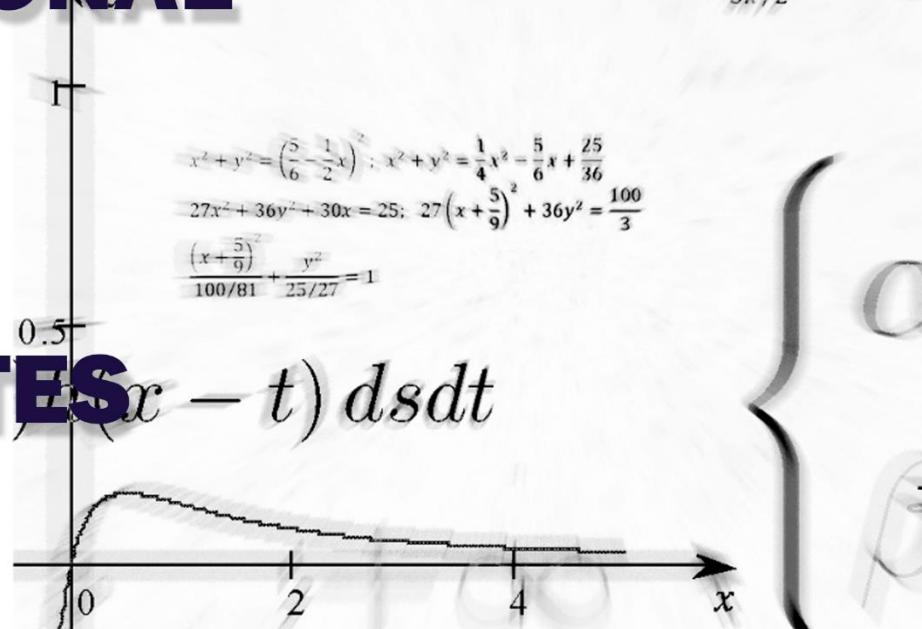


VISÃO COMPUTACIONAL EM AÇÃO E SISTEMAS MULTIAGENTES



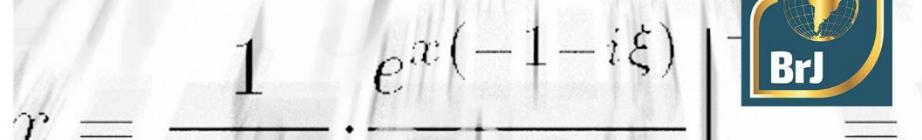
$$\iota \int h(x-s-u) du$$

$|a_n| \leq |c_n| + |c_{-n}|, \quad |b_n| \leq \frac{|a_n| + |b_n|}{2}, \quad |c_n| \leq \frac{|a_n| + |b_n|}{2}$

São José dos Pinhais

BRAZILIAN JOURNALS PUBLICAÇÕES DE PERIÓDICOS E EDITORA

2024



**Anselmo Rafael Cukla
Fernanda Pinto Mota**

**Visão computacional em ação e
sistemas multiagentes**

BrJ

**Brazilian Journals Editora
2024**

2024 by Brazilian Journals Editora
Copyright © Brazilian Journals Editora
Copyright do Texto © 2024 Os Autores
Copyright da Edição © 2024 Brazilian Journals Editora
Diagramação: Lorena Fernandes Simoni
Edição de Arte: Lorena Fernandes Simoni
Revisão: Os Autores

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores. Permitido o download da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Conselho Editorial:

Prof^a. Dr^a. Fátima Cibele Soares - Universidade Federal do Pampa, Brasil
Prof. Dr. Gilson Silva Filho - Centro Universitário São Camilo, Brasil
Prof. Msc. Júlio Nonato Silva Nascimento - Instituto Federal de Educação, Ciência e Tecnologia do Pará, Brasil
Prof^a. Msc. Adriana Karin Goelzer Leining - Universidade Federal do Paraná, Brasil
Prof. Msc. Ricardo Sérgio da Silva - Universidade Federal de Pernambuco, Brasil
Prof. Esp. Haroldo Wilson da Silva - Universidade Estadual Paulista Júlio de Mesquita Filho, Brasil
Prof. Dr. Orlando Silvestre Fragata - Universidade Fernando Pessoa, Portugal
Prof. Dr. Orlando Ramos do Nascimento Júnior - Universidade Estadual de Alagoas, Brasil
Prof^a. Dr^a. Angela Maria Pires Caniato - Universidade Estadual de Maringá, Brasil
Prof^a. Dr^a. Genira Carneiro de Araujo - Universidade do Estado da Bahia, Brasil
Prof. Dr. José Arilson de Souza - Universidade Federal de Rondônia, Brasil
Prof^a. Msc. Maria Elena Nascimento de Lima - Universidade do Estado do Pará, Brasil
Prof. Caio Henrique Ungarato Fiorese - Universidade Federal do Espírito Santo, Brasil
Prof^a. Dr^a. Silvana Saionara Gollo - Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Sul, Brasil
Prof^a. Dr^a. Mariza Ferreira da Silva - Universidade Federal do Paraná, Brasil
Prof. Msc. Daniel Molina Botache - Universidad del Tolima, Colômbia
Prof. Dr. Armando Carlos de Pina Filho- Universidade Federal do Rio de Janeiro, Brasil
Prof. Dr. Hudson do Vale de Oliveira- Instituto Federal de Educação, Ciência e Tecnologia de Roraima, Brasil
Prof^a. Msc. Juliana Barbosa de Faria - Universidade Federal do Triângulo Mineiro, Brasil
Prof^a. Esp. Marília Emanuela Ferreira de Jesus - Universidade Federal da Bahia, Brasil
Prof. Msc. Jadson Justi - Universidade Federal do Amazonas, Brasil
Prof^a. Dr^a. Alexandra Ferronato Beatrici - Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Sul, Brasil



Ano 2024

Prof^a. Msc. Caroline Gomes Mâcedo - Universidade Federal do Pará, Brasil
Prof. Dr. Dilson Henrique Ramos Evangelista - Universidade Federal do Sul e Sudeste do Pará, Brasil
Prof. Dr. Edmilson Cesar Bortoleto - Universidade Estadual de Maringá, Brasil
Prof. Msc. Raphael Magalhães Hoed - Instituto Federal do Norte de Minas Gerais, Brasil
Prof^a. Msc. Eulália Cristina Costa de Carvalho - Universidade Federal do Maranhão, Brasil
Prof. Msc. Fabiano Roberto Santos de Lima - Centro Universitário Geraldo di Biase, Brasil
Prof^a. Dr^a. Gabrielle de Souza Rocha - Universidade Federal Fluminense, Brasil
Prof. Dr. Helder Antônio da Silva, Instituto Federal de Educação do Sudeste de Minas Gerais, Brasil
Prof^a. Esp. Lida Graciela Valenzuela de Brull - Universidad Nacional de Pilar, Paraguai
Prof^a. Dr^a. Jane Marlei Boeira - Universidade Estadual do Rio Grande do Sul, Brasil
Prof^a. Dr^a. Carolina de Castro Nadaf Leal - Universidade Estácio de Sá, Brasil
Prof. Dr. Carlos Alberto Mendes Moraes - Universidade do Vale do Rio do Sino, Brasil
Prof. Dr. Richard Silva Martins - Instituto Federal de Educação, Ciência e Tecnologia Sul Rio Grandense, Brasil
Prof^a. Dr^a. Ana Lídia Tonani Tolfo - Centro Universitário de Rio Preto, Brasil
Prof. Dr. André Luís Ribeiro Lacerda - Universidade Federal de Mato Grosso, Brasil
Prof. Dr. Wagner Corsino Enedino - Universidade Federal de Mato Grosso, Brasil
Prof^a. Msc. Scheila Daiana Severo Hollveg - Universidade Franciscana, Brasil
Prof. Dr. José Alberto Yemal - Universidade Paulista, Brasil
Prof^a. Dr^a. Adriana Estela Sanjuan Montebello - Universidade Federal de São Carlos, Brasil
Prof^a. Msc. Onofre Vargas Júnior - Instituto Federal de Educação, Ciência e Tecnologia Goiano, Brasil
Prof^a. Dr^a. Rita de Cássia da Silva Oliveira - Universidade Estadual de Ponta Grossa, Brasil
Prof^a. Dr^a. Letícia Dias Lima Jedlicka - Universidade Federal do Sul e Sudeste do Pará, Brasil
Prof^a. Dr^a. Joseina Moutinho Tavares - Instituto Federal da Bahia, Brasil
Prof. Dr. Paulo Henrique de Miranda Montenegro - Universidade Federal da Paraíba, Brasil
Prof. Dr. Claudinei de Souza Guimarães - Universidade Federal do Rio de Janeiro, Brasil
Prof^a. Dr^a. Christiane Saraiva Ogrodowski - Universidade Federal do Rio Grande, Brasil
Prof^a. Dr^a. Celeide Pereira - Universidade Tecnológica Federal do Paraná, Brasil
Prof^a. Msc. Alexandra da Rocha Gomes - Centro Universitário Unifacvest, Brasil
Prof^a. Dr^a. Djanavia Azevêdo da Luz - Universidade Federal do Maranhão, Brasil
Prof. Dr. Eduardo Dória Silva - Universidade Federal de Pernambuco, Brasil
Prof^a. Msc. Juliane de Almeida Lira - Faculdade de Itaituba, Brasil
Prof. Dr. Luiz Antonio Souza de Araujo - Universidade Federal Fluminense, Brasil
Prof. Dr. Rafael de Almeida Schiavon - Universidade Estadual de Maringá, Brasil
Prof^a. Dr^a. Rejane Marie Barbosa Davim - Universidade Federal do Rio Grande do Norte, Brasil

Prof. Msc. Salvador Viana Gomes Junior - Universidade Potiguar, Brasil
Prof. Dr. Caio Marcio Barros de Oliveira - Universidade Federal do Maranhão, Brasil
Prof. Dr. Cleiseano Emanuel da Silva Paniagua - Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Brasil
Profª. Drª. Ercilia de Stefano - Universidade Federal Fluminense, Brasil

Dados Internacionais de Catalogação na Publicação (CIP)

Visão computacional em ação e sistemas multiagentes /
Anselmo Rafael Cukla; Fernanda Pinto Mota. -- São José
dos Pinhais: Editora Brazilian Journals, 2024.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui: Bibliografia

ISBN: 978-65-6016-049-1

1. Matemática. 2. Energia. 3. Consumo

I. Cukla, Anselmo Rafael. II. Mota, Fernanda Pinto.

24-210475

CDD-371.35

APRESENTAÇÃO

Sejam bem-vindos ao livro “Ambiente virtual de aprendizagem: um estudo prático sobre suas implicações”, os capítulos aqui apresentados, farão com que mergulhemos em um mundo de inovação educacional, explorando uma série de temas que abordam desde ambientes de aprendizagem até a imersão colaborativa na educação. Vamos nos aprofundar em estudos e práticas que visam enriquecer a experiência de aprendizagem, tanto em contextos presenciais quanto à distância.

Imagine um ambiente onde teoria e prática se fundem de maneira harmoniosa. O ADA-TOPOBO é um exemplo disso, integrando kits educacionais para promover uma aprendizagem mais envolvente e holística. Vamos explorar como essa abordagem tem impactado o processo de ensino e aprendizagem.

O ensino à distância tem se tornado cada vez mais comum, e plataformas como o SLOODLE estão desempenhando um papel crucial nessa transição. Vamos analisar um caso de uso específico desta plataforma e como ela tem sido eficaz na promoção da interação e do engajamento dos alunos em ambientes remotos.

A imersão é fundamental para uma aprendizagem significativa, e quando combinada com a colaboração, pode gerar resultados ainda mais poderosos. Vamos explorar um modelo de classificação para imersão colaborativa na educação e discutir como diferentes níveis de imersão podem influenciar a eficácia do processo educacional.

Por fim, vamos acompanhar em um estudo prático que utiliza equações diferenciais parciais para analisar a condução de calor em uma barra de cobre. Vamos destacar como essa abordagem prática pode enriquecer a compreensão teórica dos conceitos matemáticos envolvidos e inspirar uma aprendizagem mais contextualizada.

Em conclusão, espero que esta jornada tenha proporcionado uma visão abrangente e inspiradora sobre os diversos aspectos dos ambientes de aprendizagem e imersão na educação. Vamos continuar explorando novas formas de promover uma aprendizagem significativa e engajadora para todos os alunos.

SUMÁRIO

CAPÍTULO 1	1
SIMULANDO O IMPACTO DO CONSUMO DE ENERGIA ELÉTRICA POR MEIO DAS TÉCNICAS DE REDE COLORIDA DE PETRI E DE SISTEMAS MULTIAGENTES	
Fernanda P. Mota	
Vagner S. da Rosa	
Silvia Botelho	
Anselmo Rafael Cukla	
DOI: 10.35587/brj.ed.0002453	
CAPÍTULO 2	12
SIMULANDO O IMPACTO DO CONSUMO DE ENERGIA ELÉTRICA POR MEIO DE SISTEMAS MULTIAGENTES E DA FERRAMENTA NETLOGO	
Fernanda P. Mota	
Iverton dos Santos	
Vagner Rosa	
Anselmo Rafael Cukla	
DOI: 10.35587/brj.ed.0002454	
CAPÍTULO 3	21
SIMULANDO CONSUMIDORES DE ENERGIA ELÉTRICA POR MEIO DE SISTEMAS MULTIAGENTES	
Fernanda P. Mota	
Anselmo Rafael Cukla	
DOI: 10.35587/brj.ed.0002455	
CAPÍTULO 4	34
UM FRAMEWORK PARA SIMULAÇÃO DE POLÍTICAS PÚBLICAS APLICADO AO CASO DA PIRACEMA, SOB O OLHAR DA TEORIA DOS JOGOS	
Antonio C. da R. Costa	
Fernanda P. Mota	
Graçaliz P. Dimuro	
Iverton dos Santos	
Anselmo R. Cukla	
DOI: 10.35587/brj.ed.0002456	
CAPÍTULO 5	51
UMA COMPARAÇÃO O ENTRE MÉTODOS DE APRENDIZADO POR REFORÇO PROFUNDO APLICADOS AO CONTROLE DE UM ROBÔ MÓVEL EM AMBIENTE VERY SMALL SIZE SOCCER	
Natã Ismael Schmitt	
Maurício Moraes Godoy	
Gustavo Glass	
Bruno Silva de Castro	
Thássio Gomes Silva	
Bruno Gabriel Flores Sampaio	
Thiago A. N. De Andrade	

Anselmo Rafael Cukla
Leonardo Emmendörfer
Daniel Fernando Tello Gamarra
Gabriel Tarnowski
Fernanda Pinto Mota
DOI: 10.35587/brj.ed.0002457

CAPÍTULO 6 68
SOLUÇÃO DE VISÃO COMPUTACIONAL APLICADO A UM ROBÔ DE ESTAÇÃO
FIXA PARA SEGUIMENTO DE ALVOS

Gustavo Arthur Dutra
Anselmo R. Cukla
Solon Bevilacqua
Claudenir Rocha Alves Filho
Marcelo Serrano Zanetti
Bruno Gabriel Flores Sampaio
Fernanda Pinto Mota
Ricardo Dias Schirmer
Gabriel Tarnowski
DOI: 10.35587/brj.ed.0002458

CAPÍTULO 1

SIMULANDO O IMPACTO DO CONSUMO DE ENERGIA ELÉTRICA POR MEIO DAS TÉCNICAS DE REDE COLORIDA DE PETRI E DE SISTEMAS MULTIAGENTES

Fernanda P. Mota

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS
E-mail: nandapm2010@gmail.com

Vagner S. da Rosa

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS
E-mail: vagner.rosa@furg.br

Silvia Botelho

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS
E-mail: silviacb.botelho@gmail.com

Anselmo Rafael Cukla

Av. Roraima nº 1000, Cidade Universitária Bairro – RS, 97105-900 – Camobi, Santa Maria, RS, Brasil
E-mail: anselmo.cukla@ufsm.br

ABSTRACT: Simulation of home use of electric energy is a very powerful tool for the purpose of studying, planning and managing at electric energy distribution companies. This paper presents the initial results obtained considering two tools: the paradigm of multiagent systems (NetLogo tool) and the use of colored Petri nets by CPNTOOLS tool for the energy consumption simulation as a common resource. Thus, distinct profiles of possible behaviors of consumers and household appliances with different powers are modeled and simulated on the format of computational agents and networks with different transitions and states.

KEYWORDS: Petri Network; CPNTOOLS; Multiagent Systems; NetLogo; Energy Consumption.

1. INTRODUÇÃO

O consumo de energia é um dos principais indicadores do desenvolvimento econômico e do nível de qualidade de vida de qualquer sociedade. Ele reflete tanto o ritmo de atividade dos setores industrial, comercial e de serviços, quanto à capacidade da população para adquirir bens e serviços tecnologicamente mais avançados, como automóveis, eletrodomésticos e eletroeletrônicos [1].

Em maio deste ano o consumo cresceu 3,8% no Brasil em relação ao mesmo período do ano passado, atingindo 36,9 milgigawatts-hora (GWh). O setor residencial foi outro que teve crescimento de consumo acima da média: 4,3%. O destaque desse segmento também foi a Região Nordeste, que concentrou 36% do aumento [1].

Segundo a Aneel a expansão acentuada do consumo de energia, embora possa refletir o aquecimento econômico e a melhoria da qualidade de vida, possui aspectos negativos tais como: a possibilidade do esgotamento dos recursos utilizados para a produção de energia, o impacto ao meio ambiente produzido por essa atividade e os elevados investimentos exigidos na pesquisa de novas fontes e construção de novas usinas [2].

Neste sentido, o trabalho em questão envolve esforços direcionados em prover dados que auxiliam na análise deste tipo de situação, por meio das técnicas de simulação baseada em: Agentes e mais especificamente com suporte da ferramenta NetLogo; e Rede de Petri Colorida especialmente por meio da ferramenta CPNTOOLS. Deste modo, as seções a seguir, as quais demonstram mais detalhes desta proposta estão organizadas da seguinte maneira: seção 2 descreve resumidamente os aspectos conceituais sobre Rede Petri Colorida e da ferramenta CPNTOOLS, bem como de sistemas multiagentes e da ferramenta NetLogo; a seção 3 demonstra o modelo inicial de simulação desenvolvido em ambas as técnicas; a seção 4 relata os resultados que foram gerados pela execução do modelo em ambas as técnicas , e por fim, na seção 5 têm-se considerações finais e os trabalhos futuros.

2. REDE DE PETRI COLORIDA E SISTEMAS MULTIAGENTES

As redes de Petri podem, também, ser utilizadas para representar um modelo conceitual que descreve tanto as propriedades estáticas quanto as propriedades

dinâmicas do sistema modelado de um sistema real. As Redes de Petri são uma excelente ferramenta para modelagem de sistemas, entretanto em sistemas complexos, onde existem vários produtos distintos com processos semelhantes como protocolos de comunicação, por exemplo, elas apresentam algumas limitações [3].

As Redes de Petri Coloridas (RPC) são redes de petri de alto nível e recebem este nome porque as fichas contêm dados capazes de distinguir umas das outras. Para que uma transição esteja habilitada em uma RPC, devem existir fichas suficientes nos lugares de entrada da transição. Além disto, estas fichas devem possuir valores que sejam correspondentes às expressões dos arcos que ligam estes lugares à transição [3].

Para este trabalho optou-se pela ferramenta CPNTOOLS (Computer Tool for Coloured Petri Nets), a qual é uma ferramenta de alto nível da Rede de Petri, que suporta redes dos tipos: básicas [3], temporizadas [3] e coloridas [4]. Esta ferramenta é composta por dois componentes principais, um editor gráfico e um simulador para as redes, o que proporciona a definição de cores e as declarações de variáveis. Além disso, permite editar e analisar a sintaxe, realizar simulação automática e interativa, e por fim, analisar a performance.

Por outro lado, os Sistemas Multiagentes têm como principal característica a coletividade e não um indivíduo único, e desta forma, passa-se o foco para a forma de interação entre as entidades que formam o sistema e para a sua organização [5].

Existem diversos ambientes de programação que foram projetados para trabalhar-se com a modelagem baseada em agentes, contudo com diferentes vantagens conforme tabela 1.

Tabela 1: Comparação entre alguns ambientes de modelagem baseada em agentes

Plataformas MBA	Ascap	Mason	Repast	NetLogo	SWARM
Quantidade de Usuários	Baixa	Crescente	Grande	Grande	Baixa
Linguagem	Java	Java	Java Python	NetLogo	Java Objective C
Rapidez de execução e programação	Moderada	Mais rápido	Rápido	Moderado	Moderado
Facilidade de aprendizagem	Moderada	Moderada	Moderada	Boa	Baixa
Documentação	Boa	Pouca	Pouca	Muita	Boa

Fonte: Os autores

Neste trabalho optou-se pela ferramenta NetLogo [7], especialmente por oferecer facilidade de programação, portabilidade, documentação abundante, acesso e uso gratuitos. Nele podem ser dadas instruções a centenas ou milhares de agentes, os quais trabalham paralelamente [8]. No NetLogo pode-se, por exemplo, explorar o comportamento de um agente (micro-nível) e o que este emerge no comportamento de todo o sistema (macro-nível).

3. FUNCIONAMENTO DA FERRAMENTA

Foram modeladas quatro casas, cada uma com cinco tipos de eletrodomésticos, com respectivas características e consumos [9], conforme tabela 2 abaixo:

Tabela 2: Características e consumo dos eletrodomésticos

Equipamento	Característica	Consumo de Kw/h
Geladeira	Geladeira +Freezer com capacidade 350 Litros	1,77
Lâmpada	Lâmpada incandescente de 60watts	0,06
Chuveiro	Chuveiro no modo inverno	5.5
Televisão	Televisão de 14 polegadas	0,3
Computador	CPU + monitor	0,15

Fonte: Os autores

Foram criados quatro diferentes perfis de usuários consumidores, conforme a tabela 3 seguir:

Tabela 3: Características e perfis dos consumidores

Perfil do Consumidor	Característica
Trabalha e Economiza	Este consumidor passa um determinado período fora de casa (período de trabalho) e tem um comportamento consciente no sentido de que procura na maioria das vezes (neste caso 80%) desligar um equipamento quando para de utilizá-lo.
Não trabalha e Economiza	Este consumidor fica o tempo todo em casa (não trabalha) e tem um comportamento consciente no sentido de que procura no maior número de vezes (neste caso 80%) desligar um equipamento quando para de utilizá-lo.
Trabalha e não Economiza	Este consumidor passa um determinado período fora de casa (período de trabalho), contudo não tem um comportamento consciente no sentido de que na minoria dos casos (neste caso 20%) desliga um equipamento quando para de utilizá-lo.
Não trabalha e não Economiza	Este consumidor fica o tempo todo em casa (não trabalha), contudo não tem um comportamento consciente no sentido de que na minoria dos casos (neste caso 20%) desliga um equipamento quando para de utilizá-lo.

Fonte: Os autores

a) Características específicas do modelo de simulação CPNTOOL

O modelo de simulação de consumo de energia implementado por Rede de Petri na ferramenta CPNTOOLS, constitui-se fundamentalmente de quatro redes, detalhados a nas seções a seguir.

Consumidor 1 (Trabalha e Economiza):

Em relação à RP que representa o comportamento deste perfil de consumidor,

podem-se destacar quatro subconjuntos principais de transições e estados da rede:

- **Subconjunto A:** indica que o consumidor está trabalhando, sendo a possibilidade de 50% de o mesmo transitar nestes estados. Semelhantemente ao caso da seção anterior, a geladeira permanece sempre ligada.
- **Subconjunto B:** indica que o consumidor está em casa, possuindo também a 50% de chance para esta situação.
- **Subconjunto C:** indica quais equipamentos o consumidor pode utilizar, mais especificamente, este perfil de consumidor tem apenas 20% de chance de deixar os equipamentos ligados (econômico) após terminar de utilizá-los.
- **Subconjunto D:** indica o consumo por hora de cada equipamento conforme a Tabela 2.

Consumidor 2 (Não Trabalha e Economiza):

Em relação à RP que representa o comportamento deste perfil de consumidor, podem-se destacar dois subconjuntos principais de transições e estados da rede:

- **Subconjunto A:** indica os equipamentos que o consumidor pode utilizar e a chance de deixá-lo ligado após esta utilização. Neste caso do perfil econômico, o consumidor tem apenas 20% de chance de deixar os equipamentos ligados. No entanto, a geladeira permanece sempre ligada.
- **Subconjunto B:** indica o consumo por hora de cada equipamento conforme Tabela 2.

Consumidor 3 (Trabalha e desperdiça):

Em relação à RP que representa o comportamento deste perfil de consumidor, podem-se destacar quatro subconjuntos principais de transições e estados da rede:

- **Subconjunto A:** indica que o consumidor está trabalhando, sendo a possibilidade de 50% de o mesmo transitar nestes estados. Semelhantemente ao caso da seção anterior, a geladeira permanece sempre ligada.
- **Subconjunto B:** indica que o consumidor está em casa, possuindo também a 50% de chance para esta situação.
- **Subconjunto C:** indica quais equipamentos o consumidor pode utilizar, mais especificamente, este perfil de consumidor tem 80% de chance de deixar os equipamentos ligados (não econômico) após terminar de utilizá-los.
- **Subconjunto D:** indica o consumo por hora de cada equipamento conforme a Tabela 2.

Consumidor 4 (Não Trabalha e desperdiça):

Em relação à RP que representa o comportamento deste perfil de consumidor, podem-se destacar dois subconjuntos principais de transições e estados da rede:

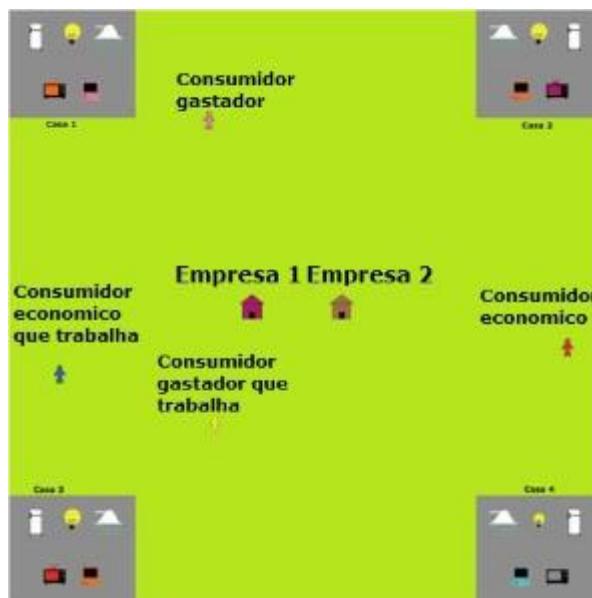
- **Subconjunto A:** indica quais equipamentos o consumidor pode utilizar e a chance de deixá-lo ligado após esta utilização. Neste caso do perfil não economico, o consumidor tem 80% de chance de deixar os equipamentos ligados, ao terminar de utilizá-los. Como anteriormente, a geladeira permanece sempre ligada.
- **Subconjunto B:** indica o consumo por hora de cada equipamento conforme Tabela 2.

4. MODELO DE SIMULAÇÃO NO NETLOGO NIDEKI

O modelo de simulação de consumo de energia baseado no paradigma de agentes e implementado na ferramenta NetLogo, possui os mesmos comportamentos probabilísticos do modelo elaborado na RP, contudo utilizando as abstrações específicas desta metáfora, pode-se dizer que (Figura1):

- Os quatro perfis de usuário, bem como os eletrodomésticos são modelados como agentes computacionais. Especificamente no que se refere ao NetLogo, podem-se implementar perfis diferentes de agentes por meio da criação de distintas breeds. Estas representam a idéia de espécies de agentes, onde cada uma incorpora um conjunto de diferentes instruções a serem executados, como por exemplo, na simulação de uma colméia os agentes da espécie operária possuem comportamentos distintos da espécie rainha.
- O ambiente também possui duas empresas, representando a situação onde os agentes se deslocam para o trabalho e permanecem no mesmo por um período de 8 horas.

Figura 1: Interface do modelo de simulação na interface NetLogo que simula o consumo de energia elétrica dos quatro tipos de consumidores com os cinco tipos de eletrodomésticos em cada casa



Fonte: Os autores

5. RESULTADOS

Em ambos os modelos de simulação supracitados foram realizadas vinte simulações, onde cada uma refere-se ao período de vinte e quatro horas na rotina dos diferentes perfis de consumidores. A tabela 3 abaixo relaciona os resultados médios de consumo em kilowatts obtidos em cada perfil.

Tabela 3: Consumo médio de cada consumidor

Consumidores	Média Netlogo	Média Petri
Consumidor 1	66,295	74,6065
Consumidor 2	67,745	73,201
Consumidor 3	63,6368	78,731
Consumidor 4	73,45	87,2375

Fonte: Os autores

Deve-se observar que ocorreu uma pequena diferença entre os modelos, onde em uma análise constatou-se que esta alteração ocorria pela discrepância do consumo de energia do chuveiro (5,5kw/h) em relação aos outros, conforme Tabela 2. Assim, se uma simulação for executada e, por exemplo, o chuveiro for ligado duas vezes no modelo NetLogo e uma vez no CPNTOOLS, dado a característica

probabilística ocasiona-se uma diferença no consumo geral da casa em cada modelo. Deste modo, geramos os resultados sem considerar o uso do mesmo, onde o consumo tornou-se mais próximo, conforme Tabela 4, demonstrando que os modelos são equivalentes.

Tabela 4: Consumo médio de cada consumidor considerando o chuveiro

Consumidores	Média Netlogo	Média Petri
Consumidor 1	44,06	45,273
Consumidor 2	44,68	45,456
Consumidor 3	51,79	51,978
Consumidor 4	180	64,3

Fonte: Os autores

Por fim, se pode observar que o consumo máximo de todas as casas foi obtido pelo consumidor 4, que não economiza e não trabalha. Por sua vez, o mínimo consumido foi obtido pelo consumidor 1, o qual trabalha e economiza.

6. CONCLUSÃO

Como demonstrado nos resultados pode-se dizer que tanto a utilização do paradigma de agentes por meio da ferramenta NetLogo, quanto da rede de Petri Colorida através da ferramenta CPNTOOLS demonstram-se como alternativas promissoras para simulações de cenários de perfis de usuários de energia elétrica. Pois os diversos comportamentos inerentes a sociedade utilitária deste serviço pode ser mapeado respectivamente em diferentes tipos de agentes, os quais são inseridos em uma ambiente virtual ou através de diferentes redes com transições e estados.

Contudo, no que se refere aos recursos providos por cada ferramenta, em nossa experiência de implementação, constatou-se uma maior dificuldade de construção sobre a ferramenta CPNTOOLS, principalmente quando a falta de representação gráfica para os resultados, mas tem como vantagem que ela dispensa conhecimentos específicos em programação. Por sua vez o NetLogo conta positivamente com representação visual dos componentes do modelo, gerar resultados por meio de gráficos, porém necessita de conhecimentos específicos em programação.

Por fim, acredita-se que o modelo apresentado embora simplificado, indica positivamente para continuidade e futuros trabalhos. Assim, os próximos passos referem-se em ampliar o modelo com mais eletrodomésticos e eletrônicos, assim como um maior número de perfis de consumidores a serem analisados.

REFERÊNCIAS

1. Consumo de Energia. Consumo de energia elétrica cresce no Brasil e Belo Monte é garantia para essa demanda 29 junho 2012 . Disponível em <http://www.multiner.com.br/multiner/Default.aspx?TabId=117>. Acessado em julho de 2012.
2. Aneel. Energia no Brasil e no mundo, Atlas de Energia Elétrica do Brasil. Disponível em: www.aneel.gov.br/arquivos/pdf/livro_atlas.pdf, acessado em julho de 2012.
3. Cardoso, Janette; Valette, Robert. Redes de Petri. Florianópolis, 1997.
4. Gonçalves, Éder M. N. Uma Abordagem para Especificação de Conhecimento para Sistemas Multiagentes Cognitivos. Florianópolis, 2006.
5. Dimuro, G. P., Costa, A. C. R., and Palazzo, L. A. M. Systems of exchange values as tools for multi-agent organizations. Journal of the Brazilian Computer Society, 11(1):3150, 2005.
6. Sapkota, P. Modeling Diffusion Using an Agent-Based Approach. PhD thesis, University of Toledo, 2010.
7. Tisue, S. and Wilensky, U. NetLogo: A simple environment for modeling complexity. In International Conference on Complex Systems, Boston, 2004.
8. Wilensky, U. NetLogo. <http://ccl.northwestern.edu/netlogo/>. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL, 1999.
9. Aneel. Aprenda a calcular o consumo de seu aparelho e economize energia, 2011.
10. Carla Katarina de Monteiro Marques (2008) Realocação Dinâmica de Recursos em Clusters de Servidores Web Utilizando Sistemas Multiagentes, Universidade Federal do Ceará, Fortaleza, Ceará.
11. Gilbert, N. and Troitzsch, K. G. (2005) Simulation for the Social Scientist. Open University Press.
12. Newton C. Braga (1966). O Consumo da Energia Elétrica (EL015), Escrevendo sobre Tecnologia para as principais revistas do mundo desde 1966.
13. Parunak, H. v. D. and Savit, R. and Riolo, R. L. Agent-Based Modeling vs. Equation-Based Modeling: A Case Study and Users' Guide. In: Multi-Agent Systems and Agent-Based Simulation First International Workshop, MABS'98, Paris, France, July 4-6, 1998. Proceedings. Springer, Berlin, 1998.
14. Russel S.; Norvig P. (2003) Artificial Intelligence: A modern approach, 2nd edition, Pearson Education.

CAPÍTULO 2

SIMULANDO O IMPACTO DO CONSUMO DE ENERGIA ELÉTRICA POR MEIO DE SISTEMAS MULTIAGENTES E DA FERRAMENTA NETLOGO

Fernanda P. Mota

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS
E-mail: nandapm2010@gmail.com

Iverton dos Santos

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS
E-mail: iverton.santos@gmail.com

Vagner Rosa

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS
E-mail: ac.rocha.costa@gmail.com

Anselmo Rafael Cukla

Departamento de Processamento de Energia Elétrica, Universidade Federal de Santa Maria (UFSM)
Av. Roraima nº 1000 Cidade Universitária Bairro – RS, 97105-900 – Camobi, Santa Maria, RS, Brasil
E-mail: anselmo.cukla@ufsm.br

RESUMO: Ferramentas para a simulação de situações habituais e não habituais de uso de energia elétrica são úteis tanto para as geradoras/distribuidoras para fins de planejamento e gestão quanto para os consumidores para fins de controle. Este trabalho demonstra os resultados iniciais obtidos a partir da utilização do paradigma de sistemas multiagentes especificamente pela ferramenta NetLogo para a simulação do consumo de energia elétrica como um recurso comum. Assim, distintos perfis de comportamentos possíveis dos consumidores e dos eletrodomésticos com diferentes potências são modelados e simulados sobre o formato de agentes computacionais.

PALAVRAS-CHAVE: Sistemas Multiagentes; NetLogo; Consumo de Energia Elétrica; Tragédia dos Comuns.

ABSTRACT: Tools for simulating situations of usual and unusual use of electricity are useful both for generating / distribution for purposes of planning and management as to consumers for control. This paper demonstrates the initial results obtained from the use of the paradigm of multi-agent systems specifically for NetLogo tool for the simulation of energy consumption as a common resource. Thus, distinct profiles of possible behaviors of consumers and household appliances with different powers are modeled and simulated on the format of computational agents.

KEYWORDS: Multiagent Systems; NetLogo; Electricity Consumption.

1. INTRODUÇÃO

O consumo de energia é um dos principais indicadores do desenvolvimento econômico e do nível de qualidade de vida de qualquer sociedade. Ele reflete tanto o ritmo de atividade dos setores industrial, comercial e de serviços, quanto à capacidade da população para adquirir bens e serviços tecnologicamente mais avançados, como automóveis, eletrodomésticos e eletroeletrônicos.

Em maio deste ano o consumo cresceu 3,8% no Brasil em relação ao mesmo período do ano passado, atingindo 36,9 milgigawatts-hora (GWh) [Consumo de energia elétrica, 2012]. O setor residencial foi outro que teve crescimento de consumo acima da média: 4,3%. O destaque desse segmento também foi a Região Nordeste, que concentrou 36% do aumento.

Segundo a Aneel a expansão acentuada do consumo de energia, embora possa refletir o aquecimento econômico e a melhoria da qualidade de vida, possui aspectos negativos tais como: a possibilidade do esgotamento dos recursos utilizados para a produção de energia, o impacto ao meio ambiente produzido por essa atividade e os elevados investimentos exigidos na pesquisa de novas fontes e construção de novas usinas [Aneel, 2012].

Neste sentido, o trabalho em questão envolve esforços direcionados em prover dados que auxiliam na análise deste tipo de situação, especialmente por meio da técnica de simulação baseada em Agentes e mais especificamente com suporte da ferramenta NetLogo. Deste modo, as seções a seguir, as quais demonstram mais detalhes desta proposta estão organizadas da seguinte maneira: seção 2 descreve resumidamente os aspectos conceituais sobre sistemas multiagentes e da ferramenta NetLogo; a seção 3 demonstra o modelo inicial de simulação desenvolvido; a seção 4 relata os resultados que foram gerados pela execução deste modelo, e por fim, na seção 5 têm-se considerações finais e os trabalhos futuros.

2. SISTEMAS MULTIAGENTES E NETLOGO

No contexto de Inteligência Artificial, podem-se definir agentes como entidades computacionais que, inseridos em um ambiente, são capazes de perceber e atuar sobre o mesmo. Um agente computacional possui atributos como operar sob controle

autônomo, perceber seu ambiente, persistir por um período de tempo, adaptar-se a mudanças e ser capaz de assumir metas. [Russel S.; Norvig P., 2003]

Existem diversos ambientes de programação que foram projetados para trabalhar-se com a modelagem baseada em agentes, contudo com diferentes vantagens conforme tabela 1.

Tabela 1: Comparação entre alguns ambientes de modelagem baseada em agentes [Sapkota 2010]

Plataformas MBA	Ascap	Mason	Repast	NetLogo	SWARM
Quantidade de Usuários	Baixa	Crescente	Grande	Grande	Baixa
Linguagem	Java	Java	Java Python	NetLogo	Java Objective C
Rapidez de execução e programação	Moderada	Mais rápido	Rápido	Moderado	Moderado
Facilidade de aprendizagem	Moderada	Moderada	Moderada	Boa	Baixa
Documentação	Boa	Pouca	Pouca	Muita	Boa

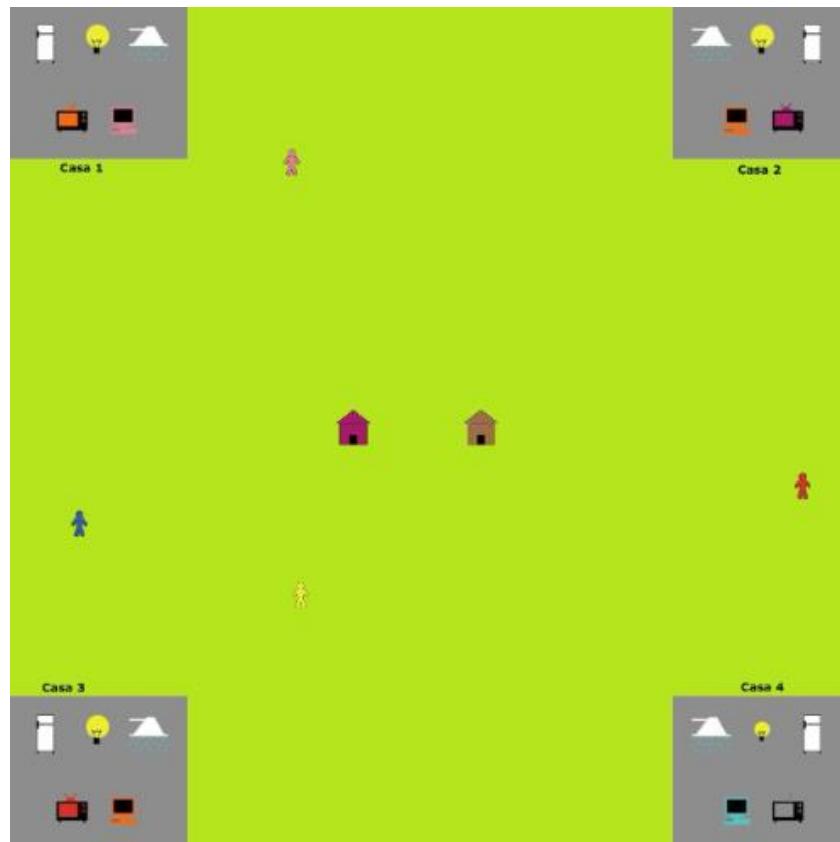
Fonte: Os autores

Neste trabalho optou-se pela ferramenta NetLogo [Tisue and Wilensky 2004], especialmente por oferecer facilidade de programação, portabilidade, documentação abundante, acesso e uso gratuitos. Nele podem ser dadas instruções a centenas ou milhares de agentes, os quais trabalham paralelamente [Wilensky, U., 1999]. No NetLogo pode-se, por exemplo, explorar o comportamento de um agente (micro-nível) e o que este emerge no comportamento de todo o sistema (macro-nível).

3. MODELO DE SIMULAÇÃO

O modelo de simulação de consumo de energia baseado no paradigma de agentes o qual foi implementado na ferramenta Netlogo consta com os seguintes elementos, conforme figura 1:

Figura 1: Interface do modelo de simulação na interface NetLogo



Fonte: Os autores

3.1 EQUIPAMENTOS ANALISADOS

Foram modeladas quatro casas, cada uma com cinco tipos de eletrodomésticos, com respectivos características e consumos [Aneel, 2011], [Newton C. Braga, 1966], conforme tabela 2 abaixo:

Tabela 2: Características e consumo dos eletrodomésticos [Aneel, 2011]

Equipamento	Característica	Consumo de Kw/min
Geladeira	Geladeira +Freezer com capacidade 350 Litros	0,0295
Lâmpada	Lâmpada incandescente de 60watts	0,001
Chuveiro	Chuveiro no modo inverno	0,0917

Televisão	Televisão de 14 polegadas	0,005
Computador	CPU + monitor	0,0025

Fonte: Os autores

3.2 USUÁRIOS CONSUMIDORES

Foram criados quatro diferentes tipos de usuários consumidores, conforme a tabela 3 seguir:

Tabela 3: Características e perfis dos consumidores

Consumidor	Tipo de Consumidor	Característica
1	Trabalha e Economiza	Este consumidor passa um determinado período fora de casa (período de trabalho) e tem um comportamento consciente no sentido de que procura sempre desligar um equipamento quando para de utilizá-lo.
2	Não trabalha e Economiza	Este consumidor fica o tempo todo em casa (não trabalha) e tem um comportamento consciente no sentido de que procura sempre desligar um equipamento quando para de utilizá-lo.
3	Trabalha e não Economiza	Este consumidor passa um determinado período fora de casa (período de trabalho), contudo não tem um comportamento consciente no sentido de que na maioria dos casos não desliga um equipamento quando para de utilizá-lo.
4	Não trabalha e não Economiza	Este consumidor fica o tempo todo em casa (não trabalha), contudo não tem um comportamento consciente no sentido de que na maioria dos casos não desliga um equipamento quando para de utilizá-lo.

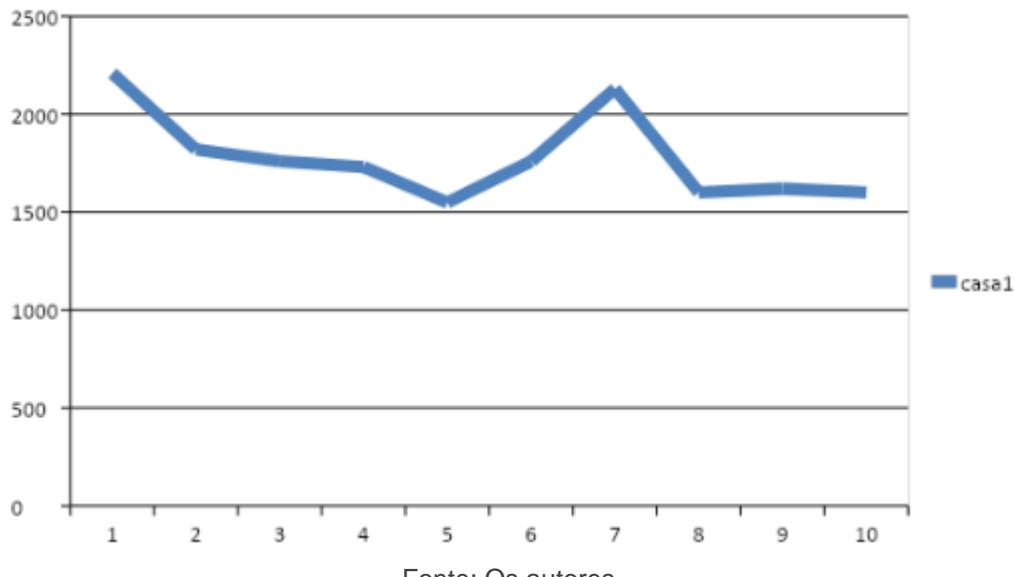
Fonte: Os autores

4. RESULTADOS PRELIMINARES NO MODELO INICIAL

Foram avaliados os quatro perfis de usuários, sobre a execução de dez simulações, conforme pode ser visto nos perfis abaixo:

Consumidor 1 (Trabalha e economiza): Conforme Figura 2, este perfil teve um consumo médio de 1778 kw/min .

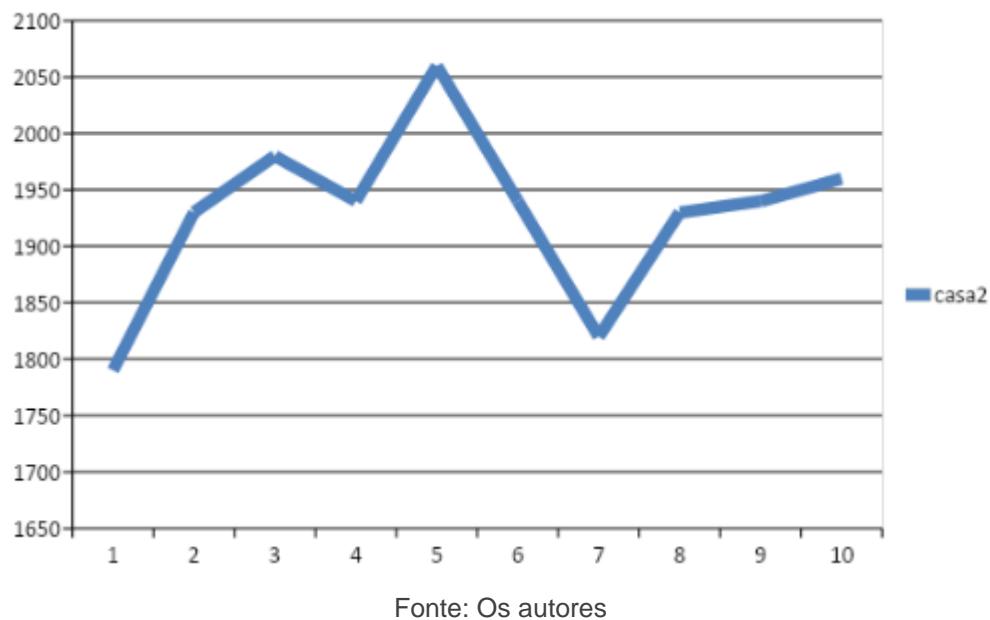
Figura 2: Consumo de energia elétrica do consumidor que economiza e trabalha



Fonte: Os autores

Consumidor 2 (Não trabalha e Economiza): Conforme Figura 3, este perfil teve um consumo médio de 1929 kw/min.

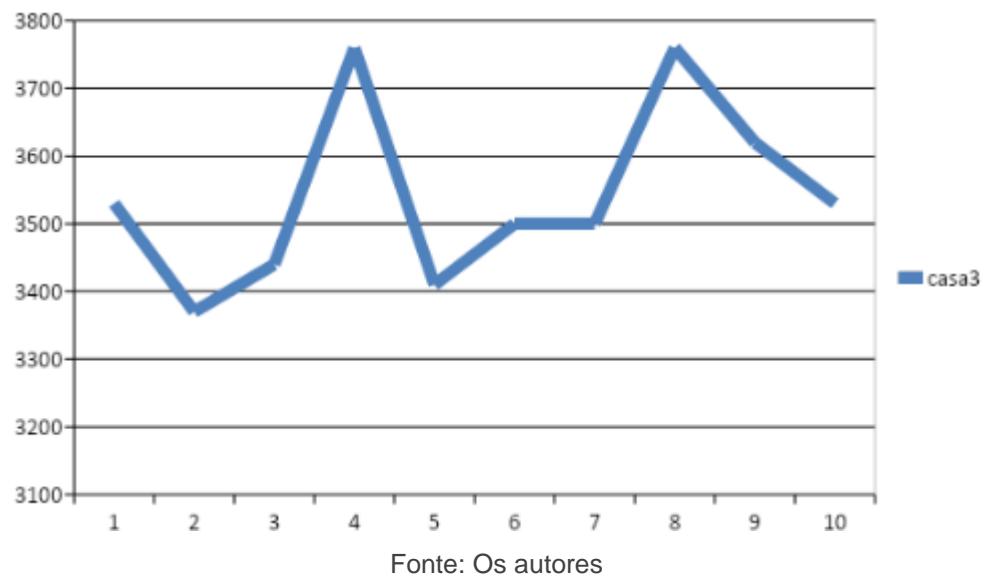
Figura 3: Consumo de energia elétrica do consumidor que economiza e não trabalha



Fonte: Os autores

Consumidor 3 (Trabalha e Não economiza): Conforme Figura 4, este perfil teve um consumo médio de 3542kw/min.

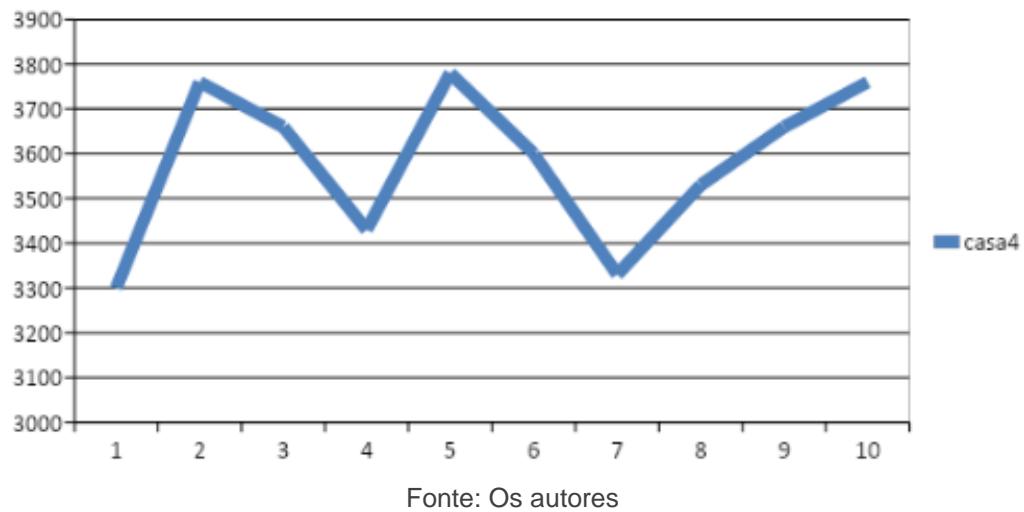
Figura 4: Consumo de energia elétrica do consumidor que Não economiza e trabalha



Fonte: Os autores

Consumidor 4 (Não Trabalha e Não economiza): Conforme Figura 5, este perfil teve um consumo médio de 3581.

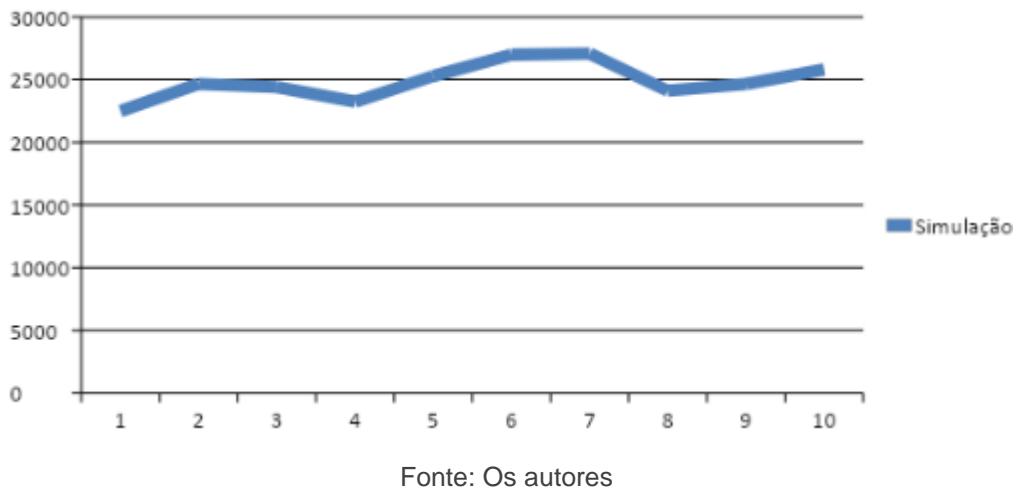
Figura 5: Consumo de energia elétrica do consumidor que Não economiza e Não trabalha



Fonte: Os autores

Assim, a energia total de 10867kw/min disponibilizada mensalmente, esgotou-se em 24869 minutos, conforme Figura 6.

Figura 6: Energia total disponibilizada mensalmente



Fonte: Os autores

5. CONCLUSÃO

Como demonstrado nos resultados pode-se dizer que a utilização do paradigma de agentes bem como da ferramenta NetLogo é uma alternativa interessante para simulações de cenários de perfis de usuários de energia elétrica. Pois os diversos comportamentos inerentes a sociedade utilitária deste serviço pode ser mapeado respectivamente em diferentes tipos de agentes os quais são inseridos em uma ambiente virtual.

Enfatizamos que estes resultados são reduzidos a escopo de um teste inicial, neste sentido estamos buscando referencias de uma quantidade produzida real, para futuramente mapearmos em nosso recurso comum. No entanto, esta avaliação indica positivamente para futuros trabalhos com mais elementos e maior número de perfis a serem analisados, sendo este a motivação para os próximos passos de nosso trabalho.

Como trabalhos futuros serão criadas casas com perfis diferentes: muitos eletrodomésticos, poucos eletrodomésticos, eletrodomésticos antigos, eletrodomésticos modernos também considera-se ampliação do modelo para indústrias. Outra perspectiva é o teste considerando punições que afetem o comportamento dos agentes, como por exemplo, as multas por excesso de consumo de energia.

REFERÊNCIAS

Aneel (2012). Energia no Brasil e no mundo, Atlas de Energia Elétrica do Brasil. Disponível em: www.aneel.gov.br/arquivos/pdf/livro_atlas.pdf, acessado em julho de 2012.

Aneel, (2011). Aprenda a calcular o consumo de seu aparelho e economize energia, 2011.

Consumo de energia elétrica (2012), Consumo de energia elétrica cresce no Brasil e Belo Monte é garantia para essa demanda 29 junho 2012. Disponível em <http://www.multiner.com.br/multiner/Default.aspx?TabId=117>. acessado em julho de 2012.

Gilbert, N. and Troitzsch, K. G. (2005) Simulation for the Social Scientist. Open University Press.

Newton C. Braga (1966). O consumo da energia elétrica (EL015), Escrevendo sobre Tecnologia para as principais revistas do mundo desde 1966. 1966.

Parunak, H. v. D. and Savit, R. and Riolo, R. L. Agent-Based Modeling vs. Equation-Based Modeling: A Case Study and Users' Guide. In: Multi-Agent Systems and Agent-Based Simulation First International Workshop, MABS'98, Paris, France, July 4-6, 1998. Proceedings. Springer, Berlin, 1998.

Russel S.; Norvig P. (2003) Artificial Intelligence: A modern approach, 2nd edition, Pearson Education.

Sapkota, P. (2010). Modeling Diffusion Using an Agent-Based Approach. PhD thesis, University of Toledo.

Tisue, S. and Wilensky, U. (2004). NetLogo: A simple environment for modeling complexity. In International Conference on Complex Systems, Boston.

Wilensky, U. (1999). NetLogo. <http://ccl.northwestern.edu/netlogo/>. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL.

CAPÍTULO 3

SIMULANDO CONSUMIDORES DE ENERGIA ELÉTRICA POR MEIO DE SISTEMAS MULTIAGENTES

Fernanda P. Mota

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS

E-mail: nandapm2010@gmail.com

Anselmo Rafael Cukla

Departamento de Processamento de Energia Elétrica, Universidade Federal de Santa Maria (UFSM)

Av. Roraima nº 1000 Cidade Universitária Bairro – RS, 97105-900 – Camobi, Santa Maria, RS, Brasil

E-mail: anselmo.cukla@ufsm.br

RESUMO: A obtenção de dados de consumo de energia elétrica em unidades consumidoras individuais é difícil de ser obtida por diversas razões como, por exemplo, aspectos de privacidade. Este artigo propõe a construção de um framework para simulação de consumidores residenciais de energia elétrica (simulou-se apenas dias de semana, não considerou-se finais de semana) com base nos conceitos de sistemas multiagentes, mais especificamente utilizou-se a ferramenta NetLogo. O framework simula o consumo residencial durante todos os dias da semana exceto os finais de semana (apenas dias úteis). Este trabalho apresentou como resultado uma ferramenta para a simulação e análise de consumo de energia elétrica utilizando a abordagem de agentes e alguns estudos de caso.

PALAVRAS-CHAVE: Sistemas Multiagentes; Simulação Computacional; Consumo de Energia Elétrica.

ABSTRACT: The electric energy consumption data of individual home use is hard to obtain due to several reasons, such as privacy issues. This article proposes a tool for simulating residential consumers of electric energy (was simulated only weekdays, being dismissed weekends), based on multiagent systems concepts using the NetLogo tool. The tool presented as results a tool for simulating and analysis of electric energy consumption by means of a agent systems approach and some case studies.

KEYWORDS: Multiagent Systems; NetLogo; Electricity Consumption.

1. INTRODUÇÃO

O consumo de energia é um dos principais indicadores do desenvolvimento econômico e do nível de qualidade de vida de qualquer sociedade. Ele reflete tanto o ritmo de atividade dos setores industrial e comercial, quanto à capacidade da população para adquirir bens e serviços tecnologicamente mais avançados, como automóveis e eletroeletrônicos. No entanto, a expansão acentuada do consumo de energia elétrica, embora possa refletir o aquecimento econômico e a melhoria da qualidade de vida, possui aspectos negativos tais como: a possibilidade do esgotamento dos recursos utilizados para a produção de energia, o impacto ao meio ambiente produzido por essa atividade e os elevados investimentos exigidos na pesquisa de novas fontes e construção de novas usinas [ANEEL, 2012].

A análise do aumento do consumo de energia no setor residencial é complexo, visto que envolve a observação de várias variáveis inerentes ao comportamento do consumidor, como por exemplo, tempo médio de uso dos equipamentos, [Hasen, 2000]. Fontes de consumo de energia elétrica (todos os equipamentos que geram consumo dentro da residência) não são medidas individualmente, o que gera desconhecimento para a maioria das pessoas a respeito do consumo de cada equipamento que está conectado a rede de energia elétrica. Devido a isso é difícil construir um modelo que relate as pessoas (comportamento/hábitos) com os eletrodomésticos (consumo). Uma das abordagens possíveis é o uso dos dados médios do Programa de Organização Familiar (uma iniciativa do governo para gerar dados do comportamento da população em vários aspectos, também é conhecido como POF) para construir uma metodologia do comportamento dos consumidores de energia elétrica [POF, 2010].

Tendo em vista os aspectos acima levantados, faz-se necessária a adoção de uma metodologia de pesquisa relacionada à infraestrutura elétrica que seja capaz de fornecer subsídios para tomadas de decisão quanto ao planejamento urbano e o uso energético. Pretende-se por meio deste trabalho, averiguar o uso da técnica de simulação baseada em agentes e da ferramenta NetLogo como mecanismos para a construção de um ferramenta que fornecerá dados que auxiliam na análise do consumo de energia, bem como realizar uma pesquisa buscando verificar os aspectos relacionados ao consumo de energia elétrica do setor residencial e sua relação com

o seu nível de desperdício (nível de consciência que o agente tem sobre economia de energia, ou seja, quanto maior a porcentagem menor será o nível de consciência e maior a chance da pessoa esquecer algum equipamento ligado durante o período que estiver fora de casa ou dormindo) e o número de equipamentos associados a cada residência.

Neste sentido, o trabalho em questão envolve esforços direcionados em prover dados que auxiliam na análise deste tipo de situação, por meio das técnicas de simulação baseada em agentes e mais especificamente com suporte da ferramenta NetLogo. Deste modo, as seções a seguir, as quais demonstram mais detalhes desta proposta estão organizadas da seguinte maneira: seção 2 descreve resumidamente os aspectos conceituais sobre sistemas multiagentes e a ferramenta NetLogo; a seção 3 demonstra o modelo inicial de simulação desenvolvido; a seção 4 relata os resultados que foram gerados pela execução do modelo e por fim, na seção 5 têm-se considerações finais e os trabalhos futuros.

2. SISTEMAS MULTIAGENS E NETLOGO

Modelo baseado em agentes consiste nas interações entre os agentes e entre estes e o ambiente. A simulação baseada em agentes (*Agent-Based Simulation – ABS*) se caracteriza pela utilização de uma grande quantidade de agentes que podem interagir uns com os outros, com pouca ou nenhuma coordenação centralizada. Além disso, a ABS possibilita a interação dos agentes (pessoas, nações ou organizações) entre si e com seu ambiente. Obtendo com isso, uma abordagem que possibilita o entendimento do comportamento do sistema – sociedades artificiais. Este enfoque tem se mostrado bastante promissor, notadamente na compreensão de sistemas complexos [Azevedo and Meneze, 2007].

No contexto de Inteligência Artificial, agentes podem ser definidos como entidades computacionais que são inseridos em um ambiente e que podem perceber (sensores) e atuar (atuadores) sobre ele. Um agente possui atributos para controlar-se de forma autônoma, perceber o ambiente, persistir por um período, adaptar-se a mudanças e assumir metas, [Russel and Norvig, 2003].

Além disso, os agentes também tornam possível a modelagem de situações nas quais as pessoas têm comportamentos diferentes e complexos, podendo levar

em conta tanto as propriedades quantitativas (parâmetros numéricos) quanto qualitativas (comportamento individual) do sistema. É importante ressaltar que mesmo em um modelo simples é possível perceber o comportamento complexo que emerge das interações e estas informações são importantes para a dinâmica do sistema[Azevedo and Meneze, 2007]. A simulação no computador é utilizada para descobrir propriedades do modelo e com isso ganhar entendimento de um processo dinâmico, o que seria muito difícil de modelar com técnicas matemáticas padrões, [Axelrod, 1996]. Portanto, estes agentes podem ser modelados de duas formas [Bittencourt, 1998]:

Agentes reativos: são agentes simples que só possuem estímulo de resposta (têm comportamento de ação/reAÇÃO), geralmente não têm memória das suas ações, não planejam suas ações futuras e não se comunicam com os outros agentes. Normalmente as sociedades de agentes reativos são numerosas, com populações da ordem de milhares de membros e a inteligência destes agentes ocorre quando eles estão em grupo, ou seja, por meio das ações do grupo.

Agentes cognitivos: são baseados em organizações sociais humanas, ou seja, os agentes possuem uma representação explícita do ambiente e dos outros agentes e dispõem de memória (podem planejar suas ações. O número de membros em uma sociedade de agentes cognitivos, em geral, é menor que o número de agentes reativos.

Os Sistemas Multiagentes têm como principal característica a coletividade e não um indivíduo único, e desta forma, passa-se o foco para a forma de interação entre as entidades que formam o sistema e para a sua organização [Dimuro et. al, 2005]. Existem diversos ambientes de programação que foram projetados para trabalhar-se com a modelagem baseada em agentes, contudo com diferentes vantagens conforme Tabela 1.

Tabela 1: Comparação entre alguns ambientes de modelagem baseada em agentes [Sapkota,2010]

Métrica\Plataforma	Ascap	Mason	Repast	NetLogo	SWARM
Quantidade de Usuários	Baixa	Crescente	Grande	Grande	Baixa
Linguagens	Java	Java	Java Python	NetLogo	Java Objective C
Velocidade de Execução e Programação	Média	Mais Rápida	Rápida	Média	Média
Facilidade de Aprendizagem	Média	Média	Média	Média	Média
Documentação	Boa	Pouca	Pouca	Muita	Boa

Fonte: Os autores

Neste trabalho optou-se pela ferramenta NetLogo [Tissue and Wilenski, 2004], especialmente por oferecer facilidade de programação, portabilidade, documentação abundante, acesso e uso gratuitos. Nela podem ser dadas instruções a centenas ou milhares de agentes, os quais trabalham paralelamente [Wilenski, 1999].

3. MODELO DE SIMULAÇÃO DE CONSUMIDORES DE ENERGIA

O modelo de simulação dos consumidores de energia elétrica em residências baseado no paradigma de agentes e implementado na ferramenta NetLogo possui as seguintes características:

Os consumidores e os eletrodomésticos foram modelados como agentes computacionais racionais, ou seja, se um equipamento já estiver ligado eles não irão ligar novamente até que o mesmo seja desligado. Especificamente no que se refere ao NetLogo, podem-se implementar perfis diferentes de agentes por meio da criação de distintas breeds (species);

Os agentes que representam os usuários podem ficar um período de tempo dormindo, este pode variar de 0 até 8 horas de sono e podem esquecer alguns equipamentos ligados neste periodo;

Os agentes que representam os usuários podem ficar um período de 0 até 8 horas fora de casa e podem esquecer alguns equipamentos ligados neste periodo;

O consumo de energia de cada equipamento foi calculado de acordo com os dados fornecidos pelas distribuidoras de energia *Light* [Light, 2013];

Consumidores (agentes): podem ficar consumindo enquanto não estão ativos

(dormindo e fora de casa) ou ativos (acordados) de forma semelhante ao Método B, porém, o período que ele permanece fora de casa não é mais fixo, o agente pode ficar por um período aleatório fora ou dormindo;

Lista do consumo médio (W.min): é uma entrada do modelo que tem o consumo dos equipamentos que serão simulados e cada residência decide quantos equipamentos ela irá possuir a partir da lista de consumo médio de entrada;

Lista de tempo médio de simulação: contém o tempo médio que cada equipamento ficará ligado e varia de acordo com o tamanho da lista de consumo médio definida pelo usuário;

Nível de desperdício: o usuário pode escolher a porcentagem de desperdício que cada residência terá (quanto maior a porcentagem maior será a chance dos consumidores esquecerem os equipamentos ligados quando saírem de casa ou quando forem dormir);

Número máximo de pessoas por residência: permite que o usuário defina qual será o tamanho máximo da família durante a simulação, porém, durante o processo de criação das famílias esse atributo é definido de forma aleatória (com um membro e no máximo o tamanho definido pelo usuário) para todas as famílias não tenham o mesmo tamanho;

Tempo que os consumidores ficarão dormindo, acordado e fora de casa: os agentes decidem (aleatório) quanto tempo eles ficaram em casa (acordados e dormindo) e quanto tempo eles ficarão fora de casa (podem esquecer um equipamento ligado quando saem de casa);

Controle de equipamentos ligados: lista de equipamentos que cada consumidor deseja ligar;

Lista de todos os equipamentos que serão ligados na residência: lista com todos os equipamentos que os consumidores desejam ligar. Esta lista é feita por meio de uma operação lógica or entre as listas de controle dos consumidores daquela residência;

Controle para religar os equipamentos: após verificar qual é o tempo mínimo de consumo todos os equipamentos ligados consomem por esse período. Após esse período o equipamento é retirado da lista e escolhe-se o menor tempo de consumo dentre os equipamentos que ainda permanecem ligados e todos os equipamentos consumem por esse período. Este processo será repetido até que a lista fique vazia.

Depois deste processo os agentes observam se estão ativos ainda, caso estejam eles ligam outros equipamentos e o processo de consumo é repetido;

Alguns equipamentos (como a geladeira e o *freezer*) não são controlados pelos agentes. Neste caso, na simulação considera-se que eles permanecem ligados por 24 horas por dia simulado, consumindo de acordo com o ciclo de trabalho de cada um desses equipamentos.

3.1 DEFINIÇÃO DOS AGENTES E AS INTERAÇÕES NO MODELO

Os agentes que representam as residências (agentes reativos) são responsáveis pelo controle do consumo, ou seja, eles reagem à vontade dos consumidores (ligar algum equipamento) e retornam o consumo daquele equipamento. E os agentes que representam os consumidores são responsáveis por ligar os equipamentos, ou seja, eles expressam sua vontade de ligar determinados equipamentos e as residências retornam como resultado o consumo. Assim, as residências sabem quantos equipamentos elas possuem e quais estão ligados. Além disso, também verificam a cada período quais equipamentos os consumidores ligaram ou desligaram e como resultado desta interação elas retornam o consumo total de cada residência.

A função consumo pede para a casa verificar qual é o tempo mínimo dentro daquela lista de consumo, o tempo médio que os equipamentos ficarão ligados e qual é o equipamento que possui o menor tempo de consumo. Feita essa análise, todos os equipamentos ficam consumindo por esse tempo. Após esse período, o equipamento é retirado da lista e um novo tempo mínimo é definido, esse processo é feito até que a lista esteja vazia.

Quando a lista está vazia a residência verifica se os consumidores ainda estão ativos, se estiverem ativos os consumidores escolhem outros equipamentos para ligar e passam a nova lista de equipamentos ligados para a residência que passa a consumir energia elétrica desta. Este processo é repetido até que o tempo máximo que os agentes permanecem ativos. Após esse período os agentes ficam inativos e podem esquecer alguns equipamentos ligados, caso isso ocorra os equipamentos permanecem ligados por um período determinado pela função *random-poisson* (a partir do tempo médio de consumo determinado na lista de entrada), caso ele não

esqueça nenhum equipamento ligado o tempo que ele fica inativo é apenas contado e o único consumo gerado é o da geladeira e do freezer.

O modelo apresentou como vantagens: a possibilidade de inserir tamanhos diferentes de listas de consumo médio de equipamentos, análise do consumo de acordo com o nível de desperdício, famílias com tamanho definido pelo usuário, tempo aleatório para os consumidores ficarem em casa, dormindo ou fora de casa. No entanto, apresentou alguns problemas: uma simulação para cada renda que deseja-se simular e uma simulação para cada estação do ano.

4. RESULTADOS

Os resultados do modelo foram avaliados em três situações (agentes com 10% de economia, agentes com 50% de economia e agentes com 90% de economia, ou seja, quanto maior a porcentagem menor será o nível de economia) e a renda está implícita nos equipamentos que estão disponíveis na lista de consumo no arquivo de entrada.

A lista de entrada pode ser observada na Tabela 2 o consumo e o tempo foram dispostos, respectivamente, em kWh/min e minutos e foi baseada na tabela de consumo disponível em [Light, 2013]. As entradas foram configuradas conforme a Figura 1.

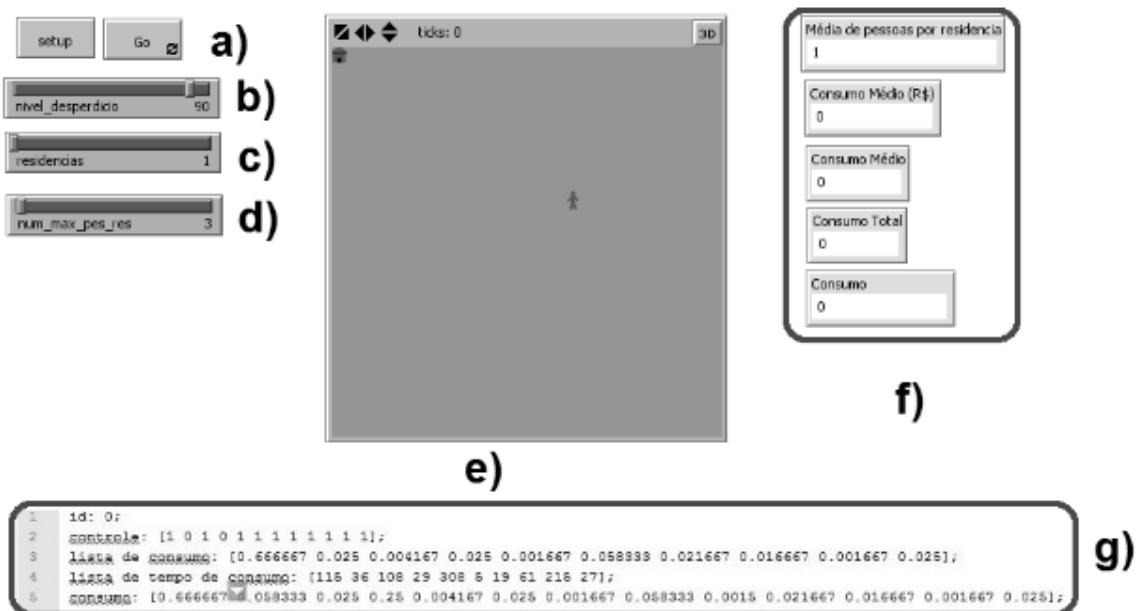
Tabela 2: Tabela Modificada da Light, *Tempo Médio de 24 horas diárias para geladeira, considerado de forma diferente ao valor da tabela original; ** considerou-se banhos de aproximadamente 8 minutos [Light, 2013]

Eletrodomésticos	Potencia Média (W)	Número de dias de uso/mês	Tempo médio de uso por dia (min)	Consumo Mensal (kwh)	Consumo Mensal (kwh/min)
Ar-Condicionado	12000 BTUS	30	120	240	0,07
*Freezer	400	30	600	120	0,01
*Geladeira	200	30	600	60	0,00
Secadora de Roupas	3500	12	60	42	0,06
Lava-Louças	1500	30	40	30	0,03
Cafeteira Elétrica	1000	30	30	15	0,02
Computador	250	30	120	15	0,00
Forno elétrico	1500	20	30	15	0,03

Lâmpada Incandescente	100	30	300	15	0,00
Chuveiro	3500	30	8	14	0,06
Televisão	90	30	300	13,5	0,00
Forno de Microondas	1300	30	20	13	0,02
Ferro Elétrico	1000	12	60	12	0,02
Ventilador	100	30	240	12	0,00
Lava-Roupas	1500	12	30	9	0,03

Fonte: Os autores

Figura 1: A) são os botões para inicializar o ambiente; B) nível-desperdício: nível de desperdício dos consumidores, quanto mais alto maior será a probabilidade dos consumidores esquecerem os equipamentos ligados; C) Residências: define qual será o número total de residências que serão simuladas; D) num-max-pes-res: número máximo de pessoas por residência; E) Ambiente gráfico de simulação, demonstra as ações dos consumidores; F) Resultado total do consumo em kWmin e em R\$; G) Resultado do consumo de uma residência em um arquivo texto



Fonte: Os autores

No estudo de caso considerou-se o consumo de 10 residências no período 24 horas durante 30 dias, com um número máximo de 3 pessoas por residência. Pode-se observar que conforme a simulação vai evoluindo as residências mudam de cor para demonstrar quais agentes estão consumindo enquanto estão acordados, dormindo ou fora de casa e não foram simuladas as famílias com mais de três pessoas por residência porque optou-se por dados de número médio de pessoas por família obtidos a partir da literatura (aproximadamente 3 pessoas por residência, [POF,

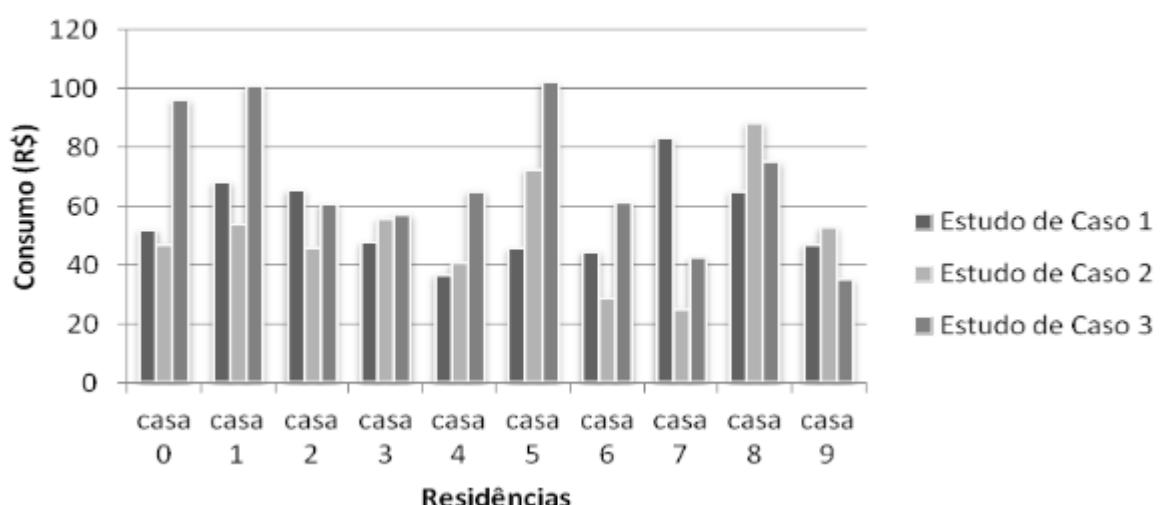
2010]).

O método tem como saída o consumo energético por residência por minuto e o consumo médio de todas as residências simuladas. A saída pode ser observada tanto nos monitores da ferramenta quanto no arquivo de saída, Figura 1. Além disso, cada equipamento tem seu consumo em kWmin e seu consumo é gerado a cada minuto de simulação. Por fim, todos os equipamentos tem a mesma probabilidade de serem escolhidos.

Os cenários simulam o comportamento dos consumidores e seu respectivo consumo de acordo com a avaliação do nível de economia dos agentes, ou seja quanto menor for o nível mais econômico o consumidor será. Após as 10 simulações para cada estudo de caso pode-se analisar que os consumidores com nível de economia de 10 % e 50% tiveram um comportamento similar, o que pode ser justificado pelo fato de que os consumidores mais econômicos têm uma média maior de equipamentos (Figura 2). Além disso, os consumidores do primeiro estudo de caso têm o comportamento similar que com o segundo estudo de caso, já que trata-se de consumidores mistos, ou seja que podem comportarem-se de forma similar aos consumidores econômicos consumidores com 50 % de economia.

Figura 2: Gráfico que demonstra a média de equipamentos por estudo de caso

Média de Consumo dos Estudos de Caso



Fonte: Os autores

5. CONCLUSÕES E TRABALHOS FUTUROS

Considera-se que o tema da dissertação é de grande interesse, pois ajuda na atualização dos dados de consumo de energia elétrica por meio dos resultados da ferramenta de simulação do comportamento dos consumidores de energia elétrica que está sendo proposta nesta dissertação. Além do mais, possibilita a análise do consumo de energia elétrica no setor residencial nos vários segmentos sociais. Sendo assim, acredita-se que a análise do comportamento dos consumidores residenciais de energia elétrica poderá ser de grande valia, tanto para a área de planejamento do setor elétrico como para o planejamento do desenvolvimento urbano.

Foi demonstrado que a obtenção de dados reais de consumo de energia elétrica no país envolve dados sigilosos dos consumidores, que são de difícil obtenção. Entretanto, neste trabalho optou-se pelo POF porque ele é um estudo que possibilita a análise de vários temas do Brasil, das grandes regiões e das situações urbanas e rurais do país. Além disso, este programa é baseado em dados que foram coletados em todo o território brasileiro (urbano e rural) que permite a análise dos gastos, rendimentos e do consumo das famílias brasileiras, mas encontrou-se um problema relacionado a falta de dados como o desvio padrão para as médias que foram fornecidas, o que limita a utilidade estatística dos dados.

Os resultados desta metodologia foram obtidos a partir da simulação de dois métodos propostos na Seção 5 que demonstram que o consumo de energia elétrica no Método A varia de acordo com as rendas das famílias, ou seja, quanto mais equipamentos maior é o consumo, o que condiz com os resultados esperados de acordo com os dados obtidos a partir da literatura [POF, 2010]. Já no Método B foi analisado o comportamento dos consumidores de acordo com o número de equipamentos e o nível de desperdício dos consumidores o que demonstrou que o consumo é maior quando os consumidores tendem a economizar menos.

Assim, conforme pode ser observado nos resultados apresentados, a utilização do paradigma de agentes bem como da ferramenta NetLogo é uma alternativa viável para simulações de cenários de perfis de usuários de energia elétrica. Isto se deve ao fato de que diversos comportamentos inerentes à sociedade utilitária deste serviço pode ser mapeado respectivamente em diferentes tipos de agentes, os quais são inseridos em uma ambiente virtual.

REFERÊNCIAS

Abushakra, B. and Claridge, D. E. (2001), "Accounting for the Occupancy Variable in Inverse Building Energy Baseline Models", In Proceeding of the International Conference for Enhanced Building Operations (ICEBO).

ANEEL, 2012. "Atlas de Energia Elétrica do Brasil," [Http:// www.aneel.gov.br/ arquivos/pdf/livro_atlas.pdf](http://www.aneel.gov.br/arquivos/pdf/livro_atlas.pdf), Dezembro

Axelrod, R. (1996), "The complexity of cooperation: agent-based models of competition and collaboration", Princeton Univ. Press.

Azevedo, L. L. and Meneze, C. S. (2007), "NetPlay – uma ferramenta para construção de modelos de simulação baseado em multiagente", XVIII Simpósio Brasileiro de Informática na Educação, SBIE, Mackenzie.

Bittencourt, G. (1998), "Inteligência Artificial Distribuída", Departamento de Automação e Sistemas. Universidade Federal de Santa Catarina.

Degelman, L. O. (2001), "A Model for Simulation of Daylighting and Occupancy Sensors as an Energy Control Strategy for Office Buildings", In Proceeding of the International Conference for Enhanced Building Operations (ICEBO).

Dimuro, G. P. and Costa, A. C. R. and Palazzo, L. A. (2005), "Systems of exchange values as tools for multi-agent organizations," In: journal of the Brazilian Computer Society, 11(1):3150.

Ha, D.L. and Ploix, S. and Zamai, E. and Jacomino, M. (2006), "A Home Automation System to Improve Household Energy Control", 12th IFAC Symposium on Information Control Problems in Manufacturing, St Etienne, France.

Hansen, A. M. D. (2000). "Padrões de Consumo de Energia Elétrica em Diferentes Tipologias de Edificações Residenciais, em Porto Alegre", Master-thesis, UFRGS, Porto Alegre.

Jinlong, O. and Kazunori, H. (2009), "Energy-saving potential by improving occupant's behaviour in urban residential sector", Hangzhou City, China.

Kashif, A. and Ploix, S. and Dugdale, J. and Le, X. H. B (2012), "Simulating the Dynamics of Occupant Behaviour for Power Management in Residential Buildings", Energy and Buildings International Journal.

Klein, L. and Kavulya, G. and Jazizadeh, F. and Kwak, J. and Becerik-Gerber, B. and Tambe, M. (2011), "Towards optimization of building energy and occupant comfort using multi-agent simulation", International Symposium on Automation and Robotics in Construction.

Le, X. H. B. and Kashif, A. and Ploix, S. and Dugdale, J. and Mascolo, M. D. and Abras, S. (2010), "Simulating inhabitant behaviour to manage energy at home", International Building Performance Simulation Association. Conference , Moret-sur-Loing, France.

POF (2010), "Pesquisa de Orçamentos Familiares 2008–2009. Despesas, Rendimentos e

Condições de Vida", Instituto Brasileiro de Geografia e Física. Rio de Janeiro.

Raaij, W.F. V. and Verhallen, T.M.M. (1983), "A behavioural model of residential energy use", A behavioural model of residential energy use, Journal of Economic Psychology.

Russel, S. and Norvig, P.(2003) , "Artificial Intelligence: A modern approach", Book, Publisher: Pearson Education .

Sapkota, P. (2010), "Modeling Diffusion Using an Agent-Based Approach, " PhD thesis, University of Toledo, 2010

Tisue, S. and Wilensky, U. (2004)" Netlogo: A simple environment for modeling complexity, " In International Conference on Complex Systems, Boston, 2004.

Wilensky, U. (1999) "NetLogo, ", Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. <http://ccl.northwestern.edu/netlogo>.

CAPÍTULO 4

UM FRAMEWORK PARA SIMULAÇÃO DE POLÍTICAS PÚBLICAS APLICADO AO CASO DA PIRACEMA, SOB O OLHAR DA TEORIA DOS JOGOS

Antonio C. da R. Costa

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS
E-mail: ac.rocha.costa@gmail.com

Fernanda P. Mota

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS
E-mail: nandapm2010@gmail.com

Graçaliz P. Dimuro

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS
E-mail: gracaliz@gmail.com

Iverton dos Santos

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS
E-mail: iverton.santos@gmail.com

Anselmo R. Cukla

Departamento de Processamento de Energia Elétrica, Universidade Federal de Santa Maria (UFSM)
Av. Roraima nº 1000 Cidade Universitária Bairro – RS, 97105-900 – Camobi, Santa Maria, RS, Brasil
E-mail: anselmo.cukla@ufsm.br

RESUMO: Este artigo ilustra a utilização de um modelo e um framework para simulação de Políticas Públicas baseado no paradigma de sistemas multiagentes. Para isso, utiliza-se um estudo de caso baseado no problema clássico abordado na Teoria dos Jogos, chamado Tragédia dos Comuns. Mais especificamente, lida-se com as Políticas Públicas de defeso, estabelecidas durante o período da Piracema.

PALAVRAS-CHAVE: Políticas públicas; Sistemas Multiagentes; Simulação Computacional.

ABSTRACT: This paper shows the utilization of a model and a simulation framework for public policies based on the paradigm of multi-agent systems. For this, we use a case study drawn from the classical problem Tragedy of the Commons addressed in game theory. More specifically, we deal with the closed Public Policy established during Piracema.

KEYWORDS: Public policies; Multi-agent systems; Computer simulation.

1. INTRODUÇÃO

De acordo com [SILVA; TROTTMAN; et al, 2011], formular Políticas Públicas tornou-se um grande desafio aos gestores públicos, uma vez que suas ações têm consequências diretas na vida dos cidadãos, seja promovendo benfeitorias, o que representa um ótimo retorno de investimento público – tanto do ponto de vista dos recursos como tempo, dinheiro e energia, despendidos pelo Estado, quanto do ponto de vista das melhorias nas vidas dos beneficiados direta ou indiretamente pela política; seja representando um mau negócio, que acarreta desperdício de recursos – materiais e humanos – e o consequente fracasso no alcance das metas estabelecidas para atender às demandas cidadãs.

Nesta perspectiva, como é descrito por [DESOUZA; LIN, 2011], desenhar Políticas Públicas exige o emprego de esforços na busca de soluções que consigam diminuir as possibilidades de erros em um cenário complexo, envolto por inúmeras condições e fatores que mudam a cada momento, como é o *sistema* de Políticas Públicas.

Com isso, é oportuno dizer que, por meio da técnica de simulação com Sistemas Multiagentes, pode-se contribuir neste sentido, pois são utilizadas ferramentas capazes de simular a realidade e sua evolução ao longo do tempo, permitindo ajustes na tentativa de encontrar uma solução para o problema enfrentado.

Não obstante, após um busca na literatura, identificou-se uma série de trabalhos que focam em construir simulações multiagente específicas para tratar problemas pontuais, como de Políticas Públicas para saúde, transito e meio-ambiente. No entanto, pode-se dizer que embora sendo possível relacionar estes projetos, até o momento não se encontrou na literatura (além do projeto MSPP, onde este trabalho está incluído) esforços direcionados ao desenvolvimento de um modelo, bem como um *framework* para simulações de Políticas Públicas baseadas em agentes, num sentido instrumental geral. Igualmente, não se encontraram trabalhos voltados, especificamente, para a implementação dos mesmos com suporte sobre as ferramentas Jason e CArtAgO.

Assim, considerando a evolução do potencial expressivo destas ferramentas para a simulação multiagente, a insuficiência instrumental constatada e o desafio supracitado na elaboração de Políticas Públicas, elaborou-se um modelo

baseado em agentes, bem como um framework com as construções que o implementam. Nas próximas seções são detalhados os conceitos e os elementos estruturais mais importantes dos mesmos. Também demonstram-se resultados de uma simulação de um estudo de caso onde utilizou-se os mesmos para simular Políticas Públicas de Defeso para a Piracema sobre uma perspectiva da Tragédia dos comuns abordada em Teoria dos Jogos.

2. POLÍTICAS PÚBLICAS

O trabalho de elaboração de um modelo e framework para simulação do processo de Políticas Públicas passou necessariamente por etapas de estudos sobre a definição conceitual de Política Pública, bem como dos principais modelos teóricos na área.

De forma geral, uma política é um conjunto de princípios que orientam e/ou condicionam decisões e ações dos agentes atuantes no contexto em questão, especialmente no que diz respeito às ações de utilização dos recursos disponíveis neste contexto [EASTON, 1965].

Por sua vez, Políticas Públicas são relativas à utilização de recursos públicos ou sociais, usualmente geridos pelo governo estabelecido na mesma [HILL, 2009]. Segundo [LOPES, B.; J, AMARAL.; CALDAS, R, 2008], para atingir resultados em diversas áreas e promover o bem-estar da sociedade, os governos se utilizam das Políticas Públicas, onde os autores definem da seguinte forma: “(...) Políticas Públicas são um conjunto de ações e decisões do governo, voltadas para a solução (ou não) de problemas da sociedade (...).”

Ainda, de acordo com [SILVEIRA, 2007], Políticas Públicas podem ser entendidas como um conjunto de normas que orientam práticas e respaldam os direitos dos indivíduos em todos os níveis e setores da sociedade. Elas devem ter como base os princípios da igualdade e da equidade, disseminando o sentido de justiça social. Por meio delas, os bens e serviços sociais são distribuídos e redistribuídos, de maneira a garantir o direito coletivo e atender às demandas da sociedade.

Tradicionalmente, o estudo das Políticas Públicas se faz com base em um conceito de *ciclo de política*, que envolve diversas etapas pelas quais a criação e

operação de uma política passam, tais como [HILL, 2009]:

identificação e formulação da questão a ser tratada, no contexto socioeconômico em foco;

formulação e análise de soluções alternativas, isto é, das possíveis políticas para o tratamento da questão;

escolha de uma solução para ser implementada, isto é, escolha da política a ser implementada;

implementação da política;

monitoração e avaliação dos efeitos da política e consequente revisão/reformulação da mesma.

Ao se analisar as etapas do modelo de ciclo de política, constata-se que as mesmas passam necessariamente utilização de mecanismos que estratifiquem informações sobre a sociedade, assim como de ferramentas capazes de alterar as condições da mesma. Estes mecanismos são respectivamente denominados segundo [HOOD, 2007] como os instrumentos do governo, mais especificamente o autor os classifica como detectores e efetuadores.

Segundo [HOOD, 2007], detectores são todos os instrumentos que o governo utiliza para captar informação e efetuadores são todos os instrumentos que o governo usa para impactar o mundo que governa. O autor caracteriza um esquema denominado “NATO” no qual o governo fundamenta seus detectores e efetuadores, representando respectivamente:

Nodality: a forma com que o governo está inserido na rede social;

Authority: o que permite o governo ter comando sobre os atores sociais (denota a posse do poder legal ou oficial);

Treasure: isto é, o conjunto de recursos financiáveis que o governo usa como suporte a suas tentativas de influenciar a estrutura e funcionamento do sistema social;

Organization: isto é, o conjunto de recursos não-financiáveis que o governo utiliza ao tentar influenciar a estrutura e o funcionamento do sistema social.

3. JASON E CARTAGO

O Jason (A Java-based AgentSpeak Interpreter Used with Saci For Multi-Agent Distribution Over the Net) [BORDINI; HUBNER; WOOLDRIDGE, 2007] permite a

implementação de agentes cognitivos baseados na arquitetura BDI (Belief, Desires and Intentions) [RAO; GEORGEFF, 1992], sendo a programação realizada na linguagem AgentSpeak(L) e inclui comunicação entre agentes baseada na teoria de atos de fala [BORDINI; VIEIRA, 2003]. Outra característica da plataforma é possibilitar que um sistema multiagente possa ser executado de maneira distribuída em uma rede com a utilização do SACI (*Simple Agent Communication Infrastructure*) [BORDINI; HUBNER; WOOLDRIDGE, 2007] ou da plataforma JADE [KRZYSZTOF; MACIEJ, 2005]. Além disso, Jason é multi-plataforma (característica herdada de sua implementação em Java) e está disponível sob licença GNU GPL.

Já o CartAgO (Common ARTifact infrastructure for AGents Open environments) [RICCI; SANTI; PIUNTI; et al, 2010] é um *framework* que possibilita a implementação de ambientes virtuais para sistemas de agentes. Conceitualmente, o **CArtAgO** é baseado no meta-modelo *Agents & Artefacts* (A&A)[OMICINI; RICCI; VIROLI, 2008] para modelar sistemas multiagentes. Este modelo introduz uma metáfora de alto nível retirada da ideia de que humanos trabalham de forma cooperativa com o seu ambiente: agentes são como entidades computacionais que realizam algum tipo de tarefa orientada para alcançar um objetivo (em analogia aos trabalhadores humanos), e artefatos são como recursos e ferramentas dinamicamente construídas, manipuladas e compartilhadas pelos agentes para dar suporte e realizarem suas atividades individuais e coletivas (como artefatos no contexto humano).

4. MODELO E FRAMEWORK

Com base nas definições de Políticas Públicas vistas na seção anterior, considerou-se os elementos principais que compõem uma Política Pública, a qual foi objetivada e implementada na dupla forma de um conjunto de normas (essencialmente obrigações e proibições), assim como em um conjunto de planos de ação. Formalmente, tem-se então que uma política pública é um par $PolPub=(Nrms, PIns)$, onde $PolPub$ é a política pública, $Nrms$ é o conjunto de normas e $PIns$ é o conjunto de planos.

As normas de obrigação e proibição, consideradas até o momento, assumem fundamentalmente o seguinte conteúdo:

Id: o identificador da norma;

Destinatário: especifica o papel ao qual a norma se aplica;

Ação: especifica uma ação a ser realizada pelo agente que assume o papel ao qual a norma foi endereçada;

Condição: especifica uma condição contextual necessária para a aplicação da norma;

Periodicidade: especifica o evento que deve ocorrer (mês, semana, ou uma ação específica) para que se verifique a condição;

Exceção: especifica uma condição na qual a norma não se aplica;

Sanção: especifica a sanção a ser aplicada no caso da violação da norma.

Por sua vez, os planos delegados correspondem à estruturação de planos utilizada no Jason, portanto:

Id: o identificador do plano;

Contexto: a condição contextual necessária para aplicação do plano;

Corpo: especifica o corpo do plano, ou seja, o conjunto de ações a ser executada;

Periodicidade: especifica o evento que deve ocorrer (mês, semana, ou uma ação específica) para que se verifique a condição, assim é um elemento opcional.

Já no que se refere aos agentes envolvidos no processo de ciclo de política, identificou-se os seguintes tipos básicos de agentes:

agentes emissores de políticas, com capacidade de expressar formalmente as políticas para os agentes envolvidos na execução da mesma (neste modelo parcial, considerou-se um único agente emissor de política, chamado agente *Governo*);

agentes sociais, que buscam atingir objetivos próprios, de forma que para tal necessitam usufruir de recursos disponibilizados no contexto em questão, os quais são geridos pelas normas da política. Assim, estes devem seguir a política, contudo esta sujeição pode ser conflitante com seus critérios intrínsecos de comportamento, gerando possíveis infrações.

agentes governamentais detectores, que desempenham a função de captar informações complementares da política, extraíndo informações do contexto em questão. Estas podem servir como referência para o processo de gestão de políticas públicas. Os detectores podem ser de dois subtipos fundamentais:

detectores que captam informações referentes ao comportamento dos agentes sociais (verificando se estão cumprindo as normas da política);

detectores responsáveis por capturar dados referentes a características e propriedades de recursos do ambiente.

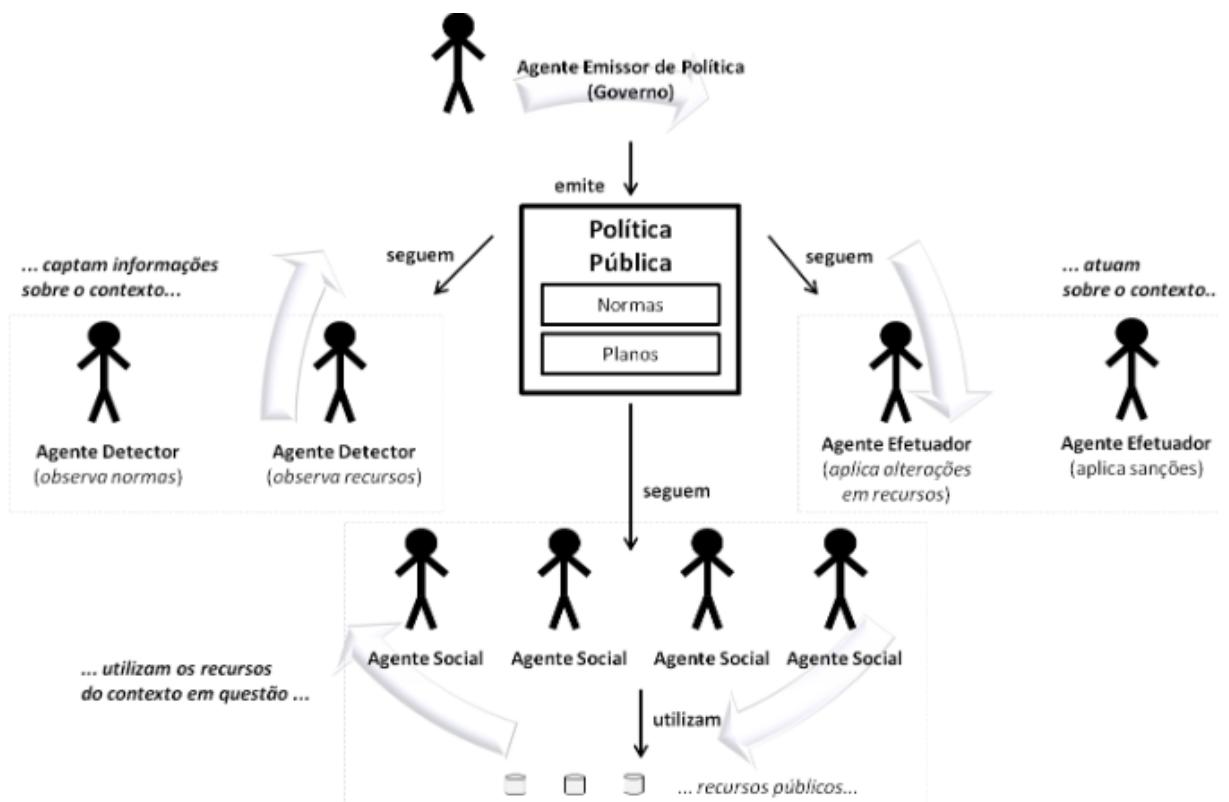
agentes governamentais efetuadores, que desempenham a função de intervenções complementares a política, instruídos por planos, bem como pelas normas. Os efetuadores também possuem dois subtipos fundamentais:

efetuadores que realizam a efetiva aplicação de sanções/penalidades aos agentes que descumpriam normas;

efetuadores que alteram características dos recursos do ambiente, por meio de ampliação, redução ou remoção.

Assim, uma definição de modelo inicial para apoio à simulação de políticas pressupõe, então, que esses quatro tipos de agentes estejam presentes na simulação, os quais interagindo promovem o ciclo de política, conforme mostrado na Fig. 1.

Figura 1: Arquitetura preliminar do modelo baseado em agentes para o processo de simulação de Políticas Públicas



Dado este modelo inicial, foi elaborada uma primeira versão do *framework* que prove sua implementação por programação. Neste, uma política pública e seus componentes se concretizam no formato de artefatos CArtAgO (dispostos em uma API com classes Java que especializam artefatos). Por sua vez, os agentes identificados (emissor de política, agentes sociais, detectores e efetuadores) possuem um conjunto pré-definido de comportamentos para interpretação, manipulação e raciocínio, estes que foram concretizados em um conjunto de planos AgentSpeak (dispostos em uma biblioteca de planos). Já os recursos públicos, devem ser providos no ambiente também na forma de um artefato CArtAgO, o qual deve prover na forma de operações as funcionalidades correspondentes.

Assim, para definir uma simulação multiagente com base e suporte deste modelo e seu *framework*, deve-se definir políticas e recursos públicos sobre os moldes daqueles artefatos no ambiente a ser simulado, bem como definir agentes que devem ser programados fundamentalmente sobre a estrutura básica daquele conjunto de planos. Mais especificamente, foram elaborados os seguintes artefatos: **NormObrg**, **NormPrb** e **Plan** os quais possuem as operações **criar**, **modificar**, e **remover**, para respectivamente criar, modificar e remover o conteúdo das normas e planos. Mais detalhes em nível de implementação, bem como do comportamento dos agentes frente às normas, podem ser encontrados em trabalho prévio [SANTOS, COSTA, 2012].

5. ESTUDO DE CASO: TRAGÉDIA DOS COMUNS E PIRACEMA SOBRE O OLHAR DA TEORIA DOS JOGOS

Um problema clássico socioeconômico estudado em Teoria dos Jogos é a Tragédia dos comuns (um caso particular do dilema dos prisioneiros com múltiplos jogadores), no qual agentes racionais utilizam um recurso comum até seu esgotamento, este que foi citado inicialmente por [HARDIN, 1968], e tem sido inspiração na elaboração de Políticas Públicas para gestão de recursos ambientais.

Em [TOCANTINS et. al., 2011] apresenta-se um cenário relacionado à pesca nas regiões tropicais do país, no qual o produto da pesca é propriedade comum e de livre acesso, tornando o manejo pesqueiro uma tarefa difícil. Trata-se de um assunto em que a natureza por si só não dá conta de resolver o assunto dado o seu contexto

político e socioeconômico. Neste sentido, ocorrem intervenções governamentais, as quais implicam na existência de regras ou códigos para definir a ação da comunidade, caso contrário os interesses individuais levariam o sistema a um colapso econômico-ecológico, pois os indivíduos, racionalmente, não iriam optar pela colaboração em sistemas de recursos comuns [LOPES, CAMILO, et. al., 2010].

Ainda no contexto das intervenções governamentais na gerencia dos recursos pesqueiros, podem-se citar os esforços na elaboração de Políticas Públicas para o fenômeno denominado Piracema. Este ocorre quando os peixes sobem as cabeceiras para desova ficando mais expostos e facilmente capturáveis. No entanto, este período é primordial, pois se refere diretamente a reprodução e consequentemente disponibilidade de novos cardumes para pesca, de modo que se for interrompido irá ocasionar a extinção das espécies e consequentemente do recurso natural.

Mais especificamente a política pública elaborada pelo governo na tentativa de solucionar este problema concretizou-se por meio da Lei nº 7.679, de 23 de novembro de 1988 conhecida como a Lei do Defeso [LEI 7.679, 1988], a qual é estabelecida anualmente pelo IBAMA. A seguir, descreve-se um cenário real de aplicação da política pública de defeso, para o caso da Piracema na região dos rios goianos, de acordo com [REVISTA PESCA, 2012].

A Piracema já começou e até 28 de fevereiro de 2012 fica permitida somente a pesca para subsistência (cota de três quilos por pescador para consumo no local) e a científica. Neste período prevalece à proibição de pesca em embarcações nos rios goianos. Durante a Piracema, a maioria das espécies nativas sobe os rios em cardumes para acasalamento e reprodução. Por isso, a Secretaria de Meio Ambiente e dos Recursos Hídricos (Semarh) fiscaliza e restringe a pesca. A proibição entrou em vigor no dia 1º de novembro. Para pescar neste período, é necessária (assim como em qualquer época do ano) a obtenção de licença de pesca. Além disso, é preciso ficar atento ao volume de pescado e ao fato de não poder transportá-lo.

A pesca só pode ser feita utilizando linha de mão ou vara, caniço simples, com molinete ou carretilha, com iscas naturais ou artificiais (a utilização dos anzóis múltiplos somente será permitida com iscas artificiais, na modalidade de arremesso e corriço). É terminantemente proibida à utilização de iscas naturais exóticas à bacia e a pesca nas lagoas marginais das bacias hidrográficas dos rios Araguaia/Tocantins, Paranaíba e São Francisco (entende-se por lagoas marginais, áreas de alagados, alagadiços, lagos, banhados, canais ou poços naturais que recebem águas dos rios ou de outras lagoas em caráter permanente ou temporário).

Durante a Piracema fica proibida qualquer atividade de pesca além da supracitada, inclusive o uso de qualquer tipo de material predatório, limitadas as quantidades de peixes embarcados assim como obediência rigorosa ao tamanho mínimo de captura. Também fica proibido o transporte de pescado, exceto aquele proveniente de aquicultura, ou seja, aqueles correlacionados as atividades de despesca, o transporte, a comercialização, o beneficiamento, a industrialização e o armazenamento do pescado das espécies provenientes de pisciculturas devidamente registradas na Semarh(Secretaria do Meio Ambiente e dos Recursos Hídricos) ou órgão ambiental competente, acompanhados da comprovação de origem do pescado.

O descumprimento destas condições sujeita o infrator à multa, apreensão do material de pesca, embarcação e processo administrativo. A Semarh mantém a fiscalização nos rios e estradas de acesso. Apesar do rigor da lei, muitos pescadores ainda não entenderam a necessidade de respeitar a Piracema e continuam praticando a pesca ilegalmente, juntando-se aos demais poluidores, predadores e trazendo por consequência a crescente falta de peixes a cada novo ano. Para o pescador consciente e que respeita não apenas a lei dos homens, mas principalmente a lei da natureza, este período é uma excelente oportunidade para praticar o pesque-e-solte em nossos rios.

5.1 MODELO DE SIMULAÇÃO ELABORADO

A partir do cenário e lei supracitados, porém limitando-se as idiossincrasias do modelo e framework elaborados, formulou-se o modelo de simulação com os elementos e características conforme as tabelas a seguir:

Tabela 1: Recurso Comum Rio

População de Peixes	Recurso comum com característica finita compartilhado pelos agentes sociais.
peixes:43200	Representa uma população de peixes da mesma espécie, com peso de cada peixe igual a 1kg.
periodo: piracema	Período da Piracema.
taxa_rep: 0.2	Taxa de reprodução dos peixes no período da Piracema.
unid_min: 7200	Unidades mínimas que necessitam permanecer no rio para que o rio continue sustentável. A mesma é utilizada para determinar a política.
ext:100	Área total de extensão do rio, correspondendo a 100 km.

Fonte: Os autores

Tabela 2: Agentes Sociais

Pescadores	São agentes racionais, ou seja, buscam a estratégia que lhes oferece maior recompensa. As quais correspondem às diferentes técnicas de pesca representadas aqui por técnica “a” e “b”. Neste caso específico, foram considerados 100 agentes pescadores.
tec_a: 1	A técnica de pesca “a” representa a pesca com anzol e outros métodos artesanais e subtraem um número menor de unidades da o do rio. Assim, estabeleceu-se que a mesma oferece 1 unidade de recompensa para o agente.
tec_b: 5	A técnica de pesca “b” representa a pesca com outros métodos mais agressivos e maior capacidade de captura (exemplo redes de arrasto), subtrai um número maior de unidades do rio. Assim, estabeleceu-se que a mesma implica em uma maior recompensa para o agente, neste caso 5 unidades, portanto, o agente tende a optar por esta técnica.
freq_pesc: 3	Número de vezes que um agente pesca por dia. Considerando que este é racional e a freqüência máxima de pesca é 3 vezes por dia (manhã, tarde e noite) o mesmo irá optar pela maximização do período de exploração.
qtd_min_sub: 3	Quantidade mínima necessária para sobrevivência de cada agente

Fonte: Os autores

Tabela 3: Agentes Detectores e Efetuadores

Fiscal	Agente responsável por monitorar o cumprimento das normas da Política Pública. Para este caso, atribui-se a este agente a dupla função de detector e atuador, neste sentido ele percebe infrações bem como aplica as penalidades.
plan(trecho, freq) trecho:10 freq: 3	plan: Plano que o mesmo utiliza para a fiscalização. Onde: freq: Número de vezes que um agente monitora o ambiente. trecho: Sub-área do rio que este agente irá cobrir.
custo: 3	Valor de custo de cada fiscal, que corresponde à freqüência com que irá efetuar a monitoração

Fonte: Os autores

6. RESULTADOS

Os cenários foram simulados no período de 120 dias, que é correspondente a duração da Piracema (1º novembro a 28 de fevereiro).

6.1 CENÁRIO 1

Num primeiro cenário não foram estabelecidas normas nem utilizados agentes

de fiscalização. Deste modo, não se teve custo político, os agentes não cooperaram (prevalecendo à escolha pela “técnica b” por todos os agentes e em todas as oportunidades de pesca), e ocorreu consumo diário de 1500 kg. Portanto, o recurso esgotou-se, perdurando apenas 28 dias dos 120 da Piracema, não sendo sustentável.

Este tipo de resultado é citado por [FIANI, 2009], onde o autor afirma que no caso em que todos se comportam de forma não-cooperativa, o resultado para todos é o pior possível, de modo que as possibilidades de bem-estar em uma sociedade na qual todos se comportam com oportunismo de curto prazo descrito pelo jogo do dilema dos prisioneiros, são muito reduzidas.

6.2 CENÁRIO 2

No segundo cenário, estabeleceram-se normas nas quais o descumprimento resulta em uma penalidade menor que a recompensa da “técnica b”, porém com uma quantidade alta de agentes fiscais, conforme tabela 4 abaixo:

Tabela 4: Elementos da Política do cenário 2

Normas	Normas que cada pescador deve cumprir;
cria (n3, proibido, pescador, tec_b, periodo("piracema"), "false", multa, 3)[artifact_id("nrmsprb")];	Esta norma estabelece que seja proibido pescar com “técnica b” no período da Piracema, sem exceção e com 3 unidades de multa.
cria (n3, proibido, pescador, tec_a, periodo("piracema"), "qtd_pesc(ACTOR, QP) & QP <= 3", multa, 1)[artifact_id("nrmsprb")];	Esta norma estabelece que seja proibido pescar com “técnica a” no período da Piracema, sendo que a exceção é um limite de 3 unidades diárias (correspondente a subsistência), e com 1 unidade de multa.
n_fiscais: 10	Número de fiscais

Fonte: Os autores

Deste modo, o custo político foi alto, porém nenhum agente cooperou, prevalecendo ainda à escolha pela “técnica b” num consumo diário de 1500 kg. Portanto, o recurso esgotou-se, perdurando apenas 28 dias dos 120 da Piracema, configurando novamente a não sustentabilidade do ambiente. Segundo (FIANI, 2009), nem sempre uma autoridade externa ao jogo possui informações suficientes para identificar o valor correto da punição a ser aplicada, e uma punição com valor

insuficiente é inócuo: os jogadores acham que “vale a pena” sofrer a punição diante dos ganhos líquidos que, ainda assim, podem obter.

6.3 CENÁRIO 3

No terceiro cenário estabeleceu-se que normas nas quais o descumprimento resulta em uma penalidade que corresponde à recompensa das técnicas, porém com uma quantidade baixa de agentes fiscais, conforme tabela 5 abaixo:

Tabela 5: Elementos da Política do cenário 3

Normas	<i>Normas que cada pescador deve cumprir;</i>
cria (n3, proibido, pescador, tec_b, periodo("piracema"), "false", multa, 5)[artifact_id("nrmsprb")];	Esta norma, estabelece que seja proibido pescar com “técnica b” no período da Piracema, sem exceção e com 5 unidades de multa.
Cria (n3, proibido, pescador, tec_a, periodo("piracema"), "qtd_pesc(ACTOR, QP) & QP <= 3", multa, 1)[artifact_id("nrmsprb")];	Esta norma estabelece que seja proibido pescar com “técnica a” no período da Piracema, sendo que a exceção é um limite de 3 unidades diárias (correspondente a subsistência), e com 1 unidade de multa.
n_fiscais: 3	Número de fiscais

Fonte: Os autores

Obteve-se assim um custo político baixo, poucos agentes cooperaram, ainda prevalecendo à escolha pela “técnica b” pela maioria dos agentes, num consumo diário de 1140 kg. Portanto, o recurso esgotou-se, perdurando apenas 37 dias dos 120 da Piracema, embora configurando uma melhora em relação ao cenário 1, continuou não sendo sustentável. Segundo [FIANI, 2009], estabelecer uma instituição que identifique e puna comportamentos não-cooperativos tem um custo, custo este que cresce com o aumento do número de jogadores que podem adotar comportamentos não cooperativos. Assim, este cenário demonstra que investimentos baixos em monitoramento políticos são realmente insuficientes.

6.4 CENÁRIO 4

No quarto cenário estabeleceram-se normas nas quais o descumprimento

resulta em uma penalidade correspondente à recompensa das técnicas, e uma quantidade alta de agentes fiscais, conforme tabela 6:

Tabela 6: Elementos da Política do cenário 4

Normas	Normas que cada pescador deve cumprir;
cria (n3, proibido, pescador, tec_b, periodo("piracema"), "false", multa, 5)[artifact_id("nrmsprb")];	Esta norma, estabelece que seja proibido pescar com “técnica b” no período da Piracema, sem exceção e com 5 unidades de multa.
cria (n3, proibido, pescador, tec_a, periodo("piracema"), "qtd_pesc(ACTOR, QP) & QP <= 3", multa, 1)[artifact_id("nrmsprb")];	Esta norma, estabelece que seja proibido pescar com “técnica a” no período da Piracema, sendo que a exceção é um limite de 3 unidades diárias (correspondente a subsistência), e com 1 unidade de multa.
n_fiscais: 3	Número de fiscais

Fonte: Os autores

Obteve-se assim um custo político alto, todos os agentes cooperam, modificando a escolha preponderante para a “técnica a”, num consumo diário de 300 kg. Assim, o recurso e os agentes mantiveram-se durante todo o período da Piracema e ainda permaneceram 20% (7200) da população dos peixes, possibilitando a continuidade de um novo ciclo no rio, portanto demonstrando o impacto da estrutura política sobre a sustentabilidade. Conforme citado anteriormente, o custo para que todos cooperem é alto, ainda o autor [FIANI, 2009] afirma que instituições que vigiem todos os agentes podem ser impraticáveis. Assim podemos dizer que aumentando a extensão do rio seria necessário a infra-estrutura política.

7. CONCLUSÃO

Este trabalho demonstrou resultados da utilização de um modelo e um framework para simulação de Políticas Públicas sobre o paradigma de sistemas multiagentes com suporte das ferramentas Jason e CArtAgO. Mais especificamente, utilizou-se um estudo de caso baseado no problema clássico Tragédia dos Comuns abordado na Teoria dos Jogos, o qual é voltado para a pesca predatória no período da Piracema.

Como pode ser observado nos cenários, foi possível expressar diferentes políticas, bem como avaliar os resultados de cada uma. No que se refere aos

resultados das simulações, obtiveram-se informações compatíveis com as conclusões da literatura, embora com a utilização de cenários simplificados.

Por fim, acredita-se que a utilização do modelo e *framework* propostos também pode oferecer suporte simular situações de políticas de gerenciamento de recursos comuns em cenários semelhantes como desmatamento, caça de animais silvestres, superpopulação. Assim, estes são trabalhos relevantes para futuros esforços.

REFERÊNCIAS

- BORDINI, R. H.; VIEIRA, R. (2003). Linguagens de Programação Orientada a Agentes: uma introdução baseada em AgentSpeak(L). Revista de Informática Teórica e Aplicada – UFRGS, V 10, N. 1, 32 p.
- BORDINI, R. H.; HUBNER, J. F.; WOOLDRIDGE, M. (2007) Programming Multi-Agent Systems in AgentSpeak using Jason. University of Liverpoll: Wiley.
- EASTON, D. (1965). A Framework for Political Analysis. Prentice-Hall, Englewood Cliffs.
- FIANI, R. (2009). Teoria dos Jogos: com aplicações em economia, administração e ciências sociais. Rio de Janeiro, Elsevier, 3^a edição.
- HARDIN, G. (1968). The Tragedy of the Commons. Science, 162: 1243-1248.
- HILL, M. (2009). The Public Policy Process. Pearson Longman, London, 5th edition.
- HOOD, C., MARGETTS, H. (2007). The Tools of Government in the Digital Age. Palgrave Macmillan, London.
- LOPES, B. AMARAL, J. N. (2008). Políticas Públicas: conceitos e práticas. Belo Horizonte.
- LOPES, CAMILO A. S.; et al. (2010). Cerrado, gerais, Sertão comunidades tradicionais dos Sertões Roseanos. volume I,Universidade Estadual de Montes Claros.
- OMICINI, A.; RICCI, A.; VIROLI, M. (2008). Artifacts in the A&A meta-model for multi-agent systems. Autonomous Agents and Multi-Agent Systems, 17(3):432–456.
- RAO, A. S.; GEORGEFF, M. P. (1992). An Abstract Architecture for Rational Agents. In: IN-INTERNATIONAL CONFERENCE ON PRINCIPLES OF KNOWLEDGE REPRESENTATION AND REASONING (KR'92), 3. Proceedings... Morgan Kaufmann, p.439–449.
- REVISTA PESCA. (2012). GO reforça fiscalização durante piracema. Disponível em <http://www.revistapesca.com.br/noticias/615-go-reforca-fiscalizacao-durante-piracema>, acesso Julho.
- RICCI, A.; SANTI, A.; PIUNTI, M et al. CArtAgO (Common ARTifact infrastructure for AGents Open environments). Disponível por WWW em <http://cartago.sourceforge.net/> acesso em 03/2010.
- SILVEIRA, A. F.; et. al. (2007). Caderno de psicologia e Políticas Públicas. Curitiba, 50p.
- TOCANTINS, NELY.; ROSSETTO, ONÉLIA CARMEM.; BORGES, FLAVYANE ROSA. (2011). Abordagem socioeconômica dos pescadores filiados à colônia z 11: município de Poconé, Pantanal de Mato Grosso, Brasil, Revista Geográfica de América Central Número Especial EGAL, Costa Rica II pp. 1-9.
- LEI 7.679 (1988). Disponível em: <http://www.prpe.mpf.gov.br/internet/Legislacao/Meio-Ambiente-e-Urbanismo/Leis/LEI-N1-7.679-DE-23-DE-NOVEMBRO-DE-1988>, acesso em julho/2012.

SANTOS, I. A. S. ; COSTA, A. C. R. (2012) . Simulando a Execução de Políticas Públicas através de Jason e CArtAgO. In: WESAAC 2012, Florianópolis. Anais do WESAAC 2012. Florianópolis : UFSC, 2012. p. 81-91.

CAPÍTULO 5

UMA COMPARAÇÃO O ENTRE MÉTODOS DE APRENDIZADO POR REFORÇO PROFUNDO APLICADOS AO CONTROLE DE UM ROBÔ MÓVEL EM AMBIENTE VERY SMALL SIZE SOCCER

Natã Ismael Schmitt

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: nischmitt@inf.ufsm.br

Maurício Moraes Godoy

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: mauriciomgodoy01@gmail.com

Gustavo Glass

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: glass.gustavo@acad.ufsm.br

Bruno Silva de Castro

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: bruno.c0310@gmail.com

Thássio Gomes Silva

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: thxssio@gmail.com

Bruno Gabriel Flores Sampaio

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: bruno.sampaio@acad.ufsm.br

Thiago A. N. De Andrade

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: thiagoan.andrade@gmail.com

Anselmo Rafael Cukla

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: anselmo.cukla@uol.com.br

Leonardo Emmendorfer

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: leonardo.emmendorfer@uol.com.br

Daniel Fernando Tello Gamarra

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: fernandotg99@gmail.com

Gabriel Tarnowski

Universidad Nacional de Misiones

Oberá, Misiones, Argentina

E-mail: gabriel.tarnowski@fio.unam.edu.ar

Fernanda Pinto Mota

Universidade Católica de Pelotas

R. Gonçalves Chaves, 373, Pelotas, RS

E-mail: fernanda.mota@ucpel.edu.br

RESUMO: O Aprendizado por Reforço (Reinforcement Learning, RL) é um campo da Inteligência Artificial, que estuda o desenvolvimento de algoritmos que aprendem a tomar decisões de forma otimizada. Nesta pesquisa nós desbravamos as fronteiras do conhecimento, explorando técnicas de aprendizado profundo para o controle de robôs em jogos de futebol. Nossa abordagem considera um ambiente controlado, tendo como referencial a competição de robótica IEEE Very Small Size Soccer. A principal contribuição da pesquisa é a comparação dos algoritmos de controle Soft Actor-Critic (SAC) e Deep Deterministic Policy Gradient (DDPG), avaliados em ambiente virtual com complexidade de jogo alterada dinamicamente. Especificamente, estes algoritmos são utilizados para modelar as ações de um jogador que desempenha papel de atacante na competição robótica. As alterações no ambiente virtual consideram a técnica Curriculum Learning, que possibilita uma curva de aprendizado gradual e eficaz durante o treinamento. Os resultados obtidos sublinham a superioridade do algoritmo SAC em relação ao DDPG neste contexto específico, destacando sua maior eficácia e adaptabilidade. Em uma perspectiva geral, os achados desta pesquisa contribuem para o entendimento mais amplo de como técnicas de aprendizado profundo podem ser otimizadas para aplicações em robótica competitiva.

PALAVRAS-CHAVE: Aprendizado por Reforço; Soft Actor-Critic; Deep Deterministic Policy Gradient; IEEE Very Small Size Soccer.

1. INTRODUÇÃO

O Aprendizado por Reforço (*Reinforcement Learning*, RL) é, provavelmente, a área do aprendizado de máquina que atrai maior fascínio entre não especialistas no tema. Isso porque, frequentemente, a pesquisa nesta área é associada ao treinamento de robôs. O ponto alto da popularização deste campo de conhecimento se deu em 2013, quando a empresa britânica *DeepMind* construiu um algoritmo capaz de aprender a jogar jogos de Atari (<https://atari.com/>) sem qualquer conhecimento prévio. A verdade é que trata-se de um campo bem mais abrangente, cujas origens de estudo e pesquisa remontam à década de cinquenta [1].

De maneira sintética, o RL é o campo da Inteligência artificial que estuda o desenvolvimento de algoritmos que aprendem a tomar decisões otimizadas, a partir de um processo de tentativa e erro, sob um mecanismo de recompensas e punições. Através de um ambiente virtual com parâmetros controlados, o algoritmo (agente) realiza determinadas ações para o atingimento de um objetivo especificado. Uma função de recompensa é utilizada para atribuir um valor numérico, que informa ao agente se sua ação contribuiu ou prejudicou a busca do objetivo. Dessa forma o algoritmo aprende quais ações, em quais estados, contribuem para uma recompensa positiva, buscando sempre maximizar o ganho de recompensas futuras. O Aprendizado por Reforço Profundo (*Deep Reinforcement Learning - DRL*) [2] é uma variação importante do RL, que emprega o uso de redes neurais profundas para a solução deste problema.

Ao longo dos anos, diversos trabalhos aplicando técnicas de DRL em diferentes contextos vêm sendo publicados. Uma pesquisa no *Google Scholar* pelo termo *Deep Reinforcement Learning* retorna mais de um milhão de artigos e outras contribuições acadêmicas, destacando a extensão da pesquisa neste domínio. Uma das aplicações em estudos emergentes inclui a utilização de técnicas de DRL para o controle de robôs em partidas de futebol, no âmbito da competição *IEEE Very Small Size Soccer* (IEEE VSSS).

O futebol de robôs IEEE VSSS, é uma modalidade de competição de robótica que reúne diversas tecnologias que cooperam para que os robôs pontuem contra o adversário, baseado nas regras da (Competição Brasileira de Robótica - CBR) [3]. Um jogo é composto de dois times de 3 robôs de roda diferencial, que são controlados

externamente. Suas dimensões são de no máximo 8 cm de largura, 8 cm de comprimento e 8 cm de altura. A arena tem 1,5 metros de comprimento e 1,3 metros de largura. Para a partida é utilizada uma bola de golf laranja com peso e características bem definidas. O VSSS é amplamente utilizado como fonte de pesquisa, trazendo avanços científicos para a área de robótica, reunindo grupos que objetivam alcançar os melhores robôs e os melhores métodos de controle. No Brasil, o principal evento de atração é a *Latin American Robotics Competition* (LARC), tendo a VSSS e muitas outras modalidades de competições que ocorrem anualmente.

O controle dos robôs é feito via um computador, que conectado a câmera (posicionada acima do campo), monitora as movimentações destes agentes em uma partida. A imagem capturada é então processada com algoritmos de visão computacional, extraíndo variáveis como posição da bola, direção e velocidade de todos os robôs em campo, dentre outras. Estas informações são utilizadas pelo algoritmo de controle de jogo, o qual tomará decisões a partir do estado atual. Os robôs de roda diferencial podem ser controlados através das velocidades de cada uma de suas rodas, de modo que o algoritmo empregado pode gerar a velocidade final das rodas de cada robô e, consequentemente, controlar os movimentos deste.

Nesta pesquisa, o objetivo é utilizar técnicas de DRL para estudar o controle de robôs em partidas de futebol, no âmbito da competição IEEE VSSS. Mais especificamente, treinar algoritmos de controle *Soft Actor-Critic* (SAC) e *Deep Deterministic Policy Gradient* (DDPG), que foram avaliados em um ambiente virtual com complexidade de jogo alterada dinamicamente. Para isto, foi utilizado o simulador de código aberto *RSoccer* [4], através de sua implementação como biblioteca da linguagem de programação *Python*.

Além desta introdução, o presente artigo está estruturado na forma delineada a seguir. Na Seção II são elencados alguns trabalhos expoentes relacionados ao tema da pesquisa. Na Seção III são apresentados detalhes metodológicos que nortearam a obtenção dos resultados desta pesquisa, incluindo aspectos teóricos sobre o aprendizado por reforço, arcabouço computacional centrado no simulador de código aberto *RSoccer*, definição das premissas de aprendizado e recompensas, dentre outros. A análise detalhada dos cenários sob investigação é apresentada na Seção IV. Considerações finais e propostas futuras são endereçadas na Seção V.

2. FUNDAMENTAÇÃO TEÓRICA

De ambas as perspectivas, teórica e aplicada, pesquisadores têm se dedicado a avanços no campo do DRL. Nesta Seção, faz-se menção a alguns trabalhos exponentes, com ênfase naqueles que possuem vínculos diretos com os achados apresentados neste estudo ou que se relacionam estreitamente com as linhas de investigação atualmente em desenvolvimento. O objetivo principal das conexões é fornecer o referencial teórico fundamental do escopo desta pesquisa e antecipar direções futuras no âmbito do DRL aplicado ao controle robótico.

A pesquisa realizada por [5] apresenta um panorama abrangente sobre o emprego do RL em tarefas de manipulação robótica, mapeando lacunas de conhecimento existentes e sugerindo futuras direções para investigação. Os autores empreenderam uma revisão sistemática, empregando uma ampla varredura na literatura científica, com foco em bases de dados eletrônicas reconhecidas pela divulgação de resultados importantes, como *IEEE Xplore* e *Google Scholar*. Neste processo, foram selecionados e analisados 42 artigos, publicados a partir do ano de 2013, com base em parâmetros específicos de inclusão.

Em uma perspectiva similar, [6] realizam uma revisão abrangente da literatura, cobrindo publicações no período 2015 e 2022, para o entendimento e aplicação de algoritmos de DRL. Estes autores direcionam seu foco para avanços significativos na utilização do RL em robótica, sublinhando os desafios ligados à transição de estratégias aprendidas em simulações para aplicações no mundo real. Este estudo abarcou a análise de mais de 150 trabalhos acadêmicos, utilizando plataformas de pesquisa como *Google Scholar*, *IEEE Xplore* e *ArXiv*.

Em um artigo seminal, [7] introduziram a metodologia de aprendizado por reforço conhecida como *Curriculum Learning*. Essa abordagem, que prioriza o treinamento progressivo em etapas de complexidade crescente, é inspirada nos processos eficazes de aprendizagem observados em humanos e animais. Nossa pesquisa faz uso da contribuição de [7] para adaptar o ambiente de treinamento nos cenários considerados.

Recentemente em [8], conduziram um estudo no qual é comparado dois tipos de redes neurais para controle de formação dos robôs em ambiente VSSS considerando os métodos DDPG [9] e *Double Deep Q-Network* (DDQN) [10]. A função

das redes neurais é introduzir um controlador que atuasse como uma espécie de técnico, que coordena o papel dos robôs, seja este atacante, zagueiro ou goleiro durante a partida.

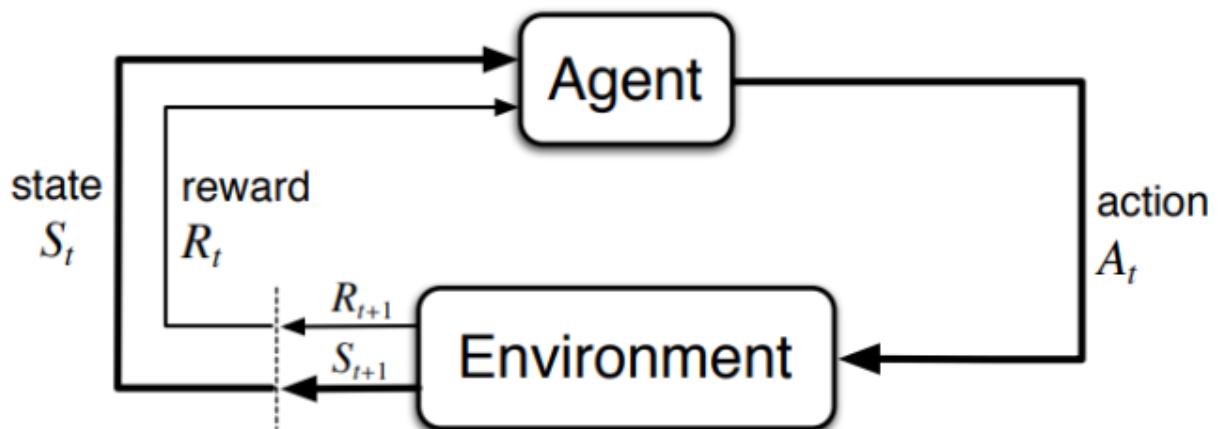
O trabalho apresentado por [11] explora a aplicação de dois algoritmos de redes neurais, especificamente o DDPG e o SAC, para a movimentação de robôs diferenciais em um ambiente virtual contendo obstáculos. O foco principal deste estudo é analisar o deslocamento do robô no campo de jogo, onde o objetivo é que ele se move entre pontos específicos do mapa sem colidir com obstáculos. Nossa investigação é fortemente inspirada nas contribuições de [11], explorando similarmente a eficácia desses algoritmos no contexto específico de navegação robótica.

3. METODOLOGIA

3.1 REINFORCEMENT LEARNING

Este trabalho, é executado seguindo o fluxo de dados de forma geral aplicado no *Reinforcement Learning*, tal como está apresentado na Figura 1 [12]. Aqui é apresentado o ambiente e o agente. O agente recebe os dados iniciais do ambiente como estado S_t e R_t e gera uma ação A_t qual é executada no ambiente, gerando novos estados e recompensas S_{t+1} e R_{t+1} , o qual são processadas novamente pelo agente, completando o ciclo.

Figura 1: Execução dos algoritmos de Reinforcement Learning



Fonte: Os autores

3.2 VISÃO GERAL DO RSOCCER

Para a realização dos testes de *Reinforcement Learning* empregados, foi utilizada a biblioteca *rSoccer*, um ambiente com a física simulada voltada para treinamentos de jogos de VSSS, baseada na biblioteca *GYM* [13], amplamente utilizada na literatura para avaliar o desempenho de algoritmos de aprendizado por reforço. A biblioteca esta disponível na linguagem de programação *Python* e teve seu ambiente modificado para permitir que o jogador fosse treinado com dificuldades progressivas e recompensas personalizadas. Além disso, a biblioteca *rSoccer* oferece suporte à renderização de imagens para visualização em tempo real dos ambientes através de uma *GUI* (*Graphical User Interface*), simplificando a observação do progresso do jogo no ambiente, permitindo uma avaliação empírica do comportamento dos agentes.

O ambiente VSSS inclui uma função de recompensa pronta para uso, que avalia as mudanças entre o estado anterior e atual do ambiente e atribui um valor numérico para indicar a importância da ação do agente para alcançar o objetivo. Esta recompensa é composta por três funções: uma função de potencial da bola, uma função de movimentação e uma função de gasto energético. A função de potencial da bola compara a posição anterior e atual da bola para determinar se ela se aproximou do gol inimigo, retornando um valor positivo proporcional ao deslocamento da bola na direção do gol e calculado pela Equação 1. A função de movimentação fornece *feedback* sobre a ação do agente, levando em consideração a aproximação do agente até a bola, incentivando o aprendizado inicial do robô e é dado pela Equação 2. Por ultimo, a recompensa dado ao gasto energético aos agentes para evitar movimentações desnecessárias e descartar caminhos não ótimos para chegar na bola. Essa recompensa é dada pela Equação 3.

$$R_p = \frac{bp_l - bp_{l-dl}}{dt} \quad (1)$$

$$\vec{RB} = \|(B_x - R_x, B_y - R_y)\| \quad (2)$$

$$E_r = - \sum_{p=0}^E (|W_0| + |W_1|) \quad (3)$$

Com as três funções descritas, a função final de recompensa se dá pela inclusão de pesos para cada função, para que o usuário possa balancear e talvez contribuir com pesos mais adequados para os algoritmos. Na Equação 4 está introduzido Wb, Wme We, que representam pesos para as funções de potencial de bola, movimentação do agente e energia gasta, respectivamente. Note que se a indicação de gols para a função de recompensa é dada pela adição ou subtração de Gp, que normalmente é um valor mais alto, para que o algoritmo aprenda a importância dos gols.

$$R = \{W_b \cdot R_p + W_m \cdot M_r + W_e \cdot E_r + G_p \cdot \begin{array}{l} \text{Gol} \\ W_b \cdot R_p + W_m \cdot M_r \\ \text{Não gol} \end{array} \\ \begin{array}{l} \text{Gol} \\ \text{adversário} \end{array}\} \quad (4)$$

3.3 ATTACKER SIMULATION AMBIENT

Esta Subseção contempla aspectos teóricos que compõem uma das principais contribuições desta pesquisa: a modificação do ambiente de aprendizagem, com ênfase no treinamento progressivo e etapas de complexidade crescente.

Visando aproveitar de técnicas de *Curriculum Learning* \cite{10.1145/1553374.1553380}, os ambientes discretos foram substituídos por um único ambiente o qual terá sua dificuldade alterada dinamicamente, permitindo ao agente um treinamento suave, pois sua curva de aprendizado ditará a dificuldade do ambiente. Desta forma, para o critério de dificuldade adotamos um número o qual varia entre 0 e 1, sendo 0 a menor dificuldade e 1 a maior dificuldade. Uma dificuldade 0 significa o ambiente com os robôs em uma posição inicial fixa e imóveis. Definimos a partir da média das recompensas dos 100 episódios anteriores qual a dificuldade atual do ambiente para calcular Da, o qual seu efeito está descrito na Figura 2. A partir disto, na Equação 5 está descrito o cálculo de Da, representando a dificuldade do ambiente, e quais valores Da admite. Nesta equação, $R_m = \max_{r \in R} R$, R é o conjunto das médias entre as 100 últimas recompensas do agente, o qual selecionamos o valor máximo de R para utilização nesta equação. é um número arbitrário para representar o valor máximo da função de recompensa o qual foi empiricamente definida como 450 a partir de treinamentos anteriores. Note que em 5 o valor mínimo de Da é 0.1.

$$D_a = \{ \begin{array}{lll} 0.1 & R_m \leq 0.6 & 0.25 \\ & & 0.6 < F \end{array} \quad (5)$$

Figura 2: Dinamicidade do ambiente do atacante



Fonte: Os autores

3.4 AGENT OBSERVATIONS

Como inspiração no trabalho de \cite{10.1007/s10846-021-01367-5}, as observações padrão do *rSoccer* neste ambiente de treinamento do atacante foram substituídas pelas descritas na Tabela 1. As observações que antes informavam coordenadas absolutas de Dinamicidade do ambiente do atacante x e y, agora informam distância e ângulo como forma de representar as posições observadas sempre em relação ao agente, para que dessa forma a rede neural tenha dados que ocorrem com mais frequência, devido ao fato de estar centrada na posição do agente, e não mais globalmente no campo, facilitando assim a generalização da rede. Também optou-se por reduzir a quantidade de dados informados sobre os outros robôs, como velocidades lineares e angulares, visto que essa informação não é de grande relevância para o objetivo do robô, além de ser uma prova de que é necessário poucas observações para que o agente satisfaça os requisitos do ambiente. Uma descrição visual para melhor compreensão das observações pode ser visualizada na

Figura 3.

Tabela 1: Observações para o agente atacante utilizadas neste trabalho

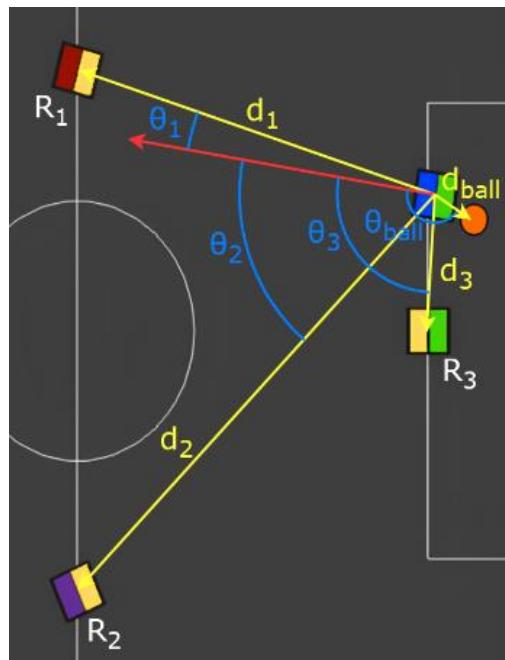
Observações
Distância entre agente e bola
Ângulo do agente para bola
Distância entre agente e gol oponente
Ângulo do agente para gol oponente
Distância entre agente e Mi
Ângulo do agente para Mi
Seno do ângulo do agente
Cosseno do ângulo do agente
Velocidade linear em X da bola
Velocidade linear em Y da bola
Velocidade linear em X do agente
Velocidade linear em Y do agente
Velocidade angular do agente

Fonte: Os autores

3.5 REWARD FUNCTION

Neste trabalho foi modificado a função de recompensa para melhorar o aprendizado do agente. A primeira modificação foi nos pesos, para que o agente priorize melhor a ocorrência de gols. Também foi feito um aumento no peso do gradiente de bola, com intuito de que o robô aprenda mais rápido que a bola deve seguir um certo percurso. A energia foi elevada para ficar mais evidente ao agente a escolha de uma rota mais curta. Os pesos utilizados para treinamento se encontram na TAB cujos valores foram explicados anteriormente.

Figura 3: Observações do agente



Fonte: Os autores

Tabela 2: Pesos utilizados na função de recompensa do ambiente atacante

Observações	Quantidade
Wb	2
Wm	0.25
We	1e-3
Gp	500

Fonte: Os autores

Na Figura 4 pode se ver as entradas e saídas para o agente atacante, que provém dos dados apresentados na Tabela 1. Cada uma das entradas faz parte do estado S do ambiente no momento t , e suas saídas compõem a ação A no momento t .

Figura 4: Diagrama de entradas e saídas do agente atacante



Fonte: Os autores

4. RESULTADOS

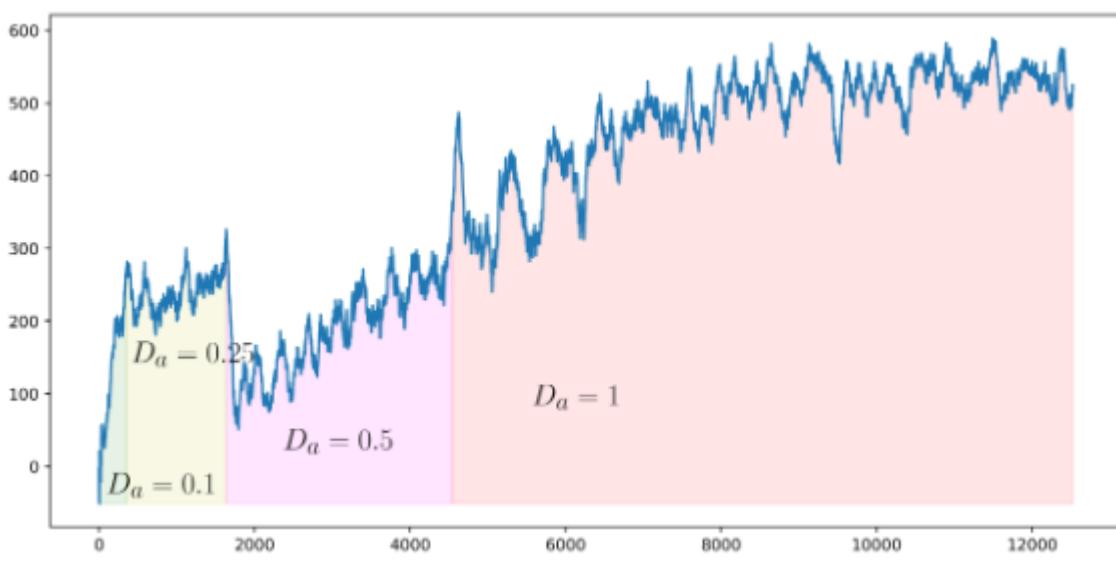
Nesta seção, são apresentados os resultados da avaliação numérica para o estudo que comparou o desempenho de dois algoritmos DRL, a saber o SAC e o DDPG, aplicados ao controle de um robô móvel no contexto de IEEE VSSS.

Foi observado que o SAC superou o DDPG em termos de obtenção de recompensas e eficácia na realização das tarefas propostas. Como pode ser visto nas Figura 5 e Figura 6, comparando as recompensas obtidas pelos métodos SAC e DDPG, respectivamente.

O gráfico da Figura 5 destaca quatro regiões com diferentes colorações, cada uma com um valor diferente para D_a , que representam etapas de treinamento com diferentes níveis de dificuldade. Os diferentes níveis de dificuldade são determinados como descrito na Equação 5. De modo geral, pode-se inferir que, à medida que D_a aumenta, a métrica de desempenho se estabiliza, sugerindo que um D_a maior poderia estar associado a uma política de aprendizado mais estável ou eficaz no longo prazo.

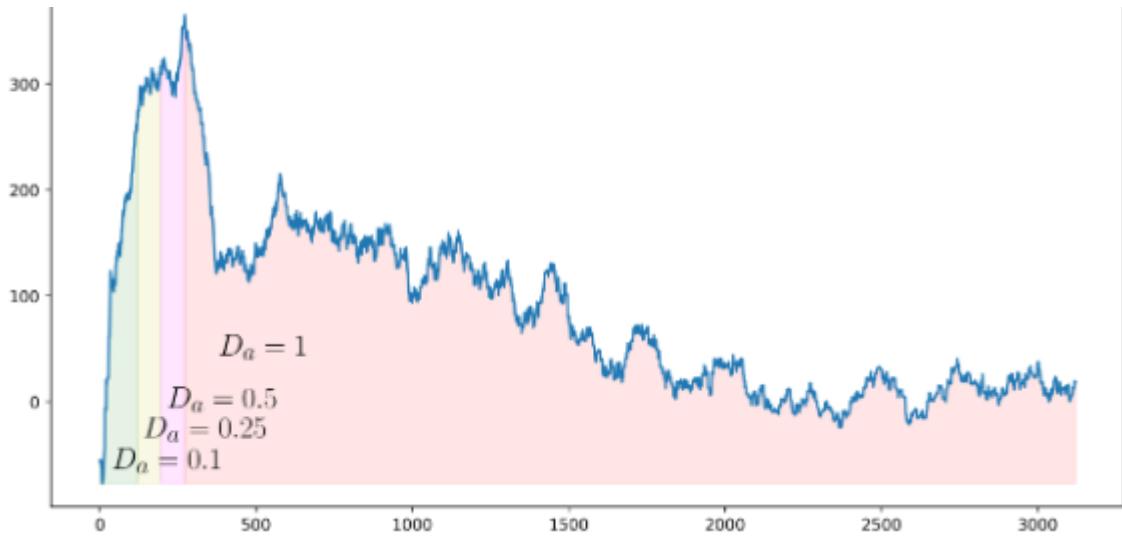
Analogamente, a imagem da Figura 6 apresenta o desempenho obtido pelo modelo DDPG, considerando diferentes estágios de aprendizado. Ao contrário do verificado para o algoritmo SAC, o desempenho é altamente afetado, decaendo à medida que a complexidade aumenta.

Figura 5: Gráfico de treinamento do algoritmo SAC



Fonte: Os autores

Figura 6: Gráfico de treinamento do algoritmo DDPG



Fonte: Os autores

De maneira geral, os resultados experimentais demonstraram que o SAC alcançou uma performance significativamente superior na tarefa de controle do atacante. O SAC não apenas conseguiu pontuar mais efetivamente contra oponentes virtuais, mas também apresentou maior adaptabilidade e capacidade de generalização para diferentes configurações de jogo e obstáculos. Por outro lado, o DDPG, embora tenha mostrado um bom desempenho inicial, enfrentou dificuldades em se adaptar às mudanças incrementais na complexidade do ambiente, resultando em uma performance menos consistente.

A superioridade do SAC pode ser atribuída à sua capacidade de explorar de maneira mais eficiente o espaço de ações e estados graças à sua política de entropia máxima. Isso permite uma exploração mais abrangente do ambiente de jogo, levando a estratégias mais robustas e adaptativas. Além disso, a estrutura do SAC, que enfatiza a aprendizagem baseada em recompensa e a minimização de erros, provou ser particularmente adequada para o ambiente dinâmico e imprevisível do IEEE VSSS.

A aplicação de técnicas de *Curriculum Learning* também desempenhou um papel crucial na melhoria do processo de aprendizagem, permitindo que os robôs se adaptassem progressivamente a desafios mais complexos. Isso simula um ambiente de aprendizado mais natural e eficaz, onde os agentes primeiro dominam tarefas simples antes de progredir para outras mais difíceis.

Os resultados também destacam a importância de uma função de recompensa bem definida no aprendizado por reforço. A funcionalidade de ajustar dinamicamente a dificuldade do ambiente e a recompensa com base no desempenho do agente mostrou ser fundamental para incentivar o robô a aprender estratégias eficazes de controle e navegação.

5. CONCLUSÕES

Este artigo aplica algoritmos de *Deep Reinforcement Learning* (DRL) no controle de robôs na modalidade de futebol de robôs IEEE Very Small Size Soccer (IEEE VSSS). Especificamente, foram considerados algoritmos de controle *Soft Actor-Critic* (SAC) e *Deep Deterministic Policy Gradient* (DDPG), modificados para atuarem como atacantes, com desempenhos avaliados em um ambiente virtual com complexidade de jogo alterada dinamicamente. O mecanismo de aprendizado leva em consideração metodologia *Curriculum Learning* \cite{10.1145/1553374.1553380}. Esta metodologia enfatiza o treinamento progressivo em etapas de complexidade crescente, inspirando-se nos eficientes processos de aprendizado observados em humanos e animais. De maneira sumarizada, os principais achados da pesquisa são elencados a seguir:

Os algoritmos de DRL demonstraram eficácia no controle de robôs na âmbito da competição IEEE VSSS;

Na função de atacante, o algoritmo SAC excedeu o desempenho do DDPG em termos de recompensas acumuladas, evidenciando uma maior eficiência na execução de estratégias ofensivas;

O algoritmo DDPG exibiu uma curva de aprendizado que iniciou com melhoria progressiva, seguida por um declínio à medida que a complexidade do ambiente aumentava. Em contrapartida, o algoritmo SAC, apesar de requerer um período mais extenso de treinamento, demonstrou superioridade em performance sob condições ambientais de variada complexidade;

A superioridade do SAC pode ser primordialmente atribuída à sua política de entropia máxima, que promove uma exploração mais efetiva do espaço de ações;

Considerando que a principal métrica de sucesso definida era a capacidade de marcar gols em todos os episódios com o menor número de tentativas possível,

constatou-se que nenhum dos algoritmos alcançou sucesso absoluto. Portanto, identifica-se a necessidade de futuros aprimoramentos nos algoritmos para atingir esta meta.

Os resultados acima listados sugerem um amplo espectro de contribuições futuras. Dentre as principais linhas de investigação em curso pelos proponentes desta pesquisa, destacam-se:

Explorar algoritmos específicos para aprimorar o treinamento de goleiros em robótica, considerando diferentes técnicas de aprendizado por reforço;

Ampliar o escopo da comparação de desempenho entre diferentes algoritmos, como SAC e DDPG, para incluir novas abordagens, focando em suas capacidades enquanto jogadores de ataque;

Investigar algoritmos de planejamento de trajetória (*path planning*) que integrem conhecimentos de aprendizado por reforço para melhor navegação em tempo real entre obstáculos cumprindo os objetivos do futebol de robôs;

Aprofundar o estudo sobre a política de entropia máxima utilizada pelo SAC para entender como essa abordagem pode ser explorada ou melhorada em diferentes configurações de robótica competitiva.

REFERÊNCIAS

1. A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and Tensorflow: Concepts, Tools, and Techniques to Build Intelligent Systems*, 3rd. O'Reilly Media, Nov. 2022, p. 861, ISBN: 978-1098125974.
2. V. Mnih, K. Kavukcuoglu, D. Silver, et al., Playing atari with deep reinforcement learning, 2013. arXiv:1312.5602 [cs.LG].
3. Very small size soccer rules, <https://www.cbrobotica.org/wp-content/uploads/2021/05/vssRules3x321.pdf>, Acesso: 18/12/2023.
4. F. B. Martins, M. G. Machado, H. F. Bassani, P. H. M. Braga, and E. S. Barros, "Rsoccer: A framework for studying reinforcement learning in small and very small size robot soccer," in RoboCup 2021: Robot World CupXXIV, R. Alami, J. Biswas, M. Cakmak, and O. Obst, Eds., Cham: Springer International Publishing, 2022, pp. 165–176, ISBN: 978-3-030-98682-7.
5. H. Nguyen and H. La, "Review of deep reinforcement learning for robot manipulation," in 2019 Third IEEE International Conference on Robotic Computing (IRC), 2019, pp. 590–595. DOI: 10.1109/IRC.2019.00120.
6. D. Han, B. Mulyana, V. Stankovic, and S. Cheng, "A survey on deep reinforcement learning algorithms for robotic manipulation," Sensors, vol. 23, no. 7, p. 3762, 2023. DOI: 10.3390/s23073762.
7. Y. Bengio, J. Louradour, R. Collobert, and J. Weston, "Curriculum learning," in Proceedings of the 26th Annual International Conference on Machine Learning, ser. ICML '09, Montreal, Quebec, Canada: Association for Computing Machinery, 2009, pp. 41–48, ISBN: 9781605585161. DOI: 10.1145/1553374.1553380. [Online]. Available: <https://doi.org/10.1145/1553374.1553380>.
8. C. H. C. Pena, M. G. Machado, M. S. Barros, et al., "An analysis of reinforcement learning applied to coach task in ieee very small size soccer," in 2020 Latin American Robotics Symposium (LARS), 2020 Brazilian Symposium on Robotics (SBR) and 2020 Workshop on Robotics in Education (WRE), 2020, pp. 1–6. DOI: 10.1109/LARS/SBR/WRE51543.2020.9307069.
9. T. P. Lillicrap, J. J. Hunt, A. Pritzel, et al., Continuous control with deep reinforcement learning, 2019. arXiv: 1509.02971 [cs.LG].
10. M.-W. Han and P. Kopacek, "Neural networks for the control of soccer robots," in ISIE'2000. Proceedings of the 2000 IEEE International Symposium on Industrial Electronics (Cat. No.00TH8543), vol. 2, 2000, 571–575 vol.2. DOI: 10.1109/ISIE.2000.930360.
11. J. C. de Jesus, V. A. Kich, A. H. Kolling, R. B. Grando, M. A. d. S. L. Cuadros, and D. F. T. Gamarra, "Soft actor-critic for navigation of mobile robots," in Journal of Intelligent & Robotic Systems, vol. 102, 2021. DOI: 10.1007/s10846-021-01367-5.
12. R. S. Sutton and A. G. Barto, *Reinforcement Learning: An Introduction*. Cambridge, MA, USA: A Bradford Book, 2018, ISBN: 0262039249.

13. G. Brockman, V. Cheung, L. Pettersson, et al., Openai gym, 2016. arXiv: 1606.01540 [cs.LG].

CAPÍTULO 6

SOLUÇÃO DE VISÃO COMPUTACIONAL APLICADO A UM ROBÔ DE ESTAÇÃO FIXA PARA SEGUIMENTO DE ALVOS

Gustavo Arthur Dutra

Universidade Federal de Santa Maria Santa Maria - RS, BRASIL

E-mail: gustavo.dutra@acad.ufsm.br

Anselmo R. Cukla

Universidade Federal de Santa Maria Santa Maria - RS, BRASIL

E-mail: anselmo.cukla@ufsm.br

Solon Bevilacqua

Universidade Federal de Goiás - Goiás, BRASIL

E-mail: solbev@gmail.com

Claudenir Rocha Alves Filho

Universidade Federal de Santa Maria Santa Maria - RS, BRASIL

E-mail: claudenir.filho@acad.ufsm.br

Marcelo Serrano Zanetti

Universidade Federal de Santa Maria Santa Maria - RS, BRASIL

E-mail: marcelo.zanetti@acad.ufsm.br

Bruno Gabriel Flores Sampaio

Universidade Federal de Santa Maria.

Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS Av. Roraima - Camobi, Santa Maria, RS

E-mail: bruno.sampaio@acad.ufsm.br

Fernanda Pinto Mota

Universidade Católica de Pelotas R. Gonçalves Chaves, 373, Pelotas, RS

E-mail: fernanda.mota@ucpel.edu.br

Ricardo Dias Schirmer

Universidade Federal de Santa Maria Santa Maria - RS, BRASIL

E-mail: ricardo.schirmer@gmail.com

Gabriel Tarnowski

Universidad Nacional de Misiones Obera, Misiones, Argentina

E-mail: gabriel.tarnowski@fio.unam.edu.ar

RESUMO: Este artigo aborda o desenvolvimento e integração de tecnologias de inteligência artificial (IA), como o Tracking Learning Detection (TLD) e o Google MediaPipe (MP), em um sistema robótico militar conhecido como Sniper Robótico (SR). O SR visa substituir o franco-atirador e o observador por câmeras equipadas

com algoritmos de IA, reduzindo a exposição dos soldados em missões de vigilância e aumentando a eficiência operacional. O TLD é utilizado para a detecção e perseguição de alvos, enquanto o MP é empregado para o reconhecimento de keypoints dos rostos do alvo. As IAs fazem o controle dos motores do robô. O artigo detalha a metodologia de desenvolvimento do software de interface do operador, bem como a integração das tecnologias TLD e MP, e discute os resultados obtidos, a eficácia do sistema na identificação e seguimento de alvos em diferentes cenários militares. São destacadas as preocupações éticas relacionadas ao uso crescente de armas robóticas e a importância de manter o controle humano sobre as decisões de seleção e ataque de alvos.

PALAVRAS-CHAVE: Google MediaPipe; Tracking Learning Detection; Robô Sniper.

1. INTRODUÇÃO

O avanço tecnológico contribuiu significativamente na evolução dos conflitos ao longo dos séculos. Com a ascensão da robótica e da IA, o cenário militar testemunhou uma transformação sem precedentes. Forças armadas enfrentam a realidade de equipamentos acessíveis, desafiando e, às vezes, superando equipamentos sofisticados, como acontece em cenários atuais onde drones de baixo custo podem inutilizar viaturas, aeronaves ou navios cujo custo é ordens de magnitude mais elevado. Esse contraste destaca a urgência na adaptação e a importância de incorporar rapidamente essas tecnologias dos países ou grupos envolvidos, tal como que é o caso do conflito entre a Rússia e a Ucrânia.

Historicamente, o papel do franco-atirador e do observador é decisiva nas operações militares. Conforme descrito no Manual do Sniper do Exército dos Estados Unidos (1994) [1], o franco-atirador tem a missão de fornecer apoio com fogo preciso de longo alcance em alvos selecionados, enquanto o observador auxilia na localização de alvos no terreno e na determinação das condições ambientais, entretanto ambos se expõe ao risco de serem identificados e alvejados pelo fogo inimigo. O desenvolvimento de SR pode ajudar a minimizar a exposição de soldados prestando apoio de fogo ao substituir o atirador e o observador por câmeras equipadas com algoritmos baseados em IA. Franco atiradores também são empregados em situações de sequestro, e SR devem minimizar o risco de ferir reféns, aumentando a precisão dos disparos ao incluir um controle mais robusto do armamento através de uma modelagem mais realista das condições climáticas locais.

No SR, as funções do atirador e do observador são replicadas por duas câmeras integradas a um sistema de visão computacional que utiliza IA., como o MP e o TLD, respectivamente, para detecção e perseguição de alvos. O TLD será usado na câmera do observador de forma a distinguir objetos, e o MP na do atirador de forma a ter precisão do centro dos olhos para o alvo.

Enquanto aos estudos para perseguição de alvos baseados em tecnologias de IA podemos mencionar dois: o MP e o TLD. Conforme [2] e [3] o MP é um framework desenvolvido para permitir aos usuários uma utilização rápida e fácil de seus recursos, através do processo de Aprendizado de Máquinas (ML). Este algoritmo oferece uma estrutura para inferência de dados sensoriais, ferramentas de avaliação de

desempenho e componentes de processamento reutilizáveis chamados Calculators, que permitem melhorias na percepção por meio de sua configuração de linguagem. O MP é capaz de reconhecer várias informações, como orientação de pessoas e arranjo de membros, e determina, por meio de uma rede convolucional, qual pessoa merece a camada de detecção, dando prioridade àquela mais ao centro da imagem.

No entanto, em casos de múltiplas pessoas na tela, ou um centro com interferências onde a percepção do rosto seja confusa, o MP pode apresentar dificuldades na identificação do alvo correto, o que é solucionado pelo uso do TLD. Conforme os estudos [4] e [5], utiliza-se o processo de Região de Interesse (ROI) com tracking em tempo real de objetos, combinando tecnologias como o algoritmo CamShift, OpenCV e ConvNet. Ele permite uma identificação precisa de pessoas, mesmo em situações complexas, como sequestros, escudos humanos, manifestações, entre outros. As tecnologias de ROI têm uma limitação relacionada à definição de um retângulo genérico, que não especifica o que está contido dentro dele. Isso pode resultar na exclusão de outros objetos que não estejam completamente dentro da área delimitada pelo retângulo. Por exemplo, se um humano estiver dentro da ROI, o centro do retângulo estará próximo ao seu umbigo. No entanto, se a pessoa levantar um braço, o retângulo se expandirá, e o centro não estará mais alinhado com o corpo. Assim, a combinação dessas duas tecnologias proporciona um sistema robusto e eficaz para a detecção e perseguição de alvos em diversas situações no contexto de defesa ou de segurança pública.

Estudos anteriores têm explorado a utilização de câmeras para o reconhecimento de gestos com o propósito de transmitir informações para sistemas de controle, como protótipos de braços robóticos. Estas investigações visam alcançar um controle mais intuitivo e eficiente dos dispositivos físicos, fazendo uso das capacidades de reconhecimento de keypoints do MP. Os artigos [6] e [7] apresentam uma abordagem congruente com o projeto discutido neste estudo. Ambos os trabalhos se concentram na identificação de gestos de uma única mão, e na posterior transmissão dessas informações para sistemas de controle. Embora os estudos mencionados evidenciem a viabilidade dessa abordagem, é importante ressaltar que testes abrangentes ainda não foram conduzidos, especialmente em cenários que envolvam desafios adicionais, como a detecção simultânea de gestos de múltiplas mãos ou gestos em posições não convencionais.

A tecnologia de TLD pode ser vista em [8] onde um robô móvel deve reconhecer e seguir um humano. Esse estudo utiliza não apenas o TLD, mas também o Median-Flow, outro algoritmo de IA nativo do Opencv, e um algoritmo genérico de reconhecimento facial. Aqui também houve uma preocupação com componentes de dispersão como humano rastreado estar em movimento ou ficar obstruído. A abordagem desse estudo está relacionada com a criação de um esqueleto de 20 juntas. O sistema parece se assemelhar com os keypoints da MP. Os testes mostram a grande capacidade da tecnologia de continuar reconhecendo o alvo mesmo depois dele sumir da tela e reaparecer. O estudo também aborda a alta taxa de falsos positivos do TLD. A tecnologia criada, chamada de SIFace-TLD pode rastrear o alvo com sucesso mesmo quando o alvo está de costas para a câmera. Além disso, o Filtro de Partículas Monte Carlo foi adotado para reduzir a influência de ruídos de medição e obter uma estimativa precisa do estado para o controle de movimento do robô. Por fim, um controlador simples e eficaz para seguimento humano foi projetado. No caso do SR, o projeto usa o MP para suprir essa necessidade.

Por outra parte, sistemas robóticos que utilizam conceito de vigilantes já existem no âmbito militar, como é o caso do SGR-A1, desenvolvido pela Samsung Heavy Industries [9]. Trata-se de um robô com capacidade autônoma de disparo, permitindo-lhe identificar e atirar em alvos sem intervenção humana. Este robô possui níveis variados de interação humana, podendo operar tanto em modo semiautônomo, onde a decisão final sobre o disparo é tomada por um ser humano, quanto em modo totalmente autônomo, onde o robô toma decisões independentes sobre quando e onde atirar. Sua interface de operação é composta por duas telas principais, câmera com visão noturna, térmicas e com ampliação de zoom.

Ainda, a empresa Dodaam Systems Ltd., reconhecida por sua liderança na fabricação de robôs militares, também investe em pesquisa, como evidenciado em [10], que apresenta um sistema de vigilância equipado com um algoritmo de rastreamento de alvos. Este sistema utiliza um vetor de direção calculado a partir do erro de posição entre o centro do visor e o centro do objeto na imagem capturada pela câmera. A empresa não se limita a um robô estático, mas possui uma linha de robôs letais e não letais, estáticos e móveis, com ou sem humanos. Possui centro de controle e uma diversidade de tecnologias que se completam.

Neste trabalho não podemos deixar de mencionar sobre o manifesto do Human

Rights Watch [11], em parceria com o Comitê Internacional da Cruz Vermelha [12], sobre as suas preocupações diante do aumento da disseminação de armas robóticas que têm o potencial de substituir humanos em situações de combate. O robô SR visa posicionar-se no mais seguro nível de interação humana, conhecido como "Human-in-the-Loop", em que os robôs necessitam de autorização humana para selecionar alvos e infligir danos, seguindo as normas internacionais estabelecidas.

Assim, o estudo foi iniciado em 2022, deu origem a um SR, Figura 1 de dois eixos, equipado com uma Pistola Taurus 9mm e duas câmeras, uma para visão do terreno e outra equipada com uma luneta. O robô possui dimensões compactas e uma estrutura modular composta por duas partes distintas: uma base e um módulo portador da arma. Possui dois motores Dynamixel Robotis MX-106R, cada um responsável por um eixo específico. No SR, as funções do atirador e do observador são replicadas por duas câmeras integradas a um sistema de visão computacional que utiliza IA, como o MP e o TLD, respectivamente, para detecção e perseguição de alvos. O TLD será usado na câmera do observador de forma a distinguir objetos, e o MP na do atirador de forma a ter precisão do centro dos olhos para o alvo. As câmeras utilizadas neste estudo são *Webcam Full Hd 1080p*, estas possuem auto foco e bom contraste, adaptando-se à iluminação.

Figura 1: Imagem de perfil do protótipo SR



Fonte: Os autores

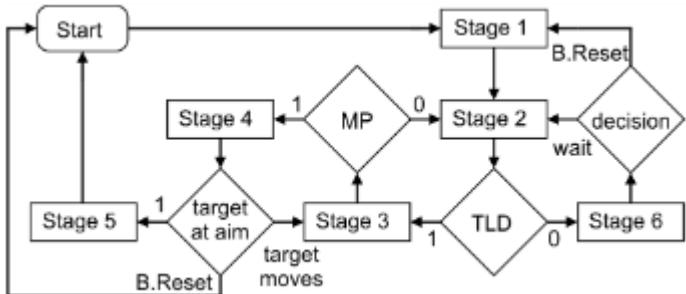
2. METODOLOGIA

O proposto artigo pretende explicar o funcionamento do software de interface do operador, bem como o desenvolvimento e a integração das tecnologias TLD e MP,

algoritmos de visão computacional baseados em inteligência artificial, os quais controlam os movimentos dos motores do robô apresentado em [13]. O objetivo principal é explicar os algoritmos que permitem o funcionamento da interface, onde o usuário possa indicar um alvo, e o robô identifique e faz o seguimento, mantendo-o centrado na tela. Como objetivos específicos podemos mencionar como as IAs interagem com o SR, incluindo a implementação de uma ROI em tempo real no algoritmo TLD, a integração entre as diversas ferramentas de IA empregadas, a utilização de keypoints do algoritmo MP para o controle dos motores do robô, e o desenvolvimento de uma interface operacional para o usuário.

Este artigo está estruturado em quatro seções distintas. Além da introdução, que apresenta conceitos e tecnologias pertinentes ao tema, inclui uma metodologia detalhada sobre o desenvolvimento e construção do software. A terceira seção aborda os resultados obtidos e as discussões decorrentes desses resultados. Por fim, a quarta seção engloba as conclusões, destacando possíveis aplicações futuras relacionadas à diferenciação de rostos.

Figura 2: Fluxograma de etapas



Fonte: Os autores

No funcionamento do SR, inicialmente quando se inicializa o sistema (Start) o robô se encontra em estado de vigilância e atende os comandos do operador, que devem ser fornecidos pelo teclado e podem movimentá-lo para qualquer direção ou ativar o algoritmo ROI que leva à primeira etapa. Neste momento (Stage 1), na tela onde o usuário visualiza as ações das duas câmeras, é disponibilizada a criação do pequeno retângulo da cor verde, que é controlado pelo mouse, em torno do alvo desejado que é selecionado pelo mouse, e pode ser movido ou alterado de tamanho com o intuito de selecionar o alvo de forma rápida e acurada. Após o retângulo ser criado pelo operador e clicado sobre o alvo a TLD entra em ação. Para melhor

visualização do início desta fase o retângulo passa da cor verde para a cor azul. A TLD possui dois ciclos internos, procura ou persegue. A procura é quando o alvo não é detectado e a perseguição é quando o alvo é detectado.

O algoritmo TLD utiliza valores de pixels para transformar esta informação em velocidade dos motores, e para esta conversão é utilizada uma função de mapeamento, que chamamos aqui de função MAP. O pseudocódigo desta função é apresentado na Figura 3.

Figura 3: Função Map

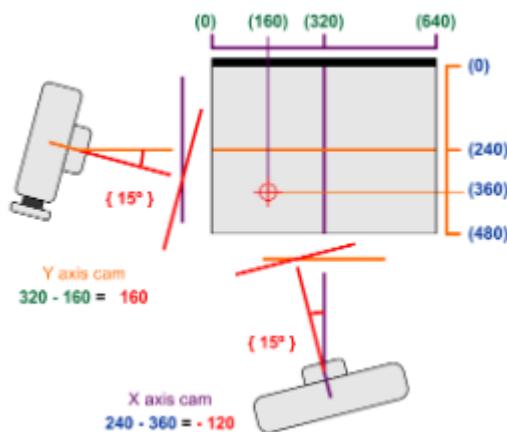
```
function MAP(refer){
    A ← minimum camera position
    B ← maximum camera position
    C ← minimum engine speed
    D ← maximum engine speed

    vel ← ((refer - A) × (D - C)) / (B - A) + C
    return vel
```

Fonte: Os autores

Como mencionado, a função MAP é a responsável por transformar valores de entrada de um intervalo de deslocamento de pixels para uma saída num intervalo de deslocamento de velocidade, que traduz as informações provenientes da câmera em comandos comprehensíveis para os motores e foi adaptada da biblioteca de linguagem C do Arduino para linguagem Python. O algoritmo utiliza a referência da distância entre o ponto central do alvo, dado pelos algoritmos TLD ou MP, e o ponto central da câmera e usa a distância para calcular a velocidade.

Figura 4: Captura dos pixels que serão convertidos pela função Map



Fonte: Os autores

Conforme ilustrado na Figura 4, cada motor possui um limite de velocidade diferente, pois seus comportamentos variam de acordo com os pontos centrais das câmeras. As câmeras possuem uma resolução de 640x480 pixels; portanto, o ponto central da câmera para o eixo x é de 320 e para o eixo y é de 240 pixels. Outra variante é o motor do eixo x, com uma relação de movimento de 1:1, enquanto para o motor do eixo y há uma relação de movimento de 20:1, devido a uma engrenagem do tipo rosca sem fim. Essa variação de movimentação do robô é resolvida com a função Map e com velocidades limites diferentes nos motores Dynamixels, sendo para o eixo x e y, respectivamente, 60 e 1000.

Agora, continuando com o fluxograma da metodologia de funcionamento do software deste trabalho, observamos que a segunda etapa se baseia na seleção e confirmação do alvo. As coordenadas x e y centrais do retângulo, ou seja, do alvo, são identificadas. Com o uso da função Map, possibilitando calcular as velocidades dos motores. O robô se moverá de forma autônoma e contínua (TLD) até atingir o ponto central do alvo, ajustando as velocidades dos motores conforme a verificação da distância entre o ponto central desejado e o da câmera, o que ocorre a cada recebimento de um novo quadro. Uma taxa de erro pode ser definida como a mínima diferença entre o ponto central do alvo e o da câmera. A sexta etapa ocorre caso o operador decida desligar o algoritmo TLD. Essa situação pode acontecer se o alvo estiver fora da região de cobertura das câmeras ou se for selecionado erroneamente pelo operador, não correspondendo ao desejado.

Posteriormente, na terceira etapa, com o robô centralizado no alvo retangular do ROI, o operador tem a opção de trocar o algoritmo de identificação por meio do teclado. Assim, o robô realizará uma identificação mais precisa usando o MP o que resulta na identificação de pontos chaves na face e corpo do alvo, diferenciando os pontos amarelos para o lado esquerdo e verde para o direito. Nesta fase, calcula-se o deslocamento do alvo em relação a um ponto de referência entre os olhos, permitindo que a câmera do "sniper" controle o movimento do robô assertivamente (MP), se desativado ou falhar em encontrar o alvo dado um tempo limite de 2 segundos irá retornar para o estágio 2.

Na quarta etapa, o alvo está na mira e o robô com precisão aguarda a decisão do operador para interromper e ir para etapa inicial ou prosseguir para a etapa final da missão, caso o alvo se movimente, de forma automatizada o MP centraliza o alvo

em tempo real, utilizando a função Map para passagem de dados aos motores. Finalmente, na quinta etapa, o operador realiza o disparo e o robô retorna à posição inicial de vigília aguardando novas instruções. Dessa forma, finalizando o ciclo que o RS percorre da identificação visual até o disparo realizado sob supervisão do operador.

A supervisão e controle do sistema são realizados por um operador designado, cujas operações são conduzidas por meio de uma interface, Figura 5. Na imagem, destacam-se duas telas principais: a tela principal do observador e uma tela secundária destinada ao atirador. Dado o contexto acadêmico deste estudo, a interface é equipada com uma série de interações, incluindo botões para ativar IAs, botões de reinicialização e de emergência, botões de disparo, bem como um bloco de texto para monitoramento de código, entre outras funcionalidades essenciais.

Figura 5: Interface entre operador e SR



Fonte: Os autores

Essa interface permite observações sobre o comportamento das IAs e a resposta dos motores. A análise das interações entre o operador e o sistema podem fornecer insights valiosos para otimizar a eficiência operacional e garantir segurança e confiabilidade das operações.

3. RESULTADOS E DISCUSSÃO

Conforme descrito na metodologia apresentada na Figura 2, o processo é iniciado com a seleção de um alvo pelo operador. Em seguida, prossegue-se para a Etapa 1, como ilustrado na Figura 6.

Figura 6: Interface entre operador e SR



Fonte: Os autores

A câmera apresentada na Figura 6 possui ampla área de captura para abranger maior quantidade de objetos e pessoas que possam ser selecionadas como alvo. A seleção de uma área de interesse permite a câmera do Sniper um maior detalhamento do alvo. É possível observar que a imagem não apresenta uma alta qualidade, uma vez que a câmera foi configurada para uma resolução de 640x480 pixels. Além disso a imagem utilizada corresponde ao observador, o qual não possui sistema de zoom apropriado.

Na Etapa 2, é importante ressaltar que a área de interesse pode ser criada em qualquer área da imagem, tornando possível a seleção de um objeto não humano e perseguição deste, o que pode ser favorável no ponto de vista de uma busca de alvo de escopo mais abrangente, entretanto a tecnologia construída é direcionada a alvos humanos, dessa forma pode-se tornar necessário repetir a etapa de seleção do alvo para prosseguir na ativação do MP para controle dos motores e busca do alvo. O resultado desta etapa está ilustrado na Figura 7.

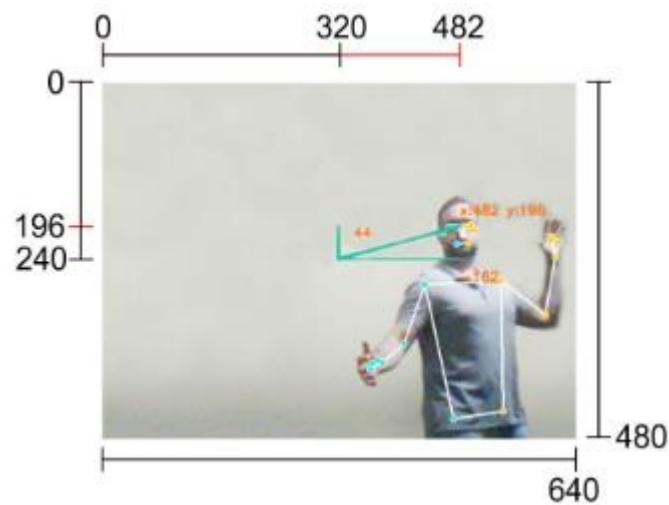
Figura 7: Resultado da Etapa 2



Fonte: Os autores

Assim, com a utilização do MP na Etapa 3, ilustrada na Figura 8, em conjunto ao TLD é possível trabalhar com grande precisão, porém o sistema não possui técnicas eficazes e específicas para real distinção entre pessoas. Esta habilidade poderá ser adquirida com a utilização de outras ferramentas que trabalham conjuntas a biblioteca OpenCV, utilizando do cálculo da distância entre pontos específicos do rosto para a diferenciação.

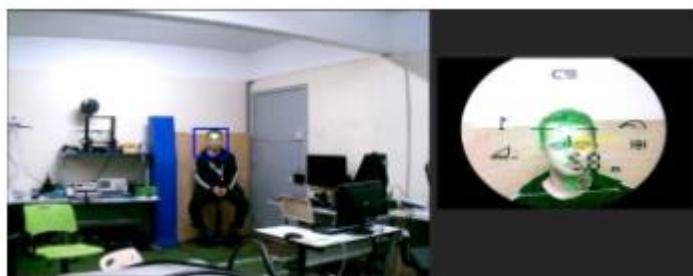
Figura 8: Resultado da Etapa 3



Fonte: Os autores

Por fim, após a transição da busca para o disparo no alvo no Etapa 4, foi utilizada uma caneta laser no local de uma arma que, ao acionar o disparo a mesma era ativada, a fim de demonstrar os testes realizados na Etapa 5.

Figura 9: Resultado da Etapa 5



Fonte: Os autores

A Figura 9 demonstra o teste realizado na ativação do laser, na imagem mais ampla à esquerda está a visão do observador, com o alvo já selecionado e centrado, e à direita está a visão do sniper, com maior detalhamento do alvo e posição exata da mira.

Independentemente de sua movimentação, a mira tende a perseguir o alvo, o que também pode ser utilizado como uma poderosa ferramenta de intimidação e confusão do alvo por conta da dificuldade na abertura dos olhos tendo em vista a localização do feixe de luz.

4. CONCLUSÃO

O estudo evidencia que a combinação de tecnologias de IA e visão computacional no SR representa uma solução promissora para operações militares. Os resultados específicos destacam a utilização em tempo real de uma ROI convertida para o algoritmo de TLD, bem como o controle dos motores e o alinhamento com o alvo por meio das IAs. A interface do operador se harmoniza com os equipamentos robóticos de combate, garantindo um cuidado ético em um tema ainda em discussão.

Próximos estudos focados na otimização dos algoritmos de IA e no desenvolvimento de um sistema próprio de combate se fazem necessários para avanços futuros nesta área. Esses novos estudos abrem a possibilidade de reconhecimento facial, através da substituição ou mistura de tecnologias de reconhecimento facial em tempo real com as usadas atualmente. Artigos como [2] e [7] mostram que obtêm-se melhores resultados algoritmos de IAs combinadas.

REFERÊNCIAS

1. Department of the Army. Sniper Training. Washington: U.S. Government Printing Office: 1994—528-027/80156, 1994, p. 329.
2. Camillo Lugaressi et al. "MediaPipe: A Framework for Building Perception Pipelines". In: (June 2019).
3. Valentin Bazarevsky et al. "BlazePose: On-device Real-time Body Pose tracking". In: (June 2020).
4. Zdenek Kalal, Krystian Mikolajczyk, and Jiri Matas. "Tracking-Learning-Detection". In: IEEE Transactions on Pattern Analysis and Machine Intelligence 34.7 (2012), pp. 1409–1422. DOI: 10.1109/TPAMI.2011.239.
5. Nadja Dardagan et al. "Multiple Object Trackers in OpenCV: A Benchmark". In: Oct. 2021. DOI: 10.1109/ISIE45552.2021.9576367.
6. P D Rathika et al. "Gesture Based Robot Arm Control". In: Nat. Volatiles & Essent. Oil (2021). DOI: 8(5):3133- 3143.
7. Muneera Altayeb. "Hand Gestures Replicating Robot Arm based on MediaPipe". In: Indonesian Journal of Electrical Engineering and Informatics (IJEEL) 11 (Sept. 2023), pp. 727–737. DOI: 10.52549/ijeei.v11i3. 4491.
8. Jing Yuan et al. "Fusing Skeleton Recognition With Face-TLD for Human Following of Mobile Service Robots". In: IEEE Transactions on Systems, Man, and Cybernetics: Systems 51.5 (2021), pp. 2963–2979. DOI: 10.1109/TSMC.2019.2921974.
9. Mark Prigg. Who goes there? Samsung unveils robot sentry that can kill from two miles away. SGR-1 has heat and motion detectors to identify potential targets more than 2 miles away Being used in the Demilitarised Zone. Acessado em 01 jan. 2023. 2014. URL: <https://www.dailymail.co.uk/sciencetech/article-56847/Who - goes - Samsung - reveals - robot - sentry - set - eye - North-Korea.html>.
10. Bong-Cheol Seo, Sung-Soo Kim, and Dong-Youm Lee. "Target-Tracking System for Mobile Surveillance Robot Using CAMShift Image Processing Technique". In: Transactions of the Korean Society of Mechanical Engineers A (2014). DOI: 10.3795/KSME-A.2014.38.2.129.
11. Bonnie Docherty. Losing Humanity. The Case against Killer Robots. Acessado em 01 jan. 2023. 2012. URL: <https://www.hrw.org/report/2012/11/19/losing-humanity/case-against-killer-robots>.
12. CICV. Armas autônomas: os Estados devem discutir os grandes desafios éticos e humanitários. Acessado em 01 jan. 2023. 2013. URL: <https://www.icrc.org/pt/content/armas-autonomas-os-estados-devem-discutir-os-grandes-desafios-eticos-e-humanitarios>.
13. Ricardo Dias Schirmer et al. "Project of a Sentinel Robot Controlled with a Tracking Algorithm". In: 2022 Latin American Robotics Symposium (LARS), 2022 Brazilian Symposium on Robotics (SBR), and 2022 Workshop on Robotics in Education (WRE) (2022), pp.241–246.DOI: 10.1109/LARS/SBR/WRE56824.2022.9995943.

Agência Brasileira ISBN
ISBN: 978-65-6016-048-4