferenças entre o comportamento reativo e o comportamento baseado em registro de memória, que, mesmo com o mesmo sistema de regras, produziram configurações finais bastante distintas. Além disso, o *payoff* dos agentes e suas relações de dominância ou dominância fraca mudam como o território será organizado e a sociedade irá evoluir.

Por mais que não fosse o foco deste trabalho, ainda percebeu-se no final como o tempo de simulação, o padrão na quantidade de mensagens trocadas e a quantidade de espaços valiosos/atrativos, regulares e não-valiosos estão correlacionados. Isso demonstra que alguns propriedades relacionadas ao processo de simulação, paralelo ao processo de transformação do espaço, são observáveis indiretamente por meio dos resultados da simulação.

Uma observação final sobre os resultados foi a emergência percebida a respeito da capacidade dos agentes em se auto-organizar no espaço, mesmo com modelos de interação diferentes. Os resultados dos experimentos base, FTA, SNG/HD e SNG/DP mostram configurações diferentes da paisagem final simuladas, mas com as quantidades de recurso obtidas pelos agentes praticamente iguais. Isso é interessante, pois sugere que o espaço pode ser ocupado de formas diferentes sem a variação drástica dos recursos espaciais explorados pelos diversos grupos. Essa propriedade, além de todos os resultados encontrados, apresenta um excelente potencial de aprofundamento para esta pesquisa.

Trabalhos Futuros

É possível perceber que essa pesquisa ainda possui muitos tópicos a serem aprofundados e estudados. A evidência de mais propriedades emergentes e a observação indireta de fenômenos que aconteceram na simulação mostram que esse estudo possui o potencial de aperfeiçoamento e expansão do modelo de interação proposto. Sendo assim, como trabalhos futuros pode-se listar:

- A implementação de mais modelos de decisão e de troca de estratégias, uma vez que eles demonstraram possuir um impacto relevante na transformação do ambiente. Em modelos de decisão, existe a ideia da implementação de múltiplos gerentes regionais, distribuindo a fila de requisição. Ainda no modelo de decisão, intenta-se criar um modelo distribuído similar ao SNG mas que não exige que todos os agentes esperem pela resolução de todos os conflitos - em vez disso, esperem apenas os agentes de suas vizinhanças, criando apenas um *stop* local;
- O uso de outros jogos implementados no sistema de regras do modelo de interação. Neste trabalho utilizou-se apenas jogos de dois jogadores com duas estratégias, em que uma delas domina fracamente a outra. Indaga-se sobre quais seriam os resultados e as propriedades emergentes obtidos no caso de jogos como pedra, papel e tesoura, em que há três estratégias e uma domina a outra;
- No tema de computação de alta performance, o estudo sistemático do uso de recursos computacionais e de tempo de simulação em cada variação do modelo apresentado neste trabalho. O tempo de simulação e o de troca de mensagens sugere que houve um *speedup* entre as variações do modelo. Até onde poderia-se otimizar o processo de simulação?
- Propor outros modelos em LUCC para a exploração de outros contextos com o sistema de interação proposto, como uso e contenção de recursos hídricos, expansão da fronteira urbana, evolução populacional de bairros e cidades e seus impactos sobre o meio ambiente, dentre outras sugestões de pesquisa;
- Aperfeiçoar os métodos descritos para que o MASE-EGTI possa ser executado em sistema computacional distribuído. O método de interação dos agentes ainda é muito dependente do uso de memória local. Se for repensando e aperfeiçoado para ser executado em um sistema distribuído, modelos ainda maiores e com mais agentes poderiam ser desenvolvidos, assim aumentando o domínio das simulações realizadas com o modelo de interação proposto.

Referências

- [1] Extending netlogo with bdi and fipa acl support. <http://users.uom.gr/~iliass/projects/NetLogo/>. Acessado em: 23/11/2017. 28
- [2] Gama, modeling made easy. <http://gama-platform.org/>. Acessado em: 22/11/2017. 27
- [3] Gama-plataform/gama: Using bdi. <https://github.com/gama-platform/gama/wiki/UsingBDI>. Acessado em: 23/11/2017. 27
- [4] Lecture notes for msc course on evolutionary game theory, uni freiburg. <http://florianhartig.github.io/EGT/>. Acessado em: 23/11/2017. 28
- [5] William L. Baker. A review of models of landscape change. *Landscape Ecology*, 2(2):111–133, 1989. 3
- [6] A. Borshchev. *The Big Book of Simulation Modeling: Multimethod Modeling with AnyLogic 6*. AnyLogic North America, 2013. 3
- [7] François Bousquet, Innocent Bakam, Hubert Proton, and Christophe Le Page. *Cor-mas: Common-pool resources and multi-agent systems*, pages 826–837. Springer Berlin Heidelberg, Berlin, Heidelberg, 1998. 2, 6, 26
- [8] Michael E. Bratman. *Intention, Plans, and Practical Reason*. Cambridge University Press, 1999. 11, 12
- [9] Lars Braubach and Alexander Pokahr. Jadex active components framework-bdi agents for disaster rescue coordination. *Software agents, agent systems and their applications*, 32:57–84, 2012. ix, 12, 46, 47
- [10] Daniel G Brown, Robert Walker, Steven Manson, and Karen Seto. Modeling land use and land cover change. In *Land change science*, pages 395–409. Springer, 2012. 13
- [11] Cássio G. C. Coelho, Carolina G. Abreu, Rafael M. Ramos, Aldo H. D. Mendes, George Teodoro, and Célia G. Ralha. MASE-BDI: agent-based simulator for environmental land change with efficient and parallel auto-tuning. *Applied Intelligence*, 45(3):904–922, Oct 2016. 6, 8, 36, 47, 51
- [12] T. Chai and R. R. Draxler. Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? – arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3):1247–1250, 2014. 58, 59, 60

- [13] Franco Ciciirelli, Andrea Giordano, and Libero Nigro. Efficient environment management for distributed simulation of large-scale situated multi-agent systems. *Concurrency and Computation: Practice and Experience*, 27(3):610–632, 2015. 4
- [14] Cassio Coelho and Celia Ralha. Mase-egti: Simulador baseado em teoria dos jogos evolucionários para sustentabilidade ambiental. In *Anais do X Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais*, pages 154–163, Porto Alegre, RS, Brasil, 2019. SBC. 8
- [15] Cássio G. C. Coelho and Célia G. Ralha. MASE-EGTI: an agent-based simulator for environmental land change. *Environmental Modelling & Software*, 147:105252, 2022. 6, 8
- [16] Daniel D Corkill. Collaborating Software: Blackboard and Multi-Agent Systems & the Future. In *Proceedings of the International Lisp Conference*, New York, USA, October 2003. 6
- [17] Easley David and Kleinberg Jon. *Networks, Crowds, and Markets: Reasoning About a Highly Connected World*. Cambridge University Press, New York, NY, USA, 2010. 19, 20
- [18] Pedro Ribeiro de Andrade. *Game theory and agent-based modelling for the simulation of spatial phenomena*. PhD thesis, Instituto Nacional de Pesquisas Espaciais (INPE), Programa de Pós-Graduação em Computação Aplicada do INPE, São José dos Campos, SP, 2010. 24
- [19] Pedro Ribeiro de Andrade, Antonio Miguel Vieira Monteiro, Gilberto Câmara, and Sandra Sandri. Games on cellular spaces: How mobility affects equilibrium. *Journal of Artificial Societies and Social Simulation*, 12(1):5, 2009. 24, 28
- [20] Scott De Marchi and Scott E Page. Agent-based models. *Annual Review of political science*, 17:1–20, 2014. 15, 74
- [21] Tiago Garcia de Senna Carneiro, Pedro Ribeiro de Andrade, Gilberto Câmara, Antônio Miguel Vieira Monteiro, and Rodrigo Reis Pereira. An extensible toolbox for modeling nature–society interactions. *Environmental Modelling & Software*, 46:104–117, 2013. 6, 25, 28
- [22] D.C. Dennett. *The Intentional Stance*. A Bradford book. A Bradford Book, 1989. 10, 11
- [23] Alexis Drogoul, Edouard Amouroux, Philippe Caillou, Benoit Gaudou, Arnaud Grignard, Nicolas Marilleau, Patrick Taillandier, Maroussia Vavasseur, Duc-An Vo, and Jean-Daniel Zucker. Gama: multi-level and complex environment for agent-based models and simulations. In *Proceedings of the 2013 international conference on Autonomous agents and multi-agent systems*, pages 1361–1362. International Foundation for Autonomous Agents and Multiagent Systems, 2013. 6, 27

- [24] Cícero C de Figueiredo, Glenio G Santos, Sidney Pereira, Jorge L do Nascimento, and José Alves Júnior. Propriedades físico-hídricas em latossolo do cerrado sob diferentes sistemas de manejo. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 13:146–151, 2009. 1, 2
- [25] Francisco Franchetti and William H. Sandholm. An introduction to dynamo: Diagrams for evolutionary game dynamics. *Biological Theory*, 8(2):167–178, 2013. 29
- [26] Saulo R Freitas, Karla M Longo, MAF Dias, and PL Dias. Emissões de queimadas em ecossistemas da américa do sul. *Estudos avançados*, 19:167–185, 2005. 1, 2
- [27] Ziyi Gao. Understanding the future of deep reinforcement learning from the perspective of game theory. *Journal of Physics: Conference Series*, 1453(1):012076, jan 2020. 12
- [28] Luciana V. Gatti, Luana S. Basso, John B. Miller, et al. Amazonia as a carbon source linked to deforestation and climate change. *Nature*, 595(7867):388–393, 2021. 1, 2
- [29] GDF. Plano Diretor de Ordenamento Territorial do Distrito Federal: documento técnico. Technical report, Secretaria de Habitação, Regularização e Desenvolvimento Urbano - SEDHAB, Brasília, 2009. ix, 54
- [30] Michael P Georgeff and Amy L Lansky. Procedural knowledge. *Proceedings of the IEEE*, 74(10):1383–1398, 1986. 12
- [31] Robert Gibbons. *Game theory for applied economists*. Princeton University Press, 1992. 17, 18
- [32] Adele Goldberg and David Robson. *Smalltalk-80: the language and its implementation*. Addison-Wesley Longman Publishing Co., Inc., 1983. 27
- [33] Volker Grimm, Uta Berger, Finn Bastiansen, Sigrunn Eliassen, Vincent Ginot, Jarl Giske, John Goss-Custard, Tamara Grand, Simone K Heinz, and Geir Huse. A standard protocol for describing individual-based and agent-based models. *Ecological Modelling*, 198(1-2):115–126, 2006. 51, 55
- [34] Volker Grimm, Uta Berger, Donald L DeAngelis, J Gary Polhill, Jarl Giske, and Steven F Railsback. The ODD protocol: A review and first update. *Ecological Modelling*, 221(23):2760–2768, 2010. 51
- [35] Volker Grimm, Steven F. Railsback, Christian E. Vincenot, Uta Berger, Cara Gallagher, Donald L. DeAngelis, Bruce Edmonds, Jiaqi Ge, Jarl Giske, Jürgen Groeneveld, Alice S.A. Johnston, Alexander Milles, Jacob Nabe-Nielsen, J. Gareth Polhill, Viktoriia Radchuk, Marie-Sophie Rohwäder, Richard A. Stillman, Jan C. Thiele, and Daniel Ayllón. The ODD protocol for describing agent-based and other simulation models: A second update to improve clarity, replication, and structural realism. *Journal of Artificial Societies and Social Simulation*, 23(2):7, 2020. xi, 26, 51, 52
- [36] Ramanathan V. Guha and Douglas B. Lenat. Enabling agents to work together. *Communications of the ACM*, 37(7):126–142, 1994. 4, 14

- [37] HJTM Haarman, Jan Verhagen, and CA Rovers. *Global environmental change and land use*. Springer Science & Business Media, 2003. 1
- [38] J. Hofbauer, K. Sigmund, and P.I.M.K. Sigmund. *Evolutionary Games and Population Dynamics*. Cambridge University Press, 1998. 22
- [39] Alain Horé and Djemel Ziou. Image quality metrics: Psnr vs. ssim. In *2010 20th International Conference on Pattern Recognition*, pages 2366–2369, 2010. 59, 60
- [40] R. A. Houghton, J. I. House, J. Pongratz, G. R. van der Werf, R. S. DeFries, M. C. Hansen, C. Le Quéré, and N. Ramankutty. Carbon emissions from land use and land-cover change. *Biogeosciences*, 9(12):5125–5142, 2012. 1, 2
- [41] Ying Huang, Pavel Janovsky, Sanjoy Das, Stephen M Welch, and Scott DeLoach. Multi-agent system for groundwater depletion using game theory. *arXiv:1607.02376*, 2016. 25
- [42] Roberto Ierusalimschy, Luiz Henrique De Figueiredo, and Waldemar Celes Filho. Lua-an extensible extension language. *Softw., Pract. Exper.*, 26(6):635–652, 1996. 28
- [43] Marton Ivanyi, Rajmund Bocsi, Laszlo Gulyas, Vilmos Kozma, and Richard Legendi. The multi-agent simulation suite. *Emergent Agents and Socialities: Social and Organizational Aspects of Intelligence*, pages 8–11, 2007. 6, 27
- [44] Luis R. Izquierdo, Segismundo S. Izquierdo, and William H. Sandholm. An introduction to abed: Agent-based simulation of evolutionary game dynamics. *Games and Economic Behavior*, 118:434 – 462, 2019. 28
- [45] Marco A. Janssen and Elinor Ostrom. Empirically based, agent-based models. *Ecology and Society*, 11(2), 2006. 15
- [46] Zheng Jianya. *Uma Investigação de Relacionamentos Baseados na Competição entre Stakeholders no Comércio Eletrônico Utilizando Teoria dos Jogos*. PhD thesis, Universidade de Brasília, 6 2016. Texto completo disponível em: <http://repositorio.unb.br/handle/10482/21445>. Acessado em 20/11/2017. 19
- [47] James Holland Jones. Evolutionary game theory, 12 2008. Texto completo disponível em: <https://web.stanford.edu/~jhj1/teachingdocs/Jones-ess-notes.pdf>. Acessado em 20/11/2017. 20, 21
- [48] E. F. Lambin, M. D. A. Rounsevell, and H. J. Geist. Are agricultural land-use models able to predict changes in land-use intensity? *Agriculture Ecosystems & Environment*, 82:321–331, 2000. 3, 13
- [49] Peter M. Vitousek, Harold A. Mooney, Jane Lubchenco, and Jerry Melillo. Human domination of earth’s ecosystems. *Science*, 277:494–499, 07 1997. 1
- [50] Marcia McNutt. Climate change impacts. *Science*, 341(6145):435–435, 2013. 1, 2
- [51] Ann Nowé, Peter Vrancx, and Yann-Michaël De Hauwere. *Game Theory and Multi-agent Reinforcement Learning*, pages 441–470. Springer Berlin Heidelberg, Berlin, Heidelberg, 2012. 12

- [52] Ester Brito Parente, Lucas Vinicius Alves da Silva, and Wanderson Carvalho da Silva. Desmatamento na amazônia: O desmatamento em vista da expansão pecuarista no município de xinguara-pa. *Revista GeoAmazônia*, 9(17):126–142, 2021. 1, 2
- [53] Anthony Patt and Bernd Siebenhüner. Agent based modeling and adaption to climate change. *Vierteljahrshefte zur Wirtschaftsforschung / Quarterly Journal of Economic Research*, 74(2):310–320, 2005. 3, 14
- [54] Roger A Pielke. Land use and climate change. *Science*, 310(5754):1625–1626, 2005. 1
- [55] Alexander Pokahr and Lars Braubach. A survey of agent-oriented development tools. In *Multi-Agent Programming*, pages 289–329. Springer, 2009. ix, 3, 10, 11
- [56] Célia G. Ralha, Carolina G. Abreu, Cássio G. C. Coelho, Alexandre Zaghetto, Bruno Macchiavello, and Ricardo B. Machado. A multi-agent model system for land-use change simulation. *Environmental Modelling & Software*, 42:30–46, 2013. 6, 36, 51
- [57] Ronald R Rindfuss, Stephen J Walsh, B L Turner, Jefferson Fox, and Vinod Mishra. Developing a science of land change: Challenges and methodological issues. *Proceedings of the National Academy of Sciences of the United States of America*, 101(39):13976–13981, 2004. 2
- [58] Maíra Iaê Savioli Rocha and Diego Tarley Ferreira Nascimento. Distribuição espaço-temporal das queimadas no bioma cerrado (1999/2018) e sua ocorrência conforme os diferentes tipos de cobertura e uso do solo. *Revista Brasileira de Geografia Física*, 14(03):1220–1235, 2021. 1, 2
- [59] S. J. Russell and P. Norvig. *Artificial Intelligence: A Modern Approach*. Prentice-Hall, USA, 3rd edition, 2010. 9
- [60] K Sakadevan and M-L Nguyen. Livestock production and its impact on nutrient pollution and greenhouse gas emissions. *Advances in agronomy*, 141:147–184, 2017. 1
- [61] Sueli Matiko Sano, Semiramis Pedrosa de Almeida, and José Felipe Ribeiro. *Cerrado: ecologia e flora*. Number v. 2 in *Cerrado: ecologia e flora*. Embrapa Informação Tecnológica, 2008. ix, 31
- [62] Yoav Shoham. Agent-oriented programming. *Artif. Intell.*, 60(1):51–92, March 1993. 9
- [63] Claudia Arantes Silva, Giancarlo Santilli, Edson Eyji Sano, and Giovanni Laneve. Fire occurrences and greenhouse gas emissions from deforestation in the brazilian amazon. *Remote Sensing*, 13(3):376, 2021. 1, 2
- [64] Alex Smajgl, Daniel G. Brown, Diego Valbuena, and Marco G.A. Huigen. Empirical characterisation of agent behaviours in socio-ecological systems. *Environmental Modelling & Software*, 26(7):837 – 844, 2011. Acessado em: 22-06-2014. 6, 14

- [65] J. Maynard Smith and George R. Price. The logic of animal conflict. *Nature*, 246(5427):15–18, 1973. 19
- [66] John Maynard Smith. *Evolution and the Theory of Games*, pages 202–215. Springer US, Boston, MA, 1988. 19
- [67] Carlos M Souza, Julia Z Shimbo, Marcos R Rosa, Leandro L Parente, Ane A Alencar, Bernardo FT Rudorff, Heinrich Hasenack, Marcelo Matsumoto, Laerte G Ferreira, Pedro WM Souza-Filho, et al. Reconstructing three decades of land use and land cover changes in brazilian biomes with landsat archive and earth engine. *Remote Sensing*, 12(17):2735, 2020. ix, 51, 56, 57
- [68] Andrew S Tanenbaum and Herbert Bos. *Modern operating systems*. Pearson, 2015. 4
- [69] Jun Tanimoto and Hiroki Sagara. Relationship between dilemma occurrence and the existence of a weakly dominant strategy in a two-player symmetric game. *Biosystems*, 90(1):105–114, 2007. 22, 23
- [70] Yong Meng Teo, Ba Linh Luong, and Claudia Szabo. Formalization of emergence in multi-agent systems. In *Proceedings of the 1st ACM SIGSIM Conference on Principles of Advanced Discrete Simulation*, pages 231–240, 2013. 3
- [71] Seth Tisue and Uri Wilensky. Netlogo: A simple environment for modeling complexity. In *International conference on complex systems*, volume 21, pages 16–21. Boston, MA, 2004. 6, 28
- [72] Monica G Turner, Robert H Gardner, and Robert V O Neill. Ecological Dynamics at Broad Scales: Ecosystems and landscapes. *BioScience*, 45:29–35, 1995. 2, 13, 74
- [73] Monica G Turner, Robert H Gardner, and Robert V O’Neill. *Landscape Ecology in theory and practice: pattern and process*. Springer-Verlag New York, Inc., 2001. 1
- [74] Peter H Verburg. Simulating feedbacks in land use and land cover change models. *Landscape Ecology*, 21(8):1171–1183, 2006. 13, 14, 15
- [75] Zhen Wang, Satoshi Kokubo, Marko Jusup, and Jun Tanimoto. Universal scaling for the dilemma strength in evolutionary games. *Physics of Life Reviews*, 14:1–30, 2015. 22, 23
- [76] Hua Wei, Guanjie Zheng, Vikash Gayah, and Zhenhui Li. A survey on traffic signal control methods, 2020. 12
- [77] Jörgen W Weibull. *Evolutionary game theory*. MIT press, 1997. 15, 18, 19
- [78] M. Wooldridge. *Introduction to Multiagent Systems*. John Wiley & Sons Ltd, West Sussex, UK, second edition, 2009. 3, 4, 9, 10, 12, 14
- [79] M. J. Wooldridge and N. R. Jennings. Formalising the cooperative problem solving process. In *13th Int. Distributed Artificial Intelligence Workshop (IWDAI-94)*, pages 403–417, 1994. 4, 10

- [80] Michael Wooldridge and Nicholas R. Jennings. Intelligent agents: Theory and practice. *Knowledge Engineering Review*, 10:115–152, 1995. 9