



UNIVERSIDADE ESTADUAL DE CAMPINAS  
Faculdade de Tecnologia

**Leonardo Grando**

**Procedimento de Recarga de Baterias de Drones  
Utilizando Simulação por Agentes e Equilíbrio de Nash**

Limeira  
2020

**Leonardo Grandó**

**Procedimento de Recarga de Baterias de Drones Utilizando Simulação  
por Agentes e Equilíbrio de Nash**

Dissertação apresentada à Faculdade de Tecnologia da Universidade Estadual de Campinas como parte dos requisitos para a obtenção do título de Mestre em Tecnologia, na área de Sistemas de Informação e Comunicação.

**Orientador: Prof. Dr. Paulo Sérgio Martins Pedro**

**Coorientador: Prof. Dr. Edson Luiz Ursini**

Este exemplar corresponde à versão final da Dissertação defendida por Leonardo Grandó e orientada pelo Prof. Dr. Paulo Sérgio Martins Pedro.

Limeira  
2020

Ficha catalográfica  
Universidade Estadual de Campinas  
Biblioteca da Faculdade de Tecnologia  
Felipe de Souza Bueno - CRB 8/8577

G764p Grando, Leonardo, 1984-  
Procedimento de recarga de baterias de drones utilizando simulação por agentes e equilíbrio de Nash / Leonardo Grando. – Limeira, SP : [s.n.], 2020.

Orientador: Paulo Sérgio Martins Pedro.

Coorientador: Edson Luiz Ursini.

Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Tecnologia.

1. Simulação (Computadores). 2. Aeronave não tripulada. 3. Agentes inteligentes (Software). 4. Teoria dos jogos. 5. Inteligência coletiva. I. Martins Pedro, Paulo Sérgio, 1967-. II. Ursini, Edson Luiz, 1951-. III. Universidade Estadual de Campinas. Faculdade de Tecnologia. IV. Título.

Informações para Biblioteca Digital

**Título em outro idioma:** Drones battery recharging procedure using agent-based simulation and Nash equilibrium

**Palavras-chave em inglês:**

Computer simulation

Drone aircraft

Intelligent agents (Computer software)

Game theory

Swarm intelligence

**Área de concentração:** Sistemas de Informação e Comunicação

**Titulação:** Mestre em Tecnologia

**Banca examinadora:**

Edson Luiz Ursini [Coorientador]

José Roberto Emiliano Leite

Ulisses Martins Dias

**Data de defesa:** 21-08-2020

**Programa de Pós-Graduação:** Tecnologia

**Identificação e informações acadêmicas do(a) aluno(a)**

- ORCID do autor: <https://orcid.org/0000-0002-0448-209X>

- Currículo Lattes do autor: <http://lattes.cnpq.br/1278197446520776>

## FOLHA DE APROVAÇÃO

Abaixo se apresentam os membros da comissão julgadora da sessão pública de defesa de dissertação para o Título de Mestre em Tecnologia na área de concentração Sistemas de Informação e Comunicação, a que se submeteu o aluno Leonardo Grando, em 21 de agosto de 2020 na Faculdade de Tecnologia – FT/UNICAMP, em Limeira/SP.

**Prof. Dr. Edson Luiz Ursini**  
Presidente da Comissão Julgadora

**Dr. José Roberto Emiliano Leite**  
Consultor Independente

**Prof. Dr. Ulisses Martins Dias**  
FT/UNICAMP

Ata da defesa, assinada pelos membros da Comissão Examinadora, consta no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria de Pós Graduação da FT.

*A reação mais comum da mente humana a uma conquista não é satisfação, e sim o anseio por mais.*  
(Yuval Noah Harari)

# Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Agradeço com todo meu coração:

- aos meus pais Terezinha e Antônio pela dádiva da vida, pela compreensão pelos meus momentos de ausência devido a minha dedicação a este trabalho;
- à minha esposa Patrícia por estar sempre ao meu lado motivando-me e também compreendendo os meus momentos de ausência. Ela também me mostrou o caminho da docência.
- Ao meu orientador Paulo, que sempre esteve ao meu lado em decisões acadêmicas e profissionais e mostrou-me caminhos e me motivou para a execução e finalização deste trabalho;
- Ao meu coorientador Ursini, que iluminou (e ainda ilumina) este trabalho com ótimas ideias e participando do mesmo de forma ativa e me acompanhando por longos períodos.  
Os prezados Professores Doutores Paulo e Ursini mais do que orientadores e coorientadores me apoiaram durante este período do Mestrado e este trabalho só foi possível pela participação direta de ambos;
- Aos funcionários e Professores da FT e da Unicamp, que de forma direta ou indireta participaram da minha formação;
- Às cantorias das minhas calopsitas, que sempre estiveram junto comigo neste trabalho, especialmente in memoriam a Kalo.

# Resumo

Este trabalho procura solucionar um dos problemas mais críticos das redes *Flying AdHoc* (FANET), que é a questão da coordenação da recarga de baterias de drones que voam em forma de enxame (*Swarms*).

Para que as recargas sejam realizadas da melhor maneira possível, é desejável que o número de dispositivos de carregamento (estações base) não seja excessivamente alto principalmente devido ao alto custo de implantação.

Por outro lado, também é necessário que, quando os drones quiserem recarregar, sempre haja uma fonte de energia disponível. Ou seja, buscamos o equilíbrio entre o número economicamente viável de estações de recarga e o abastecimento adequado dos drones quando isso for necessário. Para essa finalidade, propomos agentes (drones) munidos de inteligência interna, ou seja, com preditores internos que fornecem inteligência na tentativa de prever a próxima taxa de presença nesse dispositivo de carregamento e dessa maneira poder decidir se deve ou não ir abastecer. O ideal é que a previsão seja sempre a melhor possível. Assim, o drone deveria ir quando prevê que deve ir e não deveria ir quando prevê não ir.

A utilização do equilíbrio de Nash para este problema, sendo possível pela utilização da modelagem via o Problema El Farol Bar (PEFB), permite o desenvolvimento de uma analogia sem o conluio dos agentes na coordenação da simulação da recarga desse conjunto de drones. Ou seja, com relação à coordenação do enxame para a recarga das baterias não haverá gasto de energia em comunicação, embora esta continue nas demais tarefas inerentes ao *swarm* de drones. A verificação da adequação da proposta é feita por meio de Simulação Baseada em Agentes e neste modelo são utilizadas três políticas diferentes para a tomada de decisão do melhor preditor para cada drone. Isso permite verificar o desempenho na operação do sistema por meio do Equilíbrio de Nash.

No atual estado dessa analogia considera-se que, caso os drones forem para a estação de recarga e a mesma estiver cheia, não haverá recarga possível porque o sistema estará sobrecarregado.

Neste estudo estão incluídas análises microscópicas e macroscópicas do desempenho do *swarm*. A análise microscópica é a avaliação do desempenho das recompensas de cada preditor em relação a um conjunto de parâmetros de simulação, visando um aumento da eficácia no desempenho microscópico. A análise macroscópica é a avaliação do desempenho do atendimento global do sistema com os três tipos de políticas. Esta última análise é usada como base para o desenvolvimento da analogia de recarga dos drones.

Dessa maneira, avalia-se o desempenho dos melhores conjuntos de simulação para a recarga dos drones que permitem abastecer abaixo do limiar de recarga (número de posições disponível de recarga), mas que estão relativamente próximos a esse limiar.

# Abstract

This work seeks to solve one of the most critical problems of the Flying AdHoc (FANET) networks, which is the issue of coordinating the recharging of drones that fly in the form of Swarms.

For recharging to be done in the best possible way, it is desirable that the number of charging devices (base stations) did not be excessively high due to the high implementation cost.

Conversely, it is also necessary that, when drones want to recharge, they must have a source of energy available. In other words, we search for a balance between the economically viable number of charging stations and the adequate energy supply for the drones when necessary. For this, we propose agents (drones) equipped with internal intelligence, that is, with internal predictors that provide intelligence to attempt to predict the next attendance rate in the charging device and thus be able to decide whether go or not go to the recharging. Ideally, the forecast should be as best as possible. Therefore, the drone should go when it predicts it should go and it shouldn't go when it predicts not to go.

The Nash equilibrium usage for this problem is made possible by the modeling via the El Farol Bar Problem (EFBP), which allows the development of this analogy without the collusion of agents in coordinating the simulation of the recharge of this set of drones. In other words, there will be no energy expenditure on communication about the drones' battery recharging coordination, although the communication will continue in the other tasks inherent to the swarm of drones. The verification of the suitability of the proposal is done through Agent-Based Simulation and are used three different policies for the best predictor decision by each drone. This will allow us to verify the performance in the operation of the system through a Nash Equilibrium.

In the current state of this analogy is considered that if the drones go to the charging station and it is full, there will be no possible charging because the system is overloaded.

This study includes microscopic and macroscopic analysis. Microscopic analysis is the evaluation of the performance of the rewards of each predictor concerning a set of simulation parameters, aiming at a microscopic behavior performance improvement. A macroscopic analysis is the evaluation of the performance of the global service of the system with three types of policies. This latter analysis is used as a basis for evaluating the drone's recharge analogy.

In this way, the performance of the best simulation sets for the recharge of drones is evaluated, which allows supplying below the control threshold (attendance below than the number of recharge positions), but which are relatively close to the threshold.

# Lista de Figuras

2.1	Histórico da lotação para 100 semanas, conforme Arthur (1994). Fonte: Adaptado de Arthur (1994). . . . .	24
2.2	<i>Framework</i> proposto por Rand, integrando um modelo baseado por agentes com aprendizado por máquinas. Fonte: Adaptado de Rand (2006). . . . .	28
2.3	Estados finitos para um Drones conforme proposta de Boggio-Dandry e Soyata (2018). Fonte: Adaptado de Boggio-Dandry e Soyata (2018). . . . .	40
3.1	Integração código <i>Python</i> e <i>Netlogo</i> . . . . .	42
3.2	Tela do Ambiente de Simulação . . . . .	43
3.3	Representação gráfica do <i>El Farol Bar</i> e tipos de agentes . . . . .	43
3.4	Representação da analogia . . . . .	52
4.1	Comparativo do desempenho dos preditores com agentes 100% ZI . . . . .	58
4.2	<i>BoxPlots Rewards</i> 100%ZI e Limiar 20% . . . . .	60
4.3	<i>BoxPlots Rewards</i> 100% ZI e Limiar 40% . . . . .	60
4.4	<i>BoxPlots Rewards</i> 100%ZI e Limiar 60% . . . . .	61
4.5	<i>BoxPlots Rewards</i> 100%ZI e Limiar 80% . . . . .	61
4.6	Comparativo do desempenho dos preditores com agentes 50% ZI e 50% CPX . . . . .	62
4.7	<i>BoxPlots Rewards</i> 50%ZI & 50%CPX Limiar 20% . . . . .	64
4.8	<i>BoxPlots Rewards</i> 50%ZI & 50%CPX e Limiar 40% . . . . .	64
4.9	<i>BoxPlots Rewards</i> 50%ZI & 50%CPX e Limiar 60% . . . . .	65
4.10	<i>BoxPlots Rewards</i> 50%ZI & 50%CPX e Limiar 80% . . . . .	65
4.11	Comparativo do desempenho dos preditores com agentes 100% CPX . . . . .	68
4.12	<i>BoxPlots Rewards</i> 100%CPX Limiar 20% . . . . .	68
4.13	<i>BoxPlots Rewards</i> 100%CPX e Limiar 40% . . . . .	68
4.14	<i>BoxPlots Rewards</i> 100%CPX e Limiar 60% . . . . .	69
4.15	<i>BoxPlots Rewards</i> 100%CPX e Limiar 80% . . . . .	69
4.16	<i>Boxplots</i> dos valores do <i>Attendance</i> para todos limiares . . . . .	76
4.17	Probabilidades de recargas (valores menores do que o limiar). . . . .	78

# Lista de Tabelas

2.1	Algumas analogias do PEFB utilizadas na literatura . . . . .	31
3.1	Descrição dos Parâmetros dos preditores . . . . .	45
3.2	Parâmetros da simulação . . . . .	46
3.3	Tabela de recompensas "R" para ações dos agentes . . . . .	46
3.4	Parâmetros para simulação - Experimento 1 . . . . .	50
3.5	Parâmetros para simulação - Experimentos 2 e 3 . . . . .	51
3.6	Associação dos tipos de estados dos drones pelos tipos de preditores . . . . .	55
4.1	Estatística dos <i>Rewards</i> para os preditores 100% ZI, com limiar de 20 % . . . . .	59
4.2	Estatística dos <i>Rewards</i> para os preditores 100% ZI, com limiar de 40 % . . . . .	59
4.3	Estatística dos <i>Rewards</i> para os preditores 100% ZI, com limiar de 60 % . . . . .	62
4.4	Estatística dos <i>Rewards</i> para os preditores 100% ZI, com limiar de 80 % . . . . .	62
4.5	Estatística dos <i>Rewards</i> para os preditores 50% ZI e 50% CPX, com limiar de 20 % . . . . .	63
4.6	Estatística dos <i>Rewards</i> para os preditores 50% ZI e 50% CPX, com limiar de 40 % . . . . .	66
4.7	Estatística dos <i>Rewards</i> para os preditores 50% ZI e 50% CPX, com limiar de 60 % . . . . .	67
4.8	Estatística dos <i>Rewards</i> para os preditores 50% ZI e 50% CPX, com limiar de 80 % . . . . .	70
4.9	Estatística dos <i>Rewards</i> para os preditores 100% CPX, com limiar de 20 % . . . . .	71
4.10	Estatística dos <i>Rewards</i> para os preditores 100% CPX, com limiar de 40 % . . . . .	72
4.11	Estatística dos <i>Rewards</i> para os preditores 100% CPX, com limiar de 60 % . . . . .	73
4.12	Estatística dos <i>Rewards</i> para os preditores 100% CPX, com limiar de 80 % . . . . .	74
4.13	Resumo estatísticos (média e desvio padrão) dos valores médios dos <i>attendance</i> para as simulações . . . . .	75
4.14	Média das probabilidades de recarga dos drones para cada conjunto de parâmetros . . . . .	77

# Lista de Símbolos

$IoT$	Internet das Coisas
$PEFB$	Problema El Farol Bar
$FANETs$	Flying Ad-Hoc Networks
$COIN$	Collective Intelligence (Framework inteligência coletiva)
$L$	Quantidade de agentes que foram ao bar (Attendance) no ciclo
$B$	Limiar de $n$ agentes que definem como o bar esta lotado ou não
$ABM$	Modelagem Baseada por Agentes
$SCA$	Sistemas Complexos Adaptativos
$t$	ciclo de simulação
$p$	preditor "p" utilizado no agente
$k$	"k" preditores disponíveis aos agentes.
$n$	Agente "n"
$m$	Informação disponível "memória", $m$ semanas anteriores
$N$	somatório dos "n" agentes do sistema
$p(t)$	Valor predito pelos agentes no ciclo $t$
$Errel_{n,p,t}$	Erro relativo calculado pelo agente $n$ , utilizando o preditor $p$ no ciclo $t$ .
$SomaErrel_{n,p,t}$	Somatória do erro relativo
$TotalSomErrel_{n,t}$	Somatória da soma dos erros relativos
$R$	valor total das recompensas para cada agente
$h(t)$	valor do attendance no tempo $t$
$R$	valor total das recompensas para cada agente
$U_t$	Pontuação para o ciclo (Precisão original)
$s^k$	Preditor do attendance (precisão original)
$w$	Janela de período para calculo de estimadores
$k$	Passos a frente
$ZI$	Preditores Zero Inteligencia
$CPX$	Preditores Complexos
$MA$	Modelos de Média Móveis
$FMM_{t+k}$	Previsão para média móvel para o passo $k$
$FME_{t+k}$	Previsão para média exponencial para o passo $k$

$\alpha$	constante de suavização (valor entre 0 e 1)
<i>comEx</i>	centro de massa - média móvel exponencial
<i>hlEx</i>	meia vida - média móvel exponencial
<i>AR(p)</i>	Modelos Autorregressivos de ordem p
$FAR_t$	Previsão para modelos autorregressivos no tempo t
$\beta$	Parâmetros reais (constantes fixas)
$\varepsilon$	Ruídos relacionado aos preditores
<i>ARIMA</i>	Modelo Autorregressivo Integrado com Média Móvel
$q$	Ordem de diferenciação para um modelo MA
$\theta$	Parâmetros reais (constante)
<i>dRM</i>	Ordem de diferenciação para remoção de tendência
$y_t$	Série temporal à ser modelada e prevista.
$\mu_t$	Componente relacionado à tendência.
$\gamma_t$	Componente relacionado à sazonalidade.
$\psi_t$	Componente relacionado à ciclicidade.
$r_t$	Componente auto-regressivo.
$\epsilon_t$	Componente irregular.
$\sum_{i=1}^p \phi_i y_{t-1}$	representa os termos auto-regressivo
$\sum_{j=1}^m \beta_j X_{jt}$	termos regressivos explanatórios.
<i>RMSE</i>	Erro Quadrático Médio.

# Sumário

<b>1</b>	<b>Introdução</b>	<b>15</b>
1.1	Motivação do Trabalho . . . . .	15
1.2	Descrição do problema - <i>El Farol Bar</i> . . . . .	16
1.3	Estrutura do trabalho . . . . .	17
<b>2</b>	<b>Levantamento bibliográfico</b>	<b>19</b>
2.1	Sistemas Complexos . . . . .	19
2.2	Modelagem baseada em simulação por agentes . . . . .	20
2.3	Modelo <i>El Farol Bar</i> . . . . .	22
2.3.1	Origem do Problema do <i>El Farol Bar</i> . . . . .	23
2.3.2	Revisão Bibliográfica e aplicações do Modelo El Farol na Literatura . . . . .	25
2.4	Analogias anteriores do PEFB . . . . .	30
2.5	Técnicas de predição . . . . .	30
2.6	Preditores utilizados nos modelos . . . . .	32
2.6.1	Médias Móveis (MA) . . . . .	32
2.6.2	Modelos Exponenciais . . . . .	33
2.6.3	Modelos Regressivos . . . . .	34
2.6.4	Preditores Zero Inteligência . . . . .	36
2.7	Proposta de Aplicação do Modelo El Farol para Simulação de enxames de Drones . . . . .	37
<b>3</b>	<b>Desenvolvimento</b>	<b>41</b>
3.1	Metodologia . . . . .	41
3.2	Modelo Computacional . . . . .	42
3.2.1	Agentes . . . . .	42
3.2.2	Tomada de decisão pelos agentes . . . . .	46
3.2.3	Uso de apenas um preditor por agente . . . . .	47
3.2.4	Melhor preditor pelo somatório das diferenças . . . . .	47
3.2.5	Melhor preditor pela soma dos pesos das diferenças . . . . .	48
3.3	Questões a serem respondidas: . . . . .	49
3.3.1	Como os aspectos microscópicos deste modelo podem ser utilizados em futuros parâmetros da simulação? . . . . .	49
3.3.2	Como o sistema se comporta alterando os parâmetros implementados neste modelo? . . . . .	51
3.3.3	Como utilizar o PEFB em uma analogia para simular as recargas de baterias para um enxame de drones? . . . . .	52

<b>4</b>	<b>Pesquisa do melhor desempenho: casos estudados</b>	<b>56</b>
4.1	Como os aspectos microscópicos deste modelo podem ser utilizados em futuros parâmetros da simulação? . . . . .	56
4.1.1	Simulações com agentes 100% ZI . . . . .	57
4.1.2	Simulações com agentes 50% ZI e 50% CPX . . . . .	59
4.1.3	Simulações com agentes 100% CPX . . . . .	66
4.2	Como o sistema se comporta alterando os parâmetros implementados neste modelo? . . . . .	71
4.3	Como utilizar o PEFB em uma analogia para simular as recargas de baterias para um enxame de drones? . . . . .	73
<b>5</b>	<b>Conclusões</b>	<b>80</b>
5.1	Resultados finais e questões norteadoras . . . . .	80
5.1.1	Como os aspectos microscópicos deste modelo podem ser utilizados em futuros parâmetros da simulação? . . . . .	80
5.1.2	Como o sistema se comporta alterando os parâmetros implementados neste modelo? . . . . .	81
5.1.3	Como utilizar o PEFB em uma analogia para simular as recargas de baterias para um enxame de drones? . . . . .	81
5.2	Trabalhos Futuros . . . . .	82
	<b>Referências bibliográficas</b>	<b>84</b>

# Capítulo 1

## Introdução

### 1.1 Motivação do Trabalho

O objetivo deste trabalho consiste no estudo e inclusão de técnicas de predição para a otimização da taxa de presença dos agentes de acordo com o modelo *El Farol Bar* de William Brian Arthur (ARTHUR, 1994), em que os possíveis clientes (agentes) desejam definir se devem ou não ir ao bar "El Farol", usando como referência informações relativas às quantidades de clientes (histórico) que foram anteriormente ao bar.

O modelo *El Farol Bar* já foi previamente modelado e implementado de várias formas e em várias linguagens de programação. Porém, neste trabalho utilizaremos a abordagem na forma de Simulação por Agentes (ABS), implementado no Software *NetLogo* e baseado no modelo proposto por Rand e Wilensky.

Esse objetivo geral pode ser resumido nas seguintes questões:

1. Como os aspectos microscópicos deste modelo podem ser utilizados em futuros parâmetros desta simulação?

Com o objetivo de se conhecer o comportamento microscópico (aquele inerente à cada agente), nesta questão estudou-se a *performance* dos preditores, em relação a um indicador interno, baseado no Equilíbrio de Nash, denominado *Rewards*. Pelo estudo desses indicadores, pretende-se utilizar os mesmos para novos parâmetros, como nova forma de tomada de decisão, controle da capacidade das baterias dos drones, perfil de trabalho entre outros.

2. Como o sistema se comporta alterando os parâmetros implementados neste modelo?

Usando o conhecimento descrito no Capítulo 2, foram realizadas sugestões de preditores para serem utilizados no PEFB. Tais tipos e parâmetros dos preditores foram escolhidos de forma arbitrária, baseados na literatura vigente, visando explorar possíveis resultados diferentes dos já encontrados na literatura. Uma contribuição deste trabalho foi dividir os preditores em dois tipos de populações, baseados no poder computacional utilizado pelos preditores.

Serão avaliados os resultados obtidos com a variação dos parâmetros de simulação (quantidade de preditores por agentes, quantidade de informação disponível para os preditores, tipo de população, variação do limiar e tipo de política de cálculos para o melhor preditor. Tais parâmetros são explicados no Capítulo 3 e os resultados encontrados estão presentes no Capítulo 4.

3. Como utilizar o PEFB em uma analogia para simular às recargas de baterias para um enxame de drones?

No Capítulo 3 são apresentadas analogias que já foram utilizadas para o PEFB, onde o mesmo já serviu de base para modelos de bolsa de valores, simulação de um terminal marinho, entre outras abordagens. Pretende-se executar a modelagem de uma analogia com o uso do modelo PEFB, em um modelo de carregamento de bateria de drones, que pertencem a uma rede *Ad Hoc (Fanets-Flying AdHoc Network)*. Nesse modelo, as analogias são: o bar é a estação de carregamento e os agentes são os drones (dotados de inteligência por meio da introdução de preditores).

Com tal estudo, pretende-se expandir o conhecimento de tais técnicas de predições e expandi-lo para outros modelos de simulação por agentes (também chamados de ABS ou Simulação baseadas em Agentes).

## 1.2 Descrição do problema - *El Farol Bar*

Neste modelo,  $N$  clientes (ou melhor, agentes) desejam decidir, de forma independente, se devem ou não ir ao *El Farol Bar*. Nesse bar, semanalmente ocorrem shows de música Irlandesa. Tais clientes possuem desejo de ir ao bar, mas como o espaço físico do mesmo é limitado, existe um limiar  $B$  de lotação, que caso o mesmo seja ultrapassado, os agentes não se sentem

confortáveis. No modelo original (PEFB) esse limiar foi determinado como 60% da quantidade total da capacidade do local.

Os agentes não possuem a capacidade de saber se o bar irá encher ou não, mas os mesmos possuem preditores internos que, utilizando o histórico de  $m$  semana anteriores, tentam prever se devem ir ao bar ou ficar em casa. Tais escolhas não são afetadas pelas visitas anteriores e não ocorre comunicação entre os agentes (conluio). A única informação disponível para a tomada de decisão dos clientes é a quantidade de visitantes das últimas semanas (ARTHUR, 1994).

O modelo criado para simular a tomada de decisão dos agentes é um sistema onde cada agente possui uma quantidade de preditores (visando prever o número da lotação para a próxima semana) e a decisão de qual desses preditores a ser utilizado é obtido pelo cálculo entre a menor diferença entre o valor predito e o valor encontrado. Na simulação feita pelo autor, verificou-se que não ocorreram ciclos persistentes e a lotação média sempre converge para 60%. É observado que os preditores se auto organizam em um padrão de equilíbrio em média de 40% de predição acima de 60% de lotação do bar e 60% abaixo desse valor.

Esse modelo pode ser expandido para outras aplicações, como especulação do mercado de ações, precificação de oligopólios ou posicionamento de produtos no mercado (WILENSKY; RAND). O autor Franke (2003) descreve certas similaridades entre esse modelo e o mercado financeiro, onde  $N$  jogadores escolhem se devem investir ou não no mercado. S. Chen, Lv e Wang (2016) cita também que esse modelo é utilizado para descrever congestionamento de tráfego e de redes de computadores.

### 1.3 Estrutura do trabalho

Esta dissertação está estruturada da seguinte forma:

1. Capítulo 1: Breve descrição do modelo a ser estudado junto com a motivação e justificativa.
2. Capítulo 2: Descrição dos métodos de simulação utilizados, métodos de predição, descrição dos trabalhos já realizados integrando o modelo El Farol e técnicas de predição.

3. Capítulo 3: Descrição das etapas do desenvolvimento do projeto, descrição dos parâmetros de simulação e lógica do programa.
4. Capítulo 4: Descrição dos resultados obtidos no experimento e descrição da analogia proposta.
5. Capítulo 5: Discussão e comparativos dos resultados obtidos e sugestões para trabalhos futuros.

## Capítulo 2

# Levantamento bibliográfico

Neste capítulo apresentam-se as definições necessárias para o desenvolvimento do trabalho. São descritos conceitos relativos sobre que é um sistema complexo e simulação baseada por agentes.

Também foi realizada uma revisão bibliográfica sobre o Problema *El Farol Bar* (PEFB). A seguir, definem-se os preditores que são utilizados nesta simulação e finalmente vem a descrição da analogia proposta, que é a coordenação da recarga de um enxame de drones.

### 2.1 Sistemas Complexos

Um sistema complexo pode ser definido como uma rede de componentes sem um controle central que possuem regras simples de operações e que possibilitam um comportamento complexo coletivo, processamento de informações sofisticadas e adaptação via aprendizado ou via evolução (MITCHELL, 2011). Esses sistemas são chamados também de sistemas complexos adaptativos (SCA).

Holland (2006) apresenta algumas características desses sistemas:

- Paralelismo: SCA consistem em uma grande quantidade de agentes que interagem entre si pelo envio e recebimento de sinais de forma simultânea;
- Ações condicionais: As ações que os agentes realizam em um SCA dependem dos sinais que eles recebem. Os agentes possuem uma estrutura Se/Então (Se tal sinal é recebido, então execute ação y);

- Modularidade: Um agente possui um grupo de regras que são combinadas para agir como "sub-rotina";
- Adaptação e evolução: No SCA, os agentes mudam conforme o tempo. Essas modificações são geralmente adaptações que melhoram a *performance*, além de variações aleatórias.

Os sistemas auto-organizados são aqueles cujo comportamento organizado ocorre sem um controlador externo ou pela presença de líderes. Regras simples produzem comportamentos complexos, difíceis de se prever, chamados de emergentes. Mitchell (2011) apresenta outra definição para os sistemas complexos: **Um sistema que exhibe comportamento emergente não trivial e auto-organizado.**

O autor Mitchell (2011) cita alguns exemplos de sistemas complexos:

1. Colônias de insetos;
2. O funcionamento do cérebro;
3. O sistema imunológico;
4. Sistemas econômicos;
5. A rede mundial de computadores;
6. Relação presa/predador;
7. Crescimento de cristais.

## 2.2 Modelagem baseada em simulação por agentes

Modelagem por simulação baseada em agentes (ABMS) é uma forma de modelar sistemas complexos, compostos por agentes autônomos (MACAL; NORTH, 2010). Os autores Wilensky e Rand (2015) definem o termo **modelo** como um descritivo de um sistema do mundo real, ou seja, uma simplificação do mundo real.

Um modelo não pode conter todos os detalhes e inconsistências que estão presentes no mundo real, mas sim, descrições simplificadas da realidade. Modelos sem simplificação não são usuais, pois nesse caso é vantajoso observar o mundo real. Já a expressão **sistemas complexos**

é definida pelos autores como um sistema composto de muitas partes distribuídas e interativas. Esse campo da ciência surgiu nos anos 80 e é reportado grande quantidade de aplicações em variados campos desde a física à ecologia.

A ideia central para utilizar a Simulação Baseada em agentes é a de que muitos fenômenos podem ser modelados a partir da definição (WILENSKY; RAND, 2015):

- Os **agentes**;
- O **meio ambiente** onde tais agentes estão inseridos;
- A **descrição das interações** entre agentes-agentes e agentes-meio ambientes.

Por meio ambiente entende-se o panorama em que os agentes interagem, e os mesmos podem ser geométricos, baseados em redes ou em dados reais.

Define-se um agente como um elemento individual de uma simulação de computador. Os mesmos possuem **propriedades** (exemplo: cor, forma, capacidade da bateria de um drone), **estados** (exemplo: qual a carga da bateria de um drone, agente prevê que o bar vai estar vazio) e **comportamento** (agente tomou a decisão de ir ao *El Farol Bar*, o drone definiu não ir recarregar nesta rodada) (WILENSKY; RAND, 2015).

Outra definição para agentes é do autor Siebers et al. (2010), onde o mesmo define os agentes como objetos com atitudes.

Os autores Siebers et al. (2010) e Klugl e Bazzan (2012) citam alguns exemplos de requisitos para se utilizar a modelagem baseada em agentes:

- Quando o problema possui uma representação natural de entidades para atuarem como agentes;
- Os agentes têm relações com outros agentes, principalmente dinâmicas;
- Os agentes possuem aspectos espaciais ou geoespaciais com seu meio ambiente;
- Quando é importante que os agentes/população aprendam ou se adaptem;
- Quando é importante para que os agentes dos modelos que cooperem, conspirem ou formem organizações;
- Quando o passado não é um preditor do futuro;
- Quando é importante ocorrer escalabilidade;

- Quando as mudanças estruturais do processo são resultantes do modelo, em vez de ser uma entrada do mesmo;
- Sistemas que requerem a representação na heterogeneidade não apenas nos estados dos agentes mas também nas regras de comportamento;
- Sistemas nos quais não focam no equilíbrio estacionário, mas no fenômeno e nos comportamentos que levaram ao mesmo. Assim, a dinâmica transitória deve ser analisada.

Os autores Wilensky e Rand (2015) citam os oito principais usos dos modelos baseados por agentes:

1. Descrição;
2. Explicação;
3. Experimentação;
4. Prover fontes de analogias;
5. Comunicação/Educação;
6. Prover objetos focais ou peças centrais para o diálogo científico;
7. Experimentos minuciosos;
8. Predição.

Um outro fenômeno que caracteriza as simulações baseadas em agentes é a presença do fenômeno de emergência, em que os comportamentos individuais dos agentes resultam em comportamentos não esperados no nível macro.

Existe uma ampla variedade de ferramentas computacionais para o estudo de sistemas baseados em agentes. Neste trabalho, foi utilizado o *Netlogo*, ferramenta de código livre e disponível em <https://ccl.northwestern.edu/netlogo/>.

### **2.3 Modelo *El Farol Bar***

Nesta Seção discutem-se elementos que estão presentes na literatura que engloba o Problema *El Farol Bar*. É apresentado o artigo que introduziu o conceito do PEFB, também é apresentado a literatura com modelos subsequentes e finalmente as aplicações do PEFB.

### 2.3.1 Origem do Problema do *El Farol Bar*

O modelo El Farol, foi proposto por William Brian Arthur em 1994 com o intuito de demonstrar a limitação da racionalidade, onde as tomadas de decisões em certas situações ocorrem de forma indutiva e não dedutiva. Segundo Arthur, essa característica é inerente do ser humano, devido a sua maior facilidade na capacidade no reconhecimento de padrões ao invés de que propriamente a utilização de lógica dedutiva, fator que conferiu vantagem evolucionária no desenvolvimento do ser humano (ARTHUR, 1994).

Desta forma, o ser humano desenvolve hipóteses conforme suas observações, aplica tais hipóteses e pela observação dos resultados obtidos dessa aplicação pode ocorrer o fortalecimento ou enfraquecimento da eficácia na aplicação dessas hipóteses, removendo as ações menos efetivas e substituindo-as por novas estratégias.

Após apresentação do objetivo e ideia central do problema *El Farol Bar* segue a descrição de seu funcionamento: Na cidade de Santa Fé, nos Estados Unidos, existe um bar chamado El Farol, onde toda quinta feira ocorrem shows onde é tocado música Irlandesa; ao redor desse bar existe uma vizinhança com  $N$  pessoas ("agentes"), que gostam de música irlandesa e desejam definir, sem conluio, se irão ou não para o *El Farol Bar*. Como o espaço desse local é limitado, a noite só é agradável aos presentes se uma lotação  $L$  for menor que uma certa fração  $B$ , onde no trabalho original  $B = 60\%N$ . ou seja:

- Se  $L \geq B$  o ambiente (*El Farol Bar*) se torna desconfortável para o agente, devido lotação do bar;
- Se  $L < B$  o ambiente se torna confortável para o agente, pois o mesmo não está lotado.

No modelo original, não ocorre conluio entre os agentes, ou seja, os agentes não se comunicam entre si.

A única informação existente para a tomada de decisões dos agentes, é o histórico numérico da lotação do bar nas últimas  $d$  semanas.

Em relação aos preditores, responsáveis pela tomada de decisão da ida ou não ao bar, no modelo de Arthur (1994) é descrito que cada agente possui  $k$  preditores individualizados e a escolha final do valor predito por cada agente é realizada pelo preditor mais acurado, denominado preditor ativo.

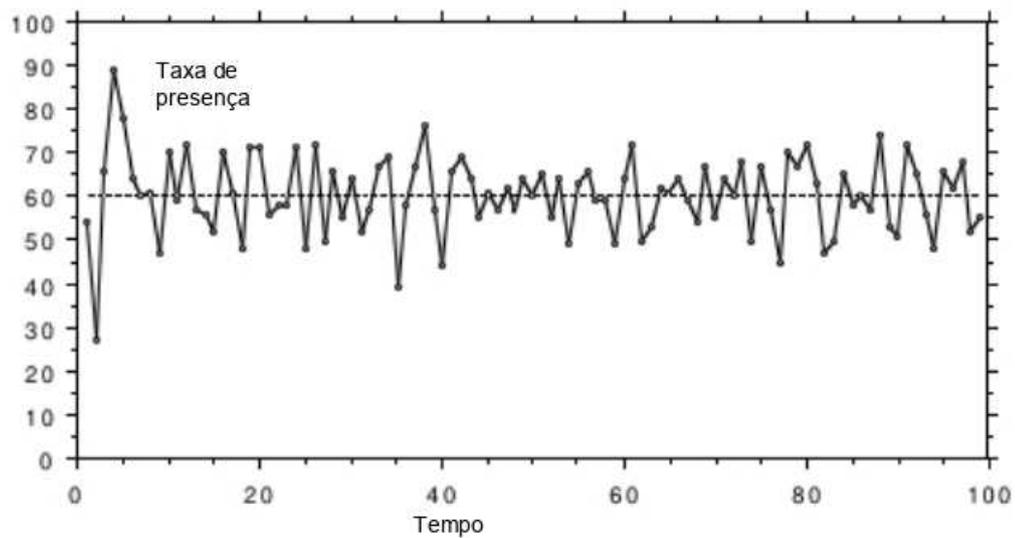


Figura 2.1: Histórico da lotação para 100 semanas, conforme Arthur (1994). Fonte: Adaptado de Arthur (1994).

Após a decisão dos agentes ser tomada (ir ou não ir ao bar), cada agente verifica novamente o histórico do valor de  $L$  das últimas  $d$  semanas e atualiza a acurácia dos preditores monitorados.

No artigo original, Arthur (1994) descreve alguns possíveis preditores para a utilização dos agentes, como:

- O mesmo da semana anterior;
- Um espelho em relação às últimas semanas;
- Valores fixos;
- Um valor aproximado da média das 4 rodadas anteriores;
- O mesmo que 2 semanas atrás;
- etc... .

Os resultados obtidos no artigo original, estão presentes na Figura 2.1. Em tal figura, é observado que a média da lotação converge sempre para  $B = 60\%N$ , onde os preditores ativos se auto-organizam num padrão de equilíbrio onde em média, 40% das previsões estão acima e 60% abaixo de  $B$ . Este equilíbrio é considerado um atrator natural para esse problema e tais probabilidades de 60/40, um equilíbrio de Nash para o PEFB.

Finalmente Arthur (1994), conclui que o PEFB é possível de ser classificado como um sistema complexo adaptativo (SCA) e várias possíveis aplicações (especulação do mercado de ações, negociações, jogo de póquer, precificação de oligopólios) são possíveis aplicações para o mesmo.

### 2.3.2 Revisão Bibliográfica e aplicações do Modelo El Farol na Literatura

Nesta Subseção é realizado um resumo de importante literatura relacionada com o Problema *El Farol Bar*.

Os autores Challet e Y.-C. Zhang (1997) propuseram uma aplicação do PEFB, simplificando o mesmo como um jogo binário, onde  $N$  agentes escolhem um dos lados e o lado que tiver a menor quantidade de agentes ganha o jogo. O nome desse jogo é chamado de "Jogo Minoritário" e assim como o PEFB, os agentes utilizam informações do histórico para a tomada de decisão e também devem se adaptar quando necessário. A maior diferença entre o modelo de PEFB e o jogo minoritário é que no primeiro, o equilíbrio  $B$  é determinado como 60% e no segundo 50%. Nesse experimento, é observado que a quantidade de memória destinada para a obtenção de estratégias possibilita um aumento na taxa de sucesso do jogo.

Observou-se queda da taxa de sucesso com o aumento do número de estratégias por agentes. Os autores definem que esse comportamento é devido a possibilitar aos agentes ficarem "confusos" com o aumento das estratégias para tomarem a decisão.

Outro resultado encontrado é pelo aumento do tempo de simulação, em que observou-se uma concentração na distribuição da taxa de sucesso, indicando que o ganho obtido pelas estratégias é igual quando o tempo de simulação tende ao infinito. Os autores também utilizaram como forma de aprendizado para a escolha das estratégias modelagem via algoritmo genético.

O autor Edmonds (1998) expande o modelo de Arthur (1994) com mais preditores e permitindo a comunicação entre os agentes, a utilização de algoritmos genéticos. A simulação realizada pelos autores, confirma os resultados de Arthur, onde os agentes trocam continuamente de estratégia de escolha de preditores para manter a média de  $B$  igual à 60% de presença.

Já os autores Bell e Sethares (1999) utilizam como analogia do PEFB para estudar a congestão ao acesso à Internet. Cita como exemplo o fato de quando tentamos acessar um

site e não ocorre congestionamento seria o mesmo de um agente visitar o bar e não estar lotado resultando em uma boa experiência. Os autores utilizaram um modelo adaptativo em que o número dos presentes raramente atingia o valor crítico de 60%. Também foi observada uma propriedade emergente em função do tipo de frequência da população ao bar (regulares e casuais). Outra observação foi que o aumento de informação disponível não resulta necessariamente em melhores resultados.

Cara, Pla e Guinea (1999) executaram uma análise de sensibilidade no modelo PEFB para o número de agentes, quantidade de memória disponíveis para a tomada de decisões dos agentes e o número de estratégias em um jogo minoritário. Também é estudado a variação das recompensas para os ganhadores e o desenvolvimento de um jogo majoritário, onde o agente prefere estar em um bar lotado.

Fogel, Chellapilla e Angeline (1999) propõe a utilização do PEFB utilizando um modelo autorregressivo, onde cada agente possui 10 modelos preditivos, e os termos de *lags* para cada semana retroativa varia de -1 a 1. Tal abordagem foi utilizada no modelo de Rand e Wilensky (2007). Os autores observam que o modelo PEFB pode ser descrito como uma cadeia de *Markov*, e realizaram uma análise estatística para demonstrar que o sistema não irá convergir para um equilíbrio.

Os autores Challet, Marsili e Y.-C. Zhang (2000) desenvolveram uma abordagem matemática visando modelar um jogo minoritário com os mecanismos do mercado financeiro real, por exemplo: diversificação de estratégia, *traders* que utilizam estratégias aleatórias, agentes que possuem informações ilegais e aumento da capacidade do processamento dos agentes. Os autores também introduzem um novo tipo de agente executando a função de produtor, resultando em uma simbiose entre os dois tipos de agentes (produtores x especuladores).

No artigo de Marsili, Challet e Zecchina (2000) foi realizado uma análise matemática, buscando uma solução analítica ao jogo minoritário, definindo-o e analisando o equilíbrio de Nash, incluindo agentes adaptativos.

Wolpert e Tumer (2001) Os autores aplicaram no PEFB um *framework* de função de melhoria de utilidade denominado *COIN (Colettive Inteligence)*. Os autores observaram que com a aplicação desse *framework* ocorreu um aumento dos valores de utilidade superior aos valores encontrados ao se utilizar algoritmo de aprendizado por reforço.

No artigo escrito por Franke (2003) é aplicado **aprendizado por reforço**, também chamado de estímulo-resposta) no PEFB, ao invés do processo de **aprendizado melhor resposta**. Segundo o autor, há algumas diferenças entre esses aprendizados:

- Os agentes não fazem uso de estatística passadas do nível de ocupação;
- No aprendizado por reforço, os agentes não formam expectativas explícitas;
- O comportamento dos agentes que utilizam o aprendizado por reforço é descrito na base da probabilidade de suas ações simples. O mesmo é modelado como um processo de atualizações dessas probabilidades, em que os agentes fazem uso de sua experiência pessoal.

Challet, Marsili e Ottino (2004) desenvolveu um formalismo matemático para o PEFB, utilizando técnicas de mecânica estatística. Considerou modelos com informações reais e aleatórias obtendo como resultados um diagrama de fase.

Luş et al. (2005) estudou o modelo e seu comportamento em relação à variação dos valores de limiar de conforto  $B$  do sistema, obtendo resultados em relação à média e variância das amostras.

Rand (2006) propõe utilizar o modelo PEFB como exemplo de uma forma de se integrar modelos de simulação baseada em agentes com técnicas de aprendizado de máquinas. A Figura 2.2 representa essa integração, mostrando o fluxo de informação entre as duas abordagens. O autor cita como exemplo de aprendizado de máquina o algoritmo genético.

Garofalo (2006) propôs uma implementação no Software *Netlogo* para o PEFB. São apresentadas três formas de avaliação do melhor preditor:

**Precisão absoluta:** nesta forma de avaliação, caso o valor do *attendance L* seja 55, caso sejam preditos dois valores distintos, como por exemplo 10 ou 55, ambos possuem o mesmo peso na tomada de decisão.

**Precisão relativa:** neste tipo, o cálculo do melhor preditor é feito pela diferença entre o valor do *attendance L* e o valor predito por cada preditor. No modelo desenvolvido nesta dissertação são utilizadas variações desse tipo de precisão.

**Precisão original:** é definido como o cálculo recorrente da precisão utilizando como peso uma variável com valores entre zero e um, calculando assim uma média ponderada dos valores obtidos nas semanas anteriores e o valor absoluto entre a última previsão do modelo e o valor mais recente do *attendance*.

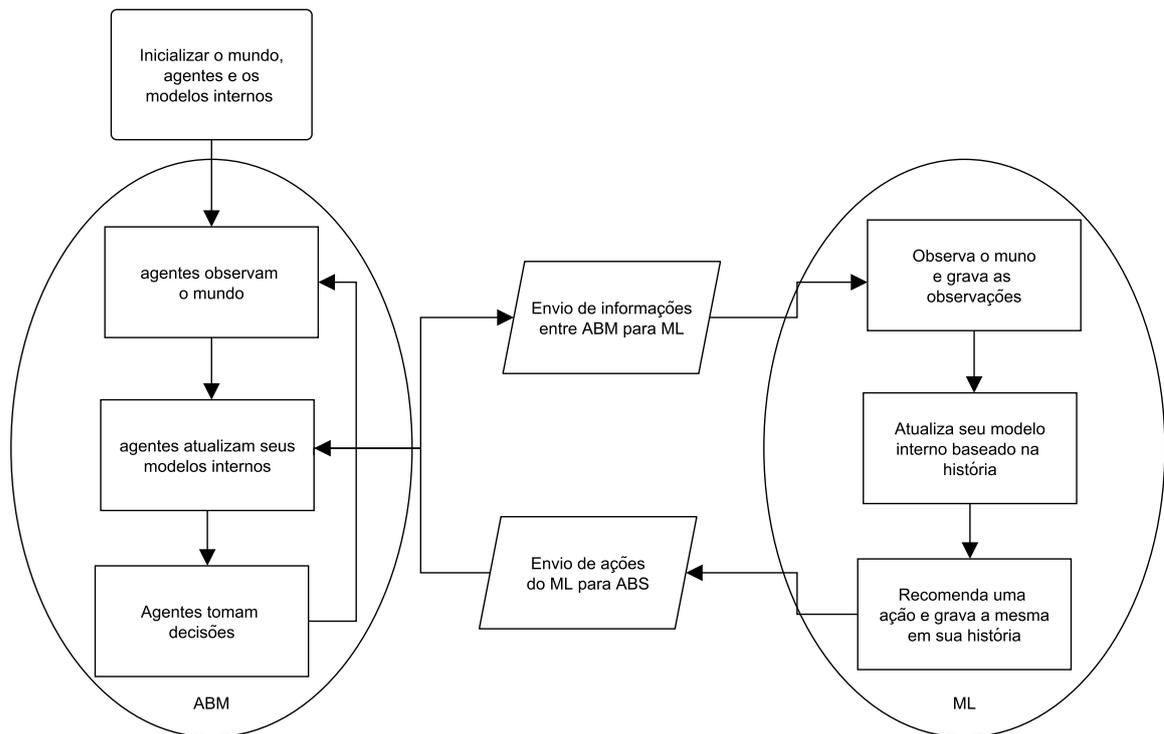


Figura 2.2: *Framework* proposto por Rand, integrando um modelo baseado por agentes com aprendizado por máquinas. Fonte: Adaptado de Rand (2006).

Em relação aos resultados, assim como em Arthur (1994) observou-se a presença do equilíbrio de Nash e que a média dos valores do *attendance* se aproximam do limiar de conforto.

O autor Papakonstantinou (2006) fez um estudo de caso onde considerou três bares na cidade de Santa Fé ao invés de apenas um. Os resultados da taxa de presença foram similares aos resultados de apenas um bar.

Whitehead (2008) modelou a aplicação de aprendizado por reforço no PEFB utilizando como base o modelo proposto por Erev e Roth (1998).

Observou convergência dos valores do *attendance* médio para o limiar de conforto, como na abordagem de Arthur (1994), mas diferem em relação à diversidade dos agentes que irão ao bar ao longo do tempo. Tal diferença é descrita pelo fato de que no aprendizado por reforço, as decisões tomadas pelos agentes são baseadas pelo valor da quantidade de frequentadores do bar e não pelos tipos de previsão utilizados pelos agentes.

Rand e Stonedahl (2009) Propuseram comparar o esforço computacional para a obtenção dos resultados para o PEFB em 4 abordagens:

- Agentes utilizando uma abordagem aleatória;

- Agentes utilizando a abordagem Neo-Clássica;
- Agentes com características do artigo de Arthur (1994);
- Agentes com características do artigo de Fogel, Chellapilla e Angeline (1999).

Os autores desenvolveram um modelo similar ao presente em Fogel, Chellapilla e Angeline (1999) (Autorregressão) e observou-se aumento na flutuação dos valores do *attendance* com o aumento da capacidade computacional, assim como uma oscilação não convergente em torno do valor médio.

Lustosa e Cajueiro (2010) aplicaram por analogia uma variação do jogo minoritário como um modelo para o mercado de leilão de veículos do Brasil. Nessa variação, os agentes participantes do jogo, possuem apenas o acesso à última informação de *attendance* para a tomada de decisão.

Sharif, Huynh e Vidal (2011) utilizaram o PEFB para modelar via analogia o gerenciamento de um conjunto de caminhões que necessitam ir para um terminal marinho para entrega e carregamento de contêiner, visando reduzir a quantidade de veículos em espera. O modelo de simulação foi baseado no trabalho de Garofalo (2006).

Szilagyi (2012) modelou o PEFB como um caso especial do jogo batalha dos sexos com N-agentes. O mesmo observou que a flutuação do valor do *attendance* em torno do valor do limiar, reduz-se ao aumentar os números de agentes.

Baccan e Macedo (2013) modelaram o PEFB com a abordagem cognitiva para a observação dos comportamentos dos agentes, incluindo emoções, como exemplo: felicidade, tristeza e surpresa na lógica dos comportamentos dos agentes.

S.-H. Chen e Gostoli (2015) buscaram estudar a relação de equidade no PEFB, modelando o mesmo via Autômato Celular em vez de um Sistema Adaptativo Complexo. Duas variações foram estudadas, sendo a primeira baseada na estrutura da interação entre os agentes e a segunda baseada na preferência pela equidade dos agentes (frequência do *attendance*). Já em outro artigo, S. H. Chen e Gostoli (2016), foi realizada uma análise de sensibilidade desse modelo, utilizando variações dos seguintes parâmetros: números de agentes, o tipo de preferência social dos agentes, limiares do *attendance* do bar, número de vizinhança da célula automata e a capacidade de memória dos agentes.

Ponsiglioni et al. (2015) analisaram quatro tipos de simulações baseadas em agentes pela implementação do PEFB no *Netlogo*. Os autores compararam resultados desses quatro modelos utilizando indicadores de equidade e também em relação à eficiência.

Chakraborti et al. (2015) estudou o PEFB e variantes como um problema de alocação de recursos via metodologia de estatística mecânica.

W. Zhang et al. (2015) aplicaram dois tipos de algoritmos de busca (busca ótima de vizinhança e busca global) em um modelo (onde os agentes estão ligados uns aos outros via rede) evolucionário do jogo minoritário e observou perda na *performance* do sistema ao aplicar esses algoritmos de busca.

Collins (2017) adaptou o PEFB com o intuito de incluir estratégia de formação de grupos entre os agentes utilizando teoria de jogos cooperativa.

Zabaleta e Arizmendi (2018) propuseram a aplicação de uma versão quântica no jogo minoritário, visando estudar o problema do espectro de alocação de redes de comunicação sem fio. Nesse artigo foi considerado um jogo com quatro jogadores. O resultado obtido depende do nível de expectativa dos agentes.

## 2.4 Analogias anteriores do PEFB

A partir dos dados presentes na Seção 2.3. pode-se compilar na Tabela 2.1 algumas aplicações do PEFB que já foram utilizadas em variados modelos. O modelo El Farol possui grande aplicação em modelos que envolvem congestionamento de recursos.

## 2.5 Técnicas de predição

Em relação aos métodos de predição e os tipos de aprendizagem por agentes que são utilizados em experimentos envolvendo subordinação humana, Duffy (2006) lista os seguintes tipos de agentes:

- Agentes Zero inteligência (modelos com baixa utilização de recursos computacionais);
- Modelos de comportamento baseado em reforço (modelos baseados em aprendizado por estímulo-resposta);

Tabela 2.1: Algumas analogias do PEFB utilizadas na literatura

Autor	Analogia	Descrição
Challet e Y.-C. Zhang (1997)	Jogo Minoritário	Os agentes devem escolher o lado com menor quantidade de agentes.
De Cara, Pla e Guinea (1999)	Jogo Majoritário	Os agentes devem escolher o lado com maior quantidade de agentes.
Bell e Sethares (1999)	Utilização do PEFB para problemas de congestionamento e de coordenação	Utilização de algoritmo adaptativo baseado em agentes.
Challet, Marsili e Y.-C. Zhang (2000)	Jogo Minoritário	Modelar alguns cenários de mercado com o Jogo Minoritário.
Sharif, Huynh e Vidal (2011)	Congestionamento de um terminal marinho (caminhões)	Utilização do <i>Netlogo</i> e estratégias descritas por Garofalo (2006).
Chakraborti et al. (2015)	Problema dos restaurantes de Calcutá	Nesse problema o número de escolhas pode ser igual ao número de agentes.
Zabaleta e Arizmendi (2018)	Jogo Majoritário	Abordagem quântica evolucionária para o jogo minoritário visando utilizar em uma rede de comunicação com escassos recursos.

- Comportamentos baseados em modelos genéticos/evolucionários (modelos que são controlados por um sistema classificatório ou critério de seleção controlado por toda a população).

Em relação aos métodos de predições para a utilização em simulação do Problema *El Farol*, os autores S.-H. Chen e Gostoli (2015) destacam dois tipos de aprendizados já utilizados na literatura para o PEFB:

- **Aprendizado de melhor resposta**, observado flutuações, às vezes severas em torno do limiar, mas é muito difícil atingir o estado estacionário onde a taxa de presença é igual a capacidade do bar;
- **Aprendizado de reforço**, nesse modelo de aprendizagem, a coordenação perfeita pode ser encontrada, sendo que a longo prazo ocorre convergência assintótica. Porém tal equilíbrio é caracterizado por segregação entre os agentes (alguns sempre frequentam o bar e outros nunca frequentam).

Nos modelos deste trabalho é utilizado o aprendizado de melhor resposta. No caso de agentes com vários preditores, a escolha do melhor preditor ocorre pela quantidade de erro existente ao prever o próximo valor do *attendance*. No caso de vários preditores por agentes, duas políticas distintas são utilizadas para a escolha do melhor preditor. Já no caso de apenas um preditor por agente, não ocorre seleção.

## 2.6 Preditores utilizados nos modelos

Neste trabalho foram definidos dois tipos de agentes, que são diferenciados pela capacidade computacional de seus preditores.

- Agentes CPX - Preditores com maior complexidade computacional. Tais preditores utilizam os valores anteriores do histórico do *attendance* para prever o novo valor;
- Agentes ZI - Preditores denominados Zero Inteligência. Nesse caso, não é predito valores utilizando o histórico do *attendance*, mas sim, valores aleatórios, contínuos ou detectores de ciclo (copiam valores cíclicos anteriores do histórico do *attendance*).

A seguir, segue descrição dos tipos de preditores que foram utilizados neste trabalho nos preditores Complexos (CPX), que efetuam cálculos matemáticos para a obtenção do valor de predição. Tais preditores são divididos em:

- Médias Móveis (MA);
- Média Exponencial (simples e avançados);
- Regressivos (Autorregressivos, ARMA e ARIMA);
- Modelos de Componentes Não Observados.

### 2.6.1 Médias Móveis (MA)

O modelo de média móvel consiste no cálculo dos valores médios em uma janela de períodos consecutivos, gerando uma série de valores médios. Uma média móvel com uma janela de comprimento  $w$  significa obter a média no conjunto de  $w$  valores consecutivos. O valor de  $w$  é determinado pelo usuário. De forma geral, existem dois tipos de média móvel: média móvel centrada e média móvel à direita, sendo a primeira utilizada para visualizar tendências, pois a

mesma pode suprimir sazonalidade e o ruído, deixando a tendência mais visível e a segunda para previsões. A diferença entre ambas é o posicionamento da janela de valores na série temporal (SHMUELI; C. LICHTENDAHL JR, 2018).

Neste texto será descrita a fórmula para a média móvel,  $FMM_{t+k}$ , que representa a previsão dos valores da média móvel  $k = 1, 2, 3$  passos para frente dos valores de *attendance*  $L$ .

$$FMM_{(t+k)} = (L_t + L_{(t-1)} + \dots + L_{(t-w+1)})/w \quad (2.1)$$

Computacionalmente, os valores foram obtidos utilizando a biblioteca *Python Pandas*.

## 2.6.2 Modelos Exponenciais

### Modelos Exponenciais Simples

Os modelos de previsão por suavização exponencial têm funcionamento similar à média móvel, mas o valor predito é obtido pela média ponderada de todos os valores anteriores. O peso  $\alpha$  decresce de forma exponencial em relação aos valores anteriores, onde:  $0 < \alpha \leq 1$  (SHMUELI; C. LICHTENDAHL JR, 2018).

Valores de  $\alpha$  próximo de zero indicam aprendizado rápido, ou seja, os valores mais recentes das observações possuem mais influência, enquanto valores menores de  $\alpha$  valorizam observações anteriores.

$$FME_{(t+k)} = \alpha * L_t + \alpha(1 - \alpha) * L_{t-1} + \alpha(1 - \alpha)^2 * L_{t-2} + \dots \quad (2.2)$$

A biblioteca *Python Pandas* possibilita a implementação desses modelos, sendo alguns parâmetros como o centro de massa (*comEx*) e meia vida (*hlEx*):

$$\alpha = \frac{1}{(1 + comEx)} \quad (2.3)$$

sendo  $comEx \geq 0$

$$\alpha = 1 - \exp^{0.5/hlEx} \quad (2.4)$$

## Modelos Exponenciais Avançados

Quando uma série temporal possui tendência ou sazonalidade, os métodos de média móvel e exponenciação simples não são indicados, necessitando retirar estes componentes como por exemplo, via diferenciação ou utilizando outra versão da suavização exponencial, que captura tendência e/ou sazonalidade (SHMUELI; C. LICHTENDAHL JR, 2018).

Se a série contém mais de uma tendência, pode ser utilizado suavização exponencial dupla, também chamada de modelo de tendência linear de Holt (SHMUELI; C. LICHTENDAHL JR).

Os tipos de tendência podem ser aditivas ou multiplicativas, mudando a forma como o algoritmo efetua o cálculo da previsão baseada nas observações.

Já no caso da ocorrência de tendência e sazonalidade, se utiliza uma extensão do modelo de tendência linear de *Holt's* chamado de método de suavização exponencial de *Holt-Winter's* e também modelos com múltipla sazonalidade, chamado de método de dupla sazonalidade de *Holt-Winter's*.

As bibliotecas *Pandas* e *Stats* foram utilizadas para os cálculos dos modelos exponenciais avançados.

### 2.6.3 Modelos Regressivos

#### Modelos Autorregressivos

Modelos autorregressivos (AR(p)) são similares aos modelos de regressão linear, exceto que os preditores são valores anteriores da série. Por exemplo, um modelo AR de ordem 2 (AR(2)) pode ser escrito da seguinte forma:

$$FAR_t = \beta_0 + \beta_1 FAR_{t-1} + \beta_2 FAR_{t-2} + \varepsilon_t \quad (2.5)$$

Estimativas com estes modelos é como ajustar um modelo com regressão linear em que as séries atuam como a saída  $FAR_t$  e as séries anteriores ( $FAR_{t-1}$  e  $FAR_{t-2}$ ) atuam como preditores (SHMUELI; C. LICHTENDAHL JR).

#### Modelos ARIMA

Os modelos Autorregressivos (AR) Integrados (I) com média móvel (MA), são modelos que diretamente contemplam a autocorrelação dos valores da série com a autocorrelação dos erros da previsão (SHMUELI; C. LICHTENDAHL JR, 2018). Uma forma mais genérica da Eq. 2.5

representa um modelo AR(p), que captura as autocorrelações dos valores da série nos lags 1, 2, ..., p.

$$FAR_t = \beta_0 + \beta_1 FAR_{t-1} + \beta_2 FAR_{t-2} + \dots + \beta_p FAR_{t-p} + \varepsilon_t \quad (2.6)$$

Para adicionar os termos de autocorrelação para os erros da previsão, utilizando média móvel, até o lag q resulta em um modelo ARMA(p,q) (SHMUELI; C. LICHTENDAHL JR):

$$FAR_t = \beta_0 + \beta_1 FAR_{t-1} + \beta_2 FAR_{t-2} + \dots + \beta_p FAR_{t-p} \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.7)$$

Modelos AR e ARMA podem ser apenas ajustados para dados sem tendência e sazonalidade, assim um modelo ARIMA incorpora uma operação preliminar de diferenciação, chamada de "I"(Integração), para a remoção de tendência. A ordem dessa diferenciação é determinada pelo parâmetro d, sendo assim podemos caracterizar este modelo como ARIMA(p, d, q), sendo que os softwares dependem dessa informação (p, d, q) para estimar os valores de  $\beta$  e de  $\theta$  (SHMUELI; C. LICHTENDAHL JR, 2018).

Computacionalmente, foi utilizada a biblioteca em *Python Stats* (SEABOLD; PERKTOLD) para os cálculos dos modelos de Autorregressivos.

### Modelos de Componentes Não Observados

Os modelos estruturados uni-variados de séries temporais são modelos em que componentes de tendência, sazonalidade, erro e outros elementos relevantes são modelados de forma explícita.

Durbin e Koopman (2012) explica e modela a formação dos componentes de tendência, sazonalidade e ciclicidade para a utilização na modelagem de séries temporais, além de explanar o desenvolvimento do passeio aleatório, em que tal modelo contém um componente e variáveis independentes, identicamente distribuídas aleatoriamente com média 0 e variância  $\sigma_n^2$ .

Os modelos de componentes não observados podem ser considerados como um modelo de regressão múltipla com os coeficientes variando em função do tempo. Isto é baseado nos princípios:

- É útil ver as séries temporais sendo decompostas em componentes de tendência, sazonalidade e cíclicos;
- Modelos de séries temporais que utilizam os mesmos pesos para observações próximas e distantes não são muitos úteis (FOMBY).

Uma forma de se descrever um modelo de componentes não observados pode ser observado na Equação 2.8

$$y_t = \mu_t + \gamma_t + \psi_t + r_t + \sum_{i=1}^p \phi_i y_{t-1} + \sum_{j=1}^m \beta_j X_{jt} + \epsilon_t \quad (2.8)$$

onde:

$y_t$  - Série temporal à ser modelada e prevista.

$\mu_t$  - Componente relacionado à tendência.

$\gamma_t$  - Componente relacionado à sazonalidade.

$\psi_t$  - Componente relacionado à ciclicidade.

$r_t$  - Componente autoregressivo.

$\epsilon_t$  - Componente irregular.

Todos os componentes acima são assumidos como não observados e a série temporal deve ser estimada em  $y_t$  e em  $x_{jt}$ . O componente  $\sum_{i=1}^p \phi_i y_{t-1}$  representa os termos autorregressivo e o termo  $\sum_{j=1}^m \beta_j X_{jt}$  termos regressivos explanatórios, que representam o momento da série temporal e estão relacionados com as observações anteriores e a última representação de fatores casuais que supostamente afetam essa série temporal (FOMBY, 2008).

#### 2.6.4 Preditores Zero Inteligência

Em relação aos preditores que compõem os agentes ZI, os mesmos foram escolhidos de forma arbitrária, baseada nos artigos dos autores Arthur (1994) e Garofalo (2006).

##### Detectores de Ciclo

Tais preditores determinam seus valores previstos pela cópia de um dos  $m$  valores anteriores das quantidades de histórico *attendance*  $L$ . Por exemplo, caso determinado, o agente vai sempre utilizar como valor preditor o último valor do histórico. Também são utilizados Detectores de

Ciclos Invertidos, onde em vez de se utilizar os últimos valores mais atuais do histórico, são utilizados os valores mais antigos desse vetor.

### **Aleatório**

Nesse tipo de preditor, o valor predito é gerado pelo algoritmo interno do *Netlogo* com valores entre 0 ao valor total de agentes.

### **Moeda**

Distribuição randômica com um percentual igual para ida e não ida ao bar. Ou seja, neste caso, o agente simula o comportamento de cada ciclo ao jogar uma moeda resultando em cara ou coroa.

### **Constantes**

Nesses preditores, os valores obtidos são sempre acima ou abaixo do valor do limiar, sendo dessa forma, os agentes sempre não vão para o bar, já que os mesmos são sempre constantes.

## **2.7 Proposta de Aplicação do Modelo El Farol para Simulação de enxames de Drones**

O conceito de enxame pode ser definido como atividades coletivas apresentadas por um grupo de pessoas ou animais agregando e formando um comportamento natural (ABIDIN; ARSHAD; NGAH, 2015).

Na literatura são encontradas várias abordagens para simular enxames de drones, como otimização de partículas de enxames, otimização por colônias de formigas (RYAN MCCUNE; MADEY, 2013), competição coletiva (MANRIQUE; D. D. JOHNSON; N. F. JOHNSON, 2017) e modelagem por colmeia de abelhas (KARABOGA; AKAY, 2009) e (VISERAS et al., 2019).

Já em relação às aplicações dos drones são observados vários usos desses dispositivos como:

- Resposta a desastre (HORIO et al., 2019);
- Entrega de produtos (ZORICAK, 2013);

- Segurança, pesquisa, monitoramento, vigilância, bem estar, mapeamento ambiental, busca e resgate (TAHIR et al., 2019);
- Tarefas de visualização em tempo real (TOGOOTOGTOKH et al., 2020);
- Restaurar comunicação celular após um furacão em Porto Rico (MAZUR; WIŚNIEWSKI, 2018);
- Cinegrafistas aéreos (CARABALLO et al., 2020).

Este trabalho busca o desenvolvimento de uma analogia para simular o carregamento/recarregamento de enxames de drones, em formação de Rede *Ad Hoc* de voo (FANET), possibilitando o contínuo funcionamento, simulando várias atividades como o carregamento de suas baterias e sua rotina de trabalho.

Uma das limitações do uso de drones como enxame é relacionada com a autonomia de suas baterias, reduzindo seu tempo de serviço. Uma das formas de melhorar essa autonomia seria o avanço das tecnologias das baterias. Já outra abordagem é melhorar a coordenação do processo de recarga, desta forma possibilitando que os drones recarreguem ou sejam substituídos para executar suas funções. Alguns autores já trabalharam com essa abordagem como os descritos a seguir:

Tahir et al. (2019) realizou um levantamento sobre a pesquisa acadêmica existente relativo à tecnologia dos enxames de drones e descreveu alguns resultados. Por exemplo, a classificação dos drones em quatro tipos: asas fixas, asas fixas híbrido, rotor simples e multi-rotor. Ele também descreveu formas de coordenação da comunicação entre os drones, começando pelo controle no chão, drones líderes e drones liderados. Em relação à questão da autonomia de uma formação de um enxame de drones, ele cita duas possíveis formas: a troca rápida de baterias e as estações terrestres de recarga autônomas. Em relação ao segundo tipo, ele cita que o contato entre os drones e o carregador é muito importante.

Zoricak (2013) apresentou um *framework* em *Python* para o carregamento automatizado de drones. Para a questão rastreamento visual, ele utiliza um modulo de sensor comercial (conhecido como *Microsoft Kinect*).

Secretary et al. (2018) Descreve que a conectividade e a autonomia são duas importantes características para o correto funcionamento de enxames de drones. O mesmo cita as vantagens operacionais e as capacidades potenciais do uso dos drones no campo de batalha.

Os autores Boggio-Dandry e Soyata (2018), em seu artigo apresentam uma abordagem para o contínuo fornecimento de energia para enxames de drones, buscando descobrir o número mínimo de drones necessários para que esse ciclo seja contínuo. Os autores utilizaram dados reais de drones comerciais e utilizaram características próprias do correto funcionamento de carga das baterias para a realização dos experimentos de simulação. Os autores propõem que cada drone esteja em um dos 7 estados conforme a Fig. 2.3:

- **A - Pronto** - Drone carregado e não operando. Todo drone se encontra nesse estágio no tempo inicial e durante a simulação muda de estado quando um drone em voo necessite de uma substituição;
- **B - Voando em enxame** - Drone em formação de voo. O drone continuará voando até que a bateria atinja seu limite crítico. Apenas drones nesse estado executam ações para que foram propostas como capturar áudio e vídeo. Um drone continuará nesse estado até que o chamem para sua substituição;
- **C - Voando em enxame e aguardando ser repostado** - Quando um drone está voando em formação e atinge um limiar da bateria crítico (30% da bateria remanescente mais a energia para retornar ao carregador) ele solicita para ser substituído e entra nesse estado. Ele continuará voando em formação com esse estado até ser autorizado para carregar suas baterias;
- **D - Voando para o enxame** - Quando um drone necessita ser substituído, um drone que esteja no estado pronto é autorizado para se encontrar com o enxame, substituindo o estado de pronto para voando para o enxame;
- **E - Voando para o carregador** - Quando um drone que precisa ser carregado é liberado do enxame, o mesmo entra nesse estado até chegar à estação de carregamento;
- **F - Na fila de abastecimento** - Após o drone chegar à estação de carregamento e tiver que aguardar para ser carregado, o mesmo entra nesse estado, enquanto não iniciar seu abastecimento;
- **G - Carregando** - Quando um carregador está disponível e o drone entra nesse estado. O mesmo irá permanecer nesse estado até a bateria atingir o nível total de carregamento e entrar no estado **Pronto**.

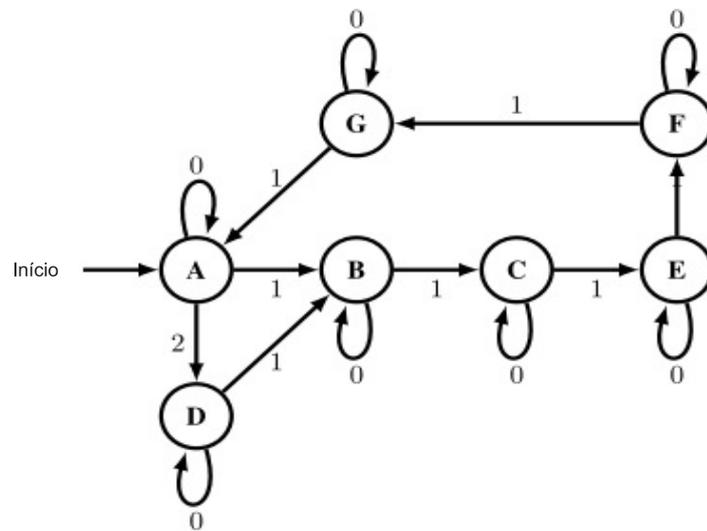


Figura 2.3: Estados finitos para um Drones conforme proposta de Boggio-Dandry e Soyata (2018). Fonte: Adaptado de Boggio-Dandry e Soyata (2018).

Estes estados serão utilizados neste trabalho para a modelagem da analogia da simulação de recarga do enxame de drones.

# Capítulo 3

## Desenvolvimento

### 3.1 Metodologia

Esta Seção tem como objetivo situar o trabalho em relação à sua metodologia e descrever os procedimentos utilizados para a obtenção dos resultados.

Segundo metodologia presente em Provdanov e Freitas (2013) pode-se classificar este trabalho quanto à sua natureza como uma pesquisa **aplicada**, pois o conhecimento gerado é utilizado para uma aplicação prática, que é a busca de uma solução para um problema específico (o desenvolvimento de uma analogia para a coordenação do processo de recargas de baterias de um enxame de drones).

Quanto aos objetivos da pesquisa, podemos classificar este trabalho como uma **pesquisa explicativa**, pois sua forma é a manipulação e controle das variáveis, buscando a identificação dos fatores que determinam ou contribuem para a ocorrência dos fenômenos, que neste trabalho é a análise do desempenho dos preditores, via experimentos, e sua interação junto com os agentes no modelo El Farol, comparando os resultados obtidos junto com a literatura vigente.

Em relação aos procedimentos técnicos é observado a utilização de **pesquisa bibliográfica** (da literatura vigente em relação ao sistema) e **experimental** pela aplicação das técnicas de predição no modelo El Farol.

```
to-report MEDIAMOVEL2
  (py:run
    "mem = mem"
    "attMV = np.array(attendance2)"
    "att1 = pd.DataFrame(data=attMV)"
    "att2 = att1.rolling(2).mean()"
    "att3 = np.float64(att2.loc[mem-1])"
  )
  set predicao py:runresult "att3"
  report predicao
end
```

Figura 3.1: Integração código *Python* e *Netlogo*

## 3.2 Modelo Computacional

Em relação à abordagem computacional deste trabalho, foi utilizado como base, o modelo criado por Rand (2006), onde o ambiente de simulação ocorre dentro de um simulador que permite a simulação baseada em agentes (*Netlogo*), mas neste trabalho alguns procedimentos (cálculos dos valores preditos por exemplo) são calculado pelo *Python*. Esta integração do *NetLogo* com o *Python* é realizada por uma extensão do *Netlogo* chamada *Python-Extention* (HEAD, 2017) e a mesma permite a utilização de código *Python* dentro do ambiente de programação do *Netlogo*.

Um exemplo desta integração pode ser observado na Figura 3.1, onde é possível observar neste exemplo do código, em vermelho, código em *Python*, onde o mesmo recebe dados do *Netlogo*, processa e retorna valores para que sejam utilizados pelo *Netlogo*.

Na Figura 3.2 é possível observar o ambiente gráfico onde ocorre a visualização dos resultados da simulação e a interação entre os agentes, o bar e a vizinhança, pela alteração de seus parâmetros.

A Figura 3.3 (a) apresenta as regiões delimitadoras da simulação, onde a área verde representa a vizinhança onde os agentes estão alocados e a região azul, o próprio *El Farol Bar*. Em relação aos agentes, nesta simulação eles foram divididos em dois tipos de categorias, com o intuito de personalizar o seu comportamento.

### 3.2.1 Agentes

Os dois tipos de agentes utilizados neste trabalho são descritos a seguir:

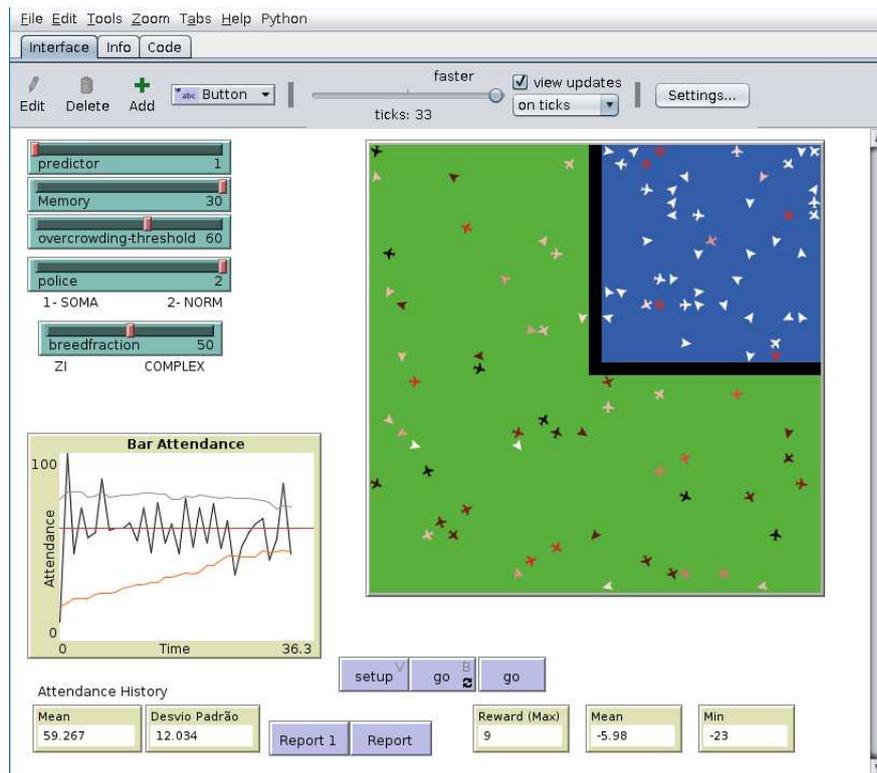


Figura 3.2: Tela do Ambiente de Simulação

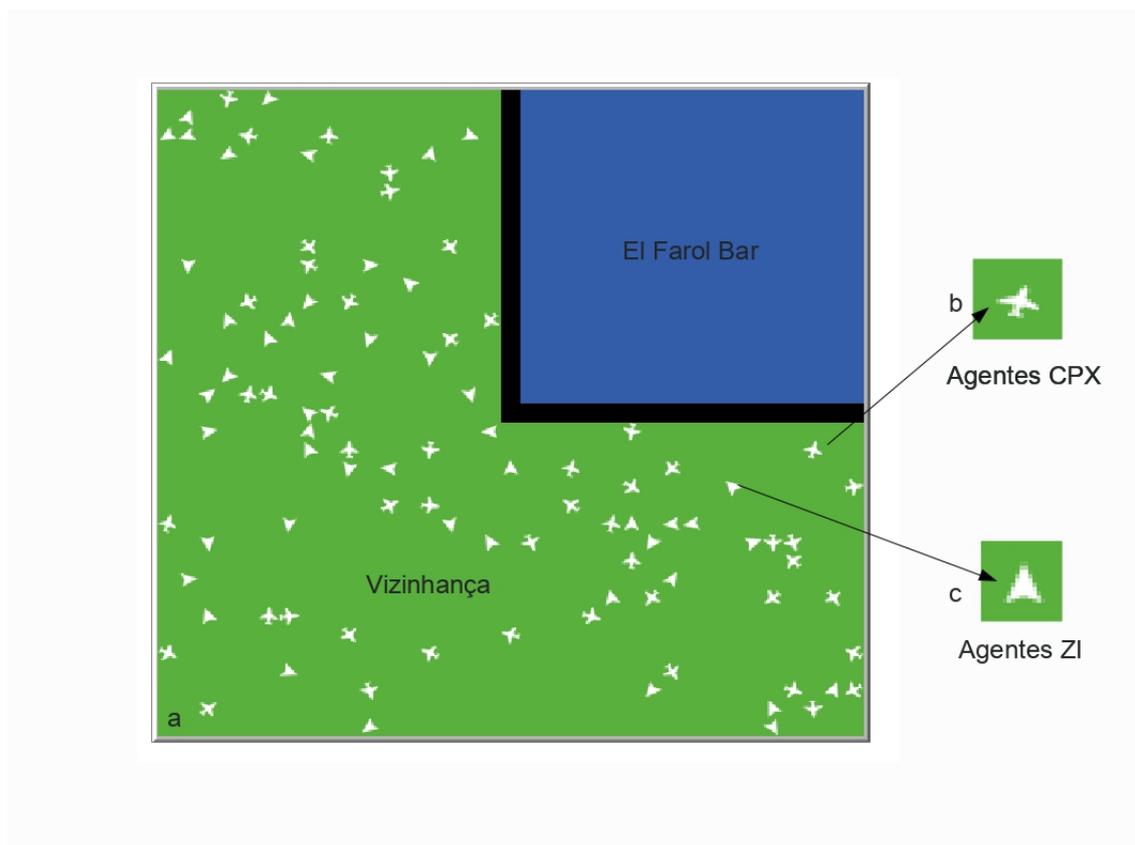


Figura 3.3: Representação gráfica do *El Farol Bar* e tipos de agentes

- Agentes Complexos (CPX), onde os agentes utilizam preditores matemáticos (exemplo: média móvel, média exponencial, autorregressivos, etc.) para a tomada de decisões. Sua representação gráfica está presente na Figura 3.3 (b);
- Agentes Zero Inteligência (ZI), esses agentes utilizam preditores que possuem baixo poder computacional, como por exemplo: valores randômicos, valores fixos, entre outros. Sua representação gráfica está presente na Figura 3.3 (c).

Os preditores são sorteados de forma aleatória no início de cada simulação, dependendo do valor  $k$  determinado pelo usuário. Para simulações com valores de  $k$  maiores do que 1, é feito um novo sorteio (até 6 vezes) dos preditores repetidos para evitar que os mesmos estejam repetidos em cada agente.

Os preditores CPX e ZI e seus parâmetros estão descritos na Tabela 3.1:

Os 29 preditores descritos na Tabela 3.1 podem ser classificados em quatro tipos:

- Estimadores: Usando os últimos valores do *attendance*, calcula e retorna uma estimativa do estado futuro;
- Aleatório: retorna valores aleatórios;
- Constante: Retorna um valor constante (um valor com incremento positivo ou negativo em relação ao limiar);
- Mímico: Copia alguns valores do histórico do *attendance*.

As escolhas desses preditores e seus parâmetros, para a realização dos experimentos, foram realizadas de forma arbitrária, baseados em dados da literatura do problema *El Farol*. Observando a Figura 3.2 no lado direito estão presentes controles deslizantes horizontais, que são utilizados para alterar os parâmetros iniciais da simulação e são descritos na Tabela 3.2.

No lado esquerdo inferior da Figura 3.2, é observado o gráfico *Bar Attendance* onde é possível acompanhar em tempo real a evolução do somatório  $L$  (também denominada *Attendance*) dos agentes que decidiram ir ao bar em cada ciclo da simulação (linha preta). O termo *Attendance* é o histórico, ou melhor, a série temporal da quantidade de pessoas que foram ao bar.

A linha vermelha, o Limiar  $B$  de  $n$  agentes é o valor de conforto. As linhas cinza e laranja são os valores do desvio padrão de  $L$  naquele momento. É possível obter um controle numérico

Tabela 3.1: Descrição dos Parâmetros dos preditores

#	Tipo	Nome	Classificação	Descrição	Parâmetros
1	CPX	Médiamovel2	Estimadores	Média Móvel 1	Janela dos 2 últimos valores do <i>attendance</i>
2	CPX	Médiamovel4	Estimadores	Média Móvel 2	Janela dos 4 últimos valores do <i>attendance</i>
3	CPX	Médiamovellen	Estimadores	Média Móvel 3	Janela m dos valores do <i>attendance</i>
4	CPX	EWM05	Estimadores	Média Exponencial 1	Janela m elementos e com valor de $\alpha = 0,5$
5	CPX	EWM025	Estimadores	Média Exponencial 2	Janela m elementos e com valor de $\alpha = 0,25$
6	CPX	EWM075	Estimadores	Média Exponencial 3	Janela m elementos e com valor de $\alpha = 0,75$
7	CPX	EWMhalf3	Estimadores	Média Exponencial 4	Janela m elementos e com valor de meia vida = 3
8	CPX	EWMhalf1	Estimadores	Média Exponencial 5	Janela m elementos e com valor de meia vida = 1
9	CPX	EWMhalf5	Estimadores	Média Exponencial 6	Janela m elementos e com valor de meia vida = 5
10	CPX	SES	Estimadores	Predição com suavização exponencial	Janela m elementos e parâmetros definidos pelo próprio algoritmo.
11	CPX	Holt	Estimadores	Predição <i>Holt</i> & <i>Winters</i>	Janela m elementos e $\alpha = 0,5$ e $\phi = 0,03$ (amortecimento da tendência)
12	CPX	Expsmdan	Estimadores	Predição <i>Holt</i> & <i>Winters</i> 2	Janela m elementos, tendência aditiva, sem componente de sazonalidade e o componente de amortecimento da tendência
13	CPX	AR	Estimadores	Predição Autorregressivo	Janela m elementos e $lag = 3$
14	CPX	ARMA10	Estimadores	Predição ARMA	Janela m elementos, com $ARMA(p, q) = ARMA(1, 0)$
15	CPX	ARIMA001	Estimadores	Predição ARIMA 1	Janela m elementos, com $ARIMA(p, d, q) = ARMA(0, 0, 1)$
16	CPX	ARIMA101	Estimadores	Predição ARIMA 2	Janela m elementos, com $ARIMA(p, d, q) = ARMA(1, 0, 1)$
17	CPX	UNOBCOMP	Estimadores	Filtro componentes não observados 1	Janela m elementos, nível = verdadeiro, tendência = falsa, comportamento cíclico = verdadeiro e comportamento irregular = verdadeiro
18	CPX	UNOBCOMP2	Aleatório	Filtro componentes não observados 2	Janela m elementos, considerando nível = caminhada aleatória, comportamento irregular = verdadeiro
19	CPX	UNOBCOMP3	Estimadores	Filtro componentes não observados 3	Janela m elementos, nível = verdadeiro, tendência = falsa, nível estocástico = verdadeiro, autorregressivo e tendência estocástica = falso
20	ZI	Cicledetector_1	Mímico	Detector de ciclo 1	Valor anterior do <i>attendance</i> ( $m = 1$ )
21	ZI	Cicledetector_2	Mímico	Detector de ciclo 2	Penúltimo valor do <i>attendance</i> ( $m = 2$ )
22	ZI	Cicledetector_3	Mímico	Detector de ciclo 3	Antepenúltimo valor do <i>attendance</i> ( $m = 3$ )
23	ZI	Cicledetectorinv_1	Mímico	Detector de ciclo invertido 1	Valor $m$ do <i>attendance</i>
24	ZI	Cicledetectorinv_2	Mímico	Detector de ciclo invertido 2	Valor $m - 1$ do <i>attendance</i>
25	ZI	Cicledetectorinv_3	Mímico	Detector de ciclo invertido 2	Valor $m - 1$ do <i>attendance</i>
26	ZI	RRandom	Aleatório	Valores aleatórios	Valor aleatório inteiro de 1 à 100
27	ZI	Coin	Aleatório	Cara ou coroa	Simula o jogar de uma moeda (50% cada lado)
28	ZI	Constanteup	Constante	Valor constante superior à B	Valor constante acima do limiar (agente nunca vai)
29	ZI	Constantedown	Constante	Valor constante inferior à B	Valor constante abaixo do limiar (agente sempre vai)

da média e do desvio padrão em tempo real de  $L$  nas janelas (*Mean* e Desvio Padrão) abaixo do gráfico. Na região central inferior da Figura 3.2 pode-se observar três janelas que contêm informações relativas aos valores máximo, médio e mínimo do indicador *Reward R*. O intuito desse indicador é comparar a taxa de acerto de cada agente, conforme sua decisão. A Tabela 3.3 demonstra a forma como esse indicador é calculado de maneira recursiva em cada ciclo da simulação.

Tabela 3.2: Parâmetros da simulação

Nome	Descrição	Limites	Unidades
<i>Predictor</i>	quantidade de $k$ preditores disponíveis para os agentes	1 a 6	preditores por agentes
<i>Memory</i>	Quantidade de informação disponível ( $m$ semanas anteriores) que os preditores dos agentes possuem para tomada de decisão	10 a 30	Semanas
<i>Overcrowding-Threshold</i>	Limiar $B$ de lotação do Bar	10 a 90	% ocupação do bar
<i>Police</i>	Políticas de tomada de decisão em que agentes com vários preditores utilizam para escolher o melhor preditor	Passo a passo, Somatório e Soma de pesos	
<i>Breedfraction</i>	Controle da constituição dos tipos de agentes (ZI e CPX) que participaram da simulação	100 % ZI a 100 % CPX	% dos tipos de agentes

Tabela 3.3: Tabela de recompensas "R" para ações dos agentes

Ação Agente	Bar Vazio	Bar Cheio
Não ir ao bar	-1	+1
Ir ao bar	+1	-1

As recompensas foram definidas baseadas no fato de que caso o agente escolha não ir ao bar, e o bar estiver vazio, ele perdeu a oportunidade de estar presente no bar (o preditor tomou a decisão errada), caso o agente escolha não ir ao bar e o bar encher, significa que ele escolheu a decisão correta. A mesma lógica funciona de forma inversa para o caso de o agente decidir ir ao bar.

### 3.2.2 Tomada de decisão pelos agentes

Conforme definição presente em Franke (2003), a abordagem utilizada nesta simulação é similar à abordagem de Arthur (1994), desta forma classificando o processo de aprendizado como **melhor resposta**.

Cada agente  $n$  necessita tomar a seguinte decisão binária em cada ciclo  $t$  :

- Se  $p(t) > B$ , o agente não deve ir ao bar;
- Se  $p(t) \leq B$ , o agente deve ir ao bar.

O cálculo de  $p(t)$  está relacionado com os tipos de preditores, descritos na Tabela 3.1 que cada tipo de agente possui e também pelas políticas que norteiam a escolha do melhor preditor.

Como descrito na Tabela 3.2 são utilizadas nesta simulação, três tipos de políticas para a escolha do melhor preditor em cada ciclo de simulação. A escolha desses tipos de políticas para serem utilizadas nesta simulação foi realizada de forma arbitrária, a partir de informações obtidas na literatura. As políticas de escolha para o melhor preditor são:

1. Uso de apenas um preditor por agente (sem decisão);
2. Melhor preditor pelo somatório da diferença;
3. Melhor preditor pela soma de pesos da diferença.

### 3.2.3 Uso de apenas um preditor por agente

Nesta política, não ocorre a escolha do melhor preditor, já que se considera apenas um preditor por agente. Ou seja, cada agente utiliza apenas um preditor previamente sorteado no começo de cada simulação.

### 3.2.4 Melhor preditor pelo somatório das diferenças

Nesta política é calculado o valor absoluto da subtração entre os valores preditos e o valor do histórico de forma recursiva. O erro relativo é definido como a diferença que cada agente  $n$ , executa em cada um dos  $k$  preditores no ciclo  $t$  entre o valor do *attendance* no ciclo anterior  $t-1$  ( $L_{(t-1)}$ ) e o valor das predições encontradas no ciclo anterior  $p_{(t-1)}$ . Esse cálculo é realizado de forma recursiva durante toda a simulação. Considerando  $SomaErrel_{n,k,0} = 0$ , o cálculo do somatório do erro absoluto, por ciclo de simulação, ocorre de maneira recursiva:

$$SomaErrel_{n,k,t} = SomaErrel_{n,k,t-2} + |L_{t-1} - p_{t-1}| \quad (3.1)$$

Nesta política, o agente escolhe como valor  $p_t$  o valor calculado pelo preditor que tenha o somatório do menor erro relativo em cada ciclo de simulação.

Por exemplo: Considerando um agente  $n$  que possua dois preditores  $k = 1$  e  $k = 2$  e que tenham acesso à uma memória  $m = 1$  (uma semana) e assim calcule os seguintes valores  $p_{(k=1,t-1)} = 15$  e  $p_{(k=2,t-1)} = 28$  e o valor do *Attendance* anterior  $L_{(t-1)} = 20$ :

$$\begin{aligned} SomaErrel_{n,1,t-1} &= SomaErrel_{n,2,t-1} = 0 \\ SomaErrel_{n,1,t} &= 0 + |20 - 15| = 5 \end{aligned}$$

$$SomaErrel_{n,2,t} = 0 + |20 - 28| = 8$$

$$Errel_{n,1,t} < Errel_{n,2,t}$$

Sendo assim neste primeiro ciclo, o preditor  $k = 1$  será o escolhido. Considerando agora um próximo ciclo ( $t + 1$ ), onde  $L_t = 30$ ,  $p_{(k=1,t)} = 40$  e  $p_{(k=2,t)} = 27$ :

$$SomaErrel_{n,1,t+1} = 5 + |30 - 40| = 15$$

$$SomaErrel_{n,2,t+1} = 8 + |30 - 27| = 11$$

$$Errel_{n,1,t+1} > Errel_{n,2,t+1}$$

Onde neste ciclo ( $t + 1$ ), o preditor  $k = 2$  será o escolhido.

Nesse caso, a escolha do agente a ser usado beneficia os preditores com melhores resultados em toda a simulação, de forma recursiva, podendo considerar que ocorre um aprendizado em que os agentes apenas selecionam os preditores com melhores resultados.

### 3.2.5 Melhor preditor pela soma dos pesos das diferenças

Esta política também utiliza as fórmulas presentes na Equação 3.1, mas em vez de apenas selecionar o melhor preditor pela soma da diferença, ele utiliza esse resultado para determinar tais pesos para cada preditor por seu percentual de acerto (calculado pela Equação 3.1 pela soma dos erros de todos os preditores).

$$TotalSomErrel_{n,t} = \sum(SomaErrel_{n,k,t}) \quad (3.2)$$

$$p(n, t) = \frac{\sum(p_k * \frac{TotalSomErrel_{n,t}}{SomaErrel_{n,k,t}})}{\sum(\frac{TotalSomErrel_{n,t}}{SomaErrel_{n,k,t}})} \quad (3.3)$$

Neste caso, o exemplo em que o agente  $n$  possua dois preditores  $k = 1$  e  $k = 2$ , que tenham acesso a uma memória  $m = 1$  e que calculem os seguintes valores  $p_{(k=1,t-1)} = 15$  e  $p_{(k=2,t-1)} = 28$  e o valor do Attendance  $L_{(t-1)} = 20$ :

$$TotalSomErrel_{n,t} = 5 + 8 = 13$$

$$p(n, t) = \frac{15 * 13 / 5 + 28 * 13 / 8}{13 / 5 + 13 / 8} = 20$$

Considerando agora um próximo ciclo ( $t + 1$ ), onde  $L_t = 30$ ,  $p_{(k=1,t)} = 40$  e  $p_{(k=2,t)} = 27$  e utilizando os valores já calculados na Subseção 3.2.4:

$$TotalSomErrel_{n,t+1} = 15 + 11 = 26$$

$$p(n, t + 1) = \frac{40 \cdot 26/15 + 27 \cdot 26/11}{26/15 + 26/11} = 33,27$$

Como no segundo tipo de política, o cálculo é recursivo, e pelo resultado é observado que o valor predito final obtido foi um valor ponderado entre os dois valores obtidos pelos dois preditores, também ocorrendo um aprendizado do melhor preditor, mas utilizando parte de cada um. Ou seja, ele não escolhe um preditor, mas uma ponderação entre ambos...

### 3.3 Questões a serem respondidas:

Segue descrição das três questões norteadoras deste trabalho. Tais questões representam seus objetivos e seu desenvolvimento permite a geração de conhecimento a partir do desenvolvimento presente no Capítulo 4.

1. Como os aspectos microscópicos deste modelo podem ser utilizados em futuros parâmetros da simulação?;
2. Como o sistema se comporta alterando os parâmetros implementados neste modelo?;
3. Como utilizar o PEFB em uma analogia para simular as recargas de baterias para um enxame de drones?.

#### 3.3.1 Como os aspectos microscópicos deste modelo podem ser utilizados em futuros parâmetros da simulação?

Para responder a esta questão, realizou-se a simulação com apenas um preditor por agente e uma análise de sensibilidade considerando variados limites de lotação do bar  $L$ , com 10 repetições de cada experimento. Os parâmetros são definidos na Tabela 3.4.

O tempo limite da simulação é de 500 ciclos (*ticks*) e 10 repetições por simulação foram realizadas, resultando em um total de 360 simulações.

Para a medição do desempenho dos preditores foi utilizado o indicador *Reward R*, seguindo a política presente na Tabela 3.3.

Para verificar se a quantidade de memória influencia na performance dos preditores, foi realizado teste de hipótese para avaliar se são encontradas evidências estatísticas de que as médias são iguais. Considerando como 95% de certeza ( $\alpha = 5\%$ ) as duas hipóteses são:

Tabela 3.4: Parâmetros para simulação - Experimento 1

Descrição Parâmetro	Valores
Quantidade de $k$ preditores disponíveis para os agentes	Um preditor por agente
Quantidade de informação disponível ( $m$ semanas anteriores) que os preditores dos agentes possuem para tomada de decisão	10, 20 e 30 Semanas
Limiar $B$ de lotação do Bar	20%, 40%, 60% e 80%
Políticas de tomada de decisão em que agentes com vários preditores utilizam para escolher o melhor preditor	<b>Política 1</b> - Um preditor por agente
Constituição dos tipos de agentes (ZI e CPX) que participaram da simulação	100% ZI , 50% ZI & 50% CPX, e 100% CPX
Quantidade de preditores pelo tipo de população	100 %ZI $\rightarrow$ 10; 50%ZI (10) & 50% CPX (19) $\rightarrow$ 29; 100% CPX $\rightarrow$ 19
Duração da simulação	500 ciclos ( <i>ticks</i> )
Quantidade de agentes	100 drones
Repetição dos experimentos	10 vezes

- $H_0$  - Não há evidências estatísticas de que a média encontrada com uma memória é diferente da de outra (e. g. 10 e 20 semanas;
- $H_1$  - Observa-se que uma média encontrada com uma memória é significativamente diferente da de outra (e. g. 10 e 20 semanas).

São efetuados testes considerando a permutação entre as 3 memórias, 10, 20 e 30 semanas. Comparando os resultados entre os conjuntos de resultados das semanas 10 e 20, 10 e 30 e 20 e 30.

Se o valor de  $p$  for menor do que 0,05, então pode-se rejeitar  $H_0$  e assim existem evidências estatísticas de 95% de que os valores encontrados pelas memórias são diferentes.

Os resultados esperados são:

- Dados estatísticos (média e desvio padrão) desses resultados (valores do *reward*);
- Qual é o melhor preditor para cada situação de limiar de lotação?;
- A quantidade de memória disponível interfere no desempenho dos preditores?.

### 3.3.2 Como o sistema se comporta alterando os parâmetros implementados neste modelo?

O objetivo do experimento é executar uma análise de sensibilidade, alterando os parâmetros conforme a Tabela 3.5, sendo esses parâmetros também utilizados no experimento descrito na Subseção 3.3.3, onde os nomes de cada protagonista da simulação está renomeado em parênteses:

Tabela 3.5: Parâmetros para simulação - Experimentos 2 e 3

Descrição dos parâmetros	Valores
Quantidade de $k$ preditores disponíveis para os agentes (ou drones)	1 e 6 preditores por agentes (ou drones)
Quantidade de informação disponível ( $m$ semanas anteriores) que os preditores dos agentes (ou drones) possuem para tomada de decisão	10, 20 & 30 Semanas
Limiar $B$ de lotação do Bar (ou estação de carregamento)	20%, 40% , 60%, e 80%
Políticas de tomada de decisão	Três: <b>Política 1</b> - Um preditor/agente; <b>Política 2</b> - Melhor preditor pelo somatória da diferença & <b>Política 3</b> - Melhor preditor pela soma dos pesos da diferença
Constituição dos tipos de agentes (ou drones) (ZI e CPX) que participaram da simulação	100% ZI, 50% ZI & 50% CPX, e 100% CPX
Quantidade de preditores pelo tipo de população	100 %ZI → 10; 50 %ZI (10) & 50 % CPX (19) → 29; 100 % CPX → 19
Duração da simulação	499 <i>ticks</i>
Quantidade de agentes	100 agentes (ou drones)
Repetição dos experimentos	10 vezes

O tempo limite da simulação é de 499 ciclos e foram 10 repetições por simulação realizada, resultando em 108 possíveis casos e 1080 simulações.

O objetivo deste experimento é conhecer o comportamento do modelo conforme se altera os parâmetros de simulação. Desta forma, pode-se comparar os resultados com a literatura e possibilitar o estudo da possível analogia entre o PEFB e a simulação de recargas de enxame de drones, conforme será descrito na Subseção 3.3.3.

Os resultados esperados são:

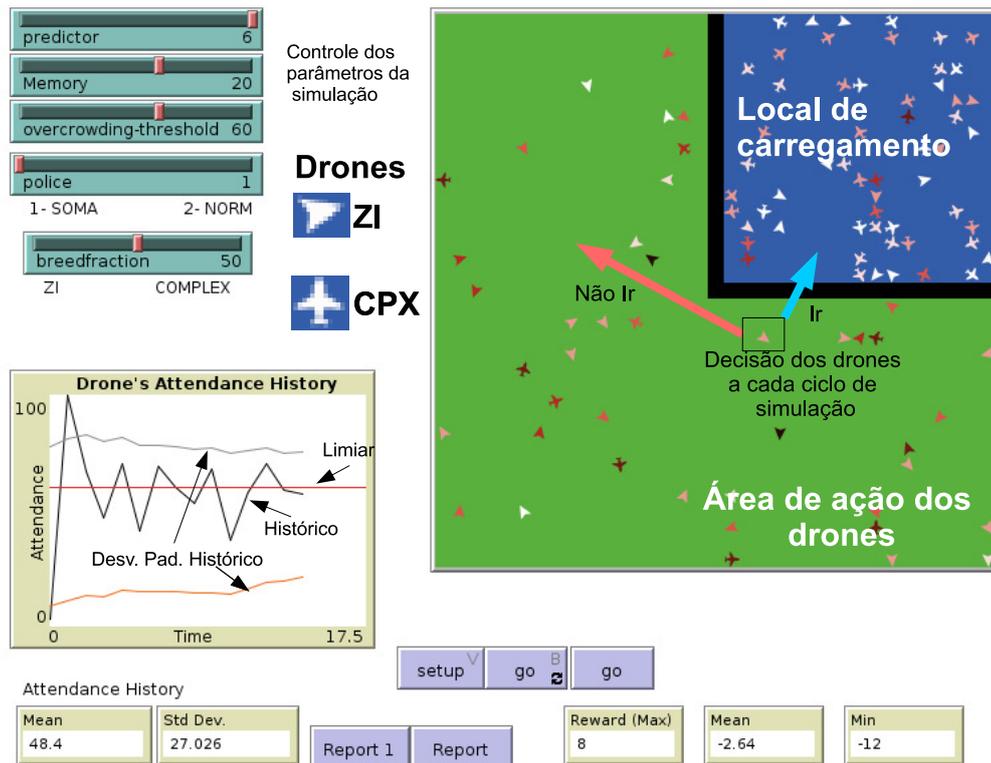


Figura 3.4: Representação da analogia

- Dados estatísticos (média e desvio padrão) dos resultados (valores de *attendance* em função do tempo) para todos os casos;
- Como os dados acima se correlacionam em relação às variações de limiar de lotação, quantidade de memória, política e tipos de agentes?;
- A constituição da população de preditores interfere no desempenho dos preditores e do sistema?;
- É possível determinar conjuntos de preditores que conseguem melhores resultados?.

### 3.3.3 Como utilizar o PEFB em uma analogia para simular as recargas de baterias para um enxame de drones?

Nesta Subsecção é descrita a elaboração de uma analogia utilizando o PEFB para construir uma proposta de coordenação de uma rede de carregamento das baterias de um enxame de drones.

A seguir, seguem itens que compõem o PEFB e a analogia:

- **Ticks:** Unidades de tempo discreto que compõem a simulação;
- **Agentes:** Os agentes são os dispositivos (drones) que compõem o enxame. Os mesmos realizam os trabalhos a que foram designados (vigilância, combate ao fogo, mapeamento). Existem dois tipos de agentes nesta simulação: ZI (Zero Inteligência) e CPX (Complexos). Essa classificação depende da sua constituição interna em relação aos tipos de preditores utilizados, como mostrado na Tabela 3.1. Neste trabalho, o número total de drones que constituem o enxame é de 100 unidades;
- **Vizinhança:** Área de ação dos drones (região verde na Figura 3.4);
- **Bar:** É o local de carga dos drones. Todos os drones do enxame carregam em um único lugar (região azul na Figura 3.4);
- **Limiar:** Capacidade de lugares para o carregamento para os drones, representado pela linha vermelha no gráfico *Attendance* da Figura 3.4. Esse valor é uma fração da quantidade total de drones presente no sistema. O mesmo pode ser controlado pelo ajuste deslizante *overcrowding-threshold*;
- **Attendance:** Número de drones que foram recarregar em cada ciclo;
- **Histórico:** Série temporal dos valores de *attendance* (linha preta no gráfico *Attendance* da Figura 3.4);
- **Memória:** Quantidade de valores anteriores do *Attendance* disponíveis para que os drones façam a estimativa do valor da próxima semana. Nesses modelos utilizaremos os últimos 10, 20 e 30 valores;
- **Valor do Attendance acima do limiar:** Neste caso, o sistema fica sobrecarregado e nenhum drone é carregado;
- **Preditores:** Inteligência interna dos drones que monitoram sua capacidade de bateria e uso (uso de bateria devido ao uso do drone). Nesse modelo, por questão de simplificação, são considerados os valores de memória para se tomar as decisões;
- **Saco de estratégia:** Quantidade de preditores que competem entre si para serem escolhidos como o preditor mais acurado. Para a tomada de decisão do melhor preditor

são utilizadas três políticas, conforme já explicado nas Subseções 3.2.3, 3.2.4 e 3.2.5. Desta forma, podem ser utilizados um ou seis preditores por agente;

- **Tomada de decisão:** Os drones podem ir (seta verde na Figura 3.4) ou não ir (seta vermelha na Figura 3.4) para o carregador em cada ciclo, conforme o valor obtidos pelo conjunto de preditores. Como indicador da taxa de acerto para esta decisão são utilizados os valores dos *Rewards* conforme a lógica presente na Tabela 3.3.

Os autores Boggio-Dandry e Soyata (2018) descrevem sete possíveis estados para uma modelagem de estação de recarregamentos de drones em *FANET*, conforme representado na Figura 2.3:

1. **Pronto:** Drones estão carregados e prontos para voar;
2. **Voando em enxame:** Drones estão voando em enxames e fazendo seu trabalho;
3. **Em enxame aguardando recarga:** Drones precisando recarregar e esperando para ser substituído por outro drone;
4. **Voando para o enxame:** Após os drones estarem recarregados, retorna para o enxame;
5. **Voando para o recarregador:** Drones retornando do voo para o carregador;
6. **Na fila do carregador:** Aguardando a disponibilidade de lugar para o drone ser carregado;
7. **Carregando:** Drones em processo de carregamento.

O modelo deste trabalho usa uma versão simplificada desta abordagem, que pode ser definida como:

1. **Voando em enxame:** Drones estão voando na vizinhança, esperando os drones tomar a decisão de ir ou não ir para os carregadores a cada ciclo da simulação;
2. **No enxame aguardando recarga:** Neste estado, o drone tomou a decisão de ir para a recarga e possuem duas possibilidades:
  - (a) **O carregador está cheio:** Neste caso, o drone não irá recarregar. Desta forma, ocorre os seguintes estados: **Em enxame aguardando recarga** → **Voando para o carregamento** → **Voando para o enxame** → **Voando em enxame**;

- (b) **O carregador está disponível:** Ocorre o carregamento dos drones. **Em enxame aguardando recarga → Voando para o carregamento → Na fila do carregador → Carregando → pronto → Voando para o enxame → Voando em enxame.**

Considerando os tipos de preditores com os estados dos drones, podemos correlacionar ambos na Tabela 3.6 :

Tabela 3.6: Associação dos tipos de estados dos drones pelos tipos de preditores

Estados dos Drones	Estimadores	Aleatório	Constante	Mímico
Voando em enxame	✓	✓	✓	✓
No enxame aguardando recarga - Carregador cheio	✓	✓	✓	✓
No enxame aguardando recarga - Carregador disponível	✓	✓	✓	✓

A Tabela 3.6 correlaciona os tipos de preditores e os possíveis estados dos drones e a Tabela 3.5 descreve quais parâmetros foram utilizados para executar a simulação dessa analogia, utilizando novos nomes conforme já descrito. Lembrando que neste modelo não é considerado o consumo de bateria dos drones nem o tempo necessário para o recarregamento das baterias. Em um trabalho futuro, onde esses parâmetros estejam incluídos, a Tabela 3.6 poderá ser alterada para aproveitar o comportamento interno de cada preditor, como por exemplo, se um drone necessitar recarregar sua bateria de forma urgente, o preditor que considera como estimativa o valor constante abaixo do limiar, pode ser escolhido por uma política de escolha do preditor por agente, onde desta forma o drone irá de forma continua até o carregador, até sua recarga.

## Capítulo 4

# Pesquisa do melhor desempenho: casos estudados

Neste capítulo, são descritos resultados encontrados nos experimentos citados no Capítulo 3. Com tais resultados, será possível responder às 3 questões descritas na Seção 3.3.

### 4.1 Como os aspectos microscópicos deste modelo podem ser utilizados em futuros parâmetros da simulação?

Para descobrir qual o melhor preditor, dos escolhidos de forma aleatória para a constituição do espaço de estratégias para o PEFB, foram executados 360 experimentos, utilizando análise de sensibilidade pela variação dos seguintes parâmetros:

- Quantidade de preditores por agentes ( $k$ ): 1;
- Tipo de agentes: 100% ZI, 50% ZI & 50% CPX, e 100% CPX;
- Tipos de preditores: 10 preditores ZI e 19 Preditores CPX;
- Limiares de lotação do bar (B): 20%, 40%, 60%, e 80%;
- Dados disponíveis (memória  $m$ ): 10, 20, 30 semanas;
- Tempo limite de simulação: 500 *ticks*;
- Repetições das simulações: 10 vezes.

O objetivo desse experimento é o estudo do aspecto microscópico da simulação relacionado com o desempenho dos preditores. Para medir tal desempenho, é utilizado um preditor por agente. Tal escolha é devido não haver troca de preditores durante as simulações por agente, assim o desempenho do agente é diretamente proporcional ao desempenho do preditor. Os resultados estão relacionados com os valores médios dos *rewards* obtidos nos 36 tipos de configurações de parâmetros com 10 repetições cada.

Devido o caráter aleatório do sorteio dos preditores por agentes no início de cada simulação, conforme já descrito na Subseção 3.2.1, pode ocorrer que em algumas rodadas de simulações, alguns preditores não sejam sorteados, sendo desta forma a possibilidade de que não haja em todas as 36 configurações, 10 repetições para esses preditores não sorteados.

Os resultados foram separados por tipo de população por agentes, onde cada resultado é avaliado pelos limiares e pela variação da memória (informação) disponível para cada preditor tomar sua decisão. Para comparar se é observada variação perceptível nos valores das médias entre diferentes valores de memória, foi utilizado um teste de hipótese *t-student* de diferença das médias com nível de significância de 5%, sendo um teste de cauda dupla.

As hipóteses para este teste são:

- H0: Com o nível de significância de 95%, não se pode rejeitar que médias das diferenças de duas amostras são iguais a 0;
- H1: Com o nível de significância de 95% é verificada uma diferença entre os valores das médias de ambas amostras diferente de 0.

Se o valor de  $p$  encontrado for maior que o nível de significância, não se pode rejeitar a hipótese nula H0, então não se pode rejeitar que a diferença das médias das duas amostras é igual a 0. Caso contrário, pode-se rejeitar H0 e assumir H1. Em cada um dos 12 experimentos, são feitos testes estatísticos entre os resultados obtidos para as memórias (quantidade de memória disponível) de 10 e 20, 10 e 30, e 20 e 30 semanas.

#### 4.1.1 Simulações com agentes 100% ZI

A Figura 4.1 mostra os resultados das médias de todos os valores dos *rewards* para cada preditor com uma população de apenas agentes ZI. Essas médias incluem todos os valores obtidos alterando a quantidade de informação disponível (memória) como na Fig. 4.1,

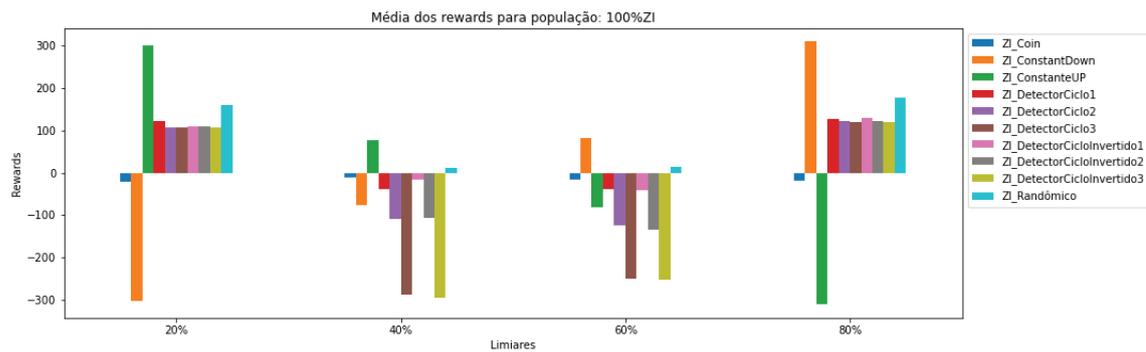


Figura 4.1: Comparativo do desempenho dos preditores com agentes 100% ZI

Observando a Figura 4.1, nota-se uma simetria nos valores obtidos dos *rewards* dos preditores, conforme variam-se os valores dos limiares de forma progressiva. O possível eixo de simetria está presente no valor de limiar de 50%. É também observado que os desempenhos dos preditores *Simples\_ConstantDown* e *Simples\_ConstantUp* são inversos, mostrando que o desempenho dos mesmos é dependente dos valores do limiar, já que um funciona melhor com limiar menores e o outro com limiares maiores.

Outro fator interessante é que nos valores intermediários de limiar (40% e 60%) é a variação do desempenho dos preditores que seleciona seu valor predito pela repetição dos valores anteriores do histórico, os chamados Detectores de ciclos, ou seja, é observado que os preditores *Simples\_DetectorCiclo3* e *Simples\_DetectorCicloInvertido3*, possuem um desempenho inferior aos preditores *Simples\_DetectorCiclo1* e *Simples\_DetectorCicloInvertido1*, sendo um possível padrão para esse caso.

Também é interessante o bom desempenho do preditor que utiliza valores randômicos, o que pode ser explicado pela própria natureza desse tipo de preditor.

Em relação ao aspecto de variação de desempenho pela memória, segue os dados abaixo:

### Variações do desempenho dos preditores pela variação da quantidade de informações disponíveis

As Tabelas 4.1, 4.2, 4.3 e 4.4 apresentam os resultados para os testes de hipóteses *t-student* da média para os limiares de 20%, 40%, 60%, e 80% com uma população de apenas preditores ZI. Os dados a seguir mostram os valores médios para cada tipo de capacidade de memória, o resultado dos testes e os valores *p* para cada teste. Lembrando que cada teste é realizado em duplas, sendo elas as seguintes: memórias 10-20, 10-30, e 20-30 semanas.

Tabela 4.1: Estatística dos *Rewards* para os preditores 100% ZI, com limiar de 20 %

Preditores Limiar: 20%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Simple_Coin	-18,0	-22,6	-24,8	0,730	H0	0,565	H0	0,824	H0
Simple_ConstantDown	-292,8	-314,0	-303,4	0,292	H0	0,507	H0	0,594	H0
Simple_ConstanteUP	290,8	312,0	301,4	0,292	H0	0,507	H0	0,594	H0
Simple_DetectorCiclo1	122,4	132,2	113,4	0,759	H0	0,703	H0	0,619	H0
Simple_DetectorCiclo2	84,8	133,0	106,0	0,209	H0	0,502	H0	0,476	H0
Simple_DetectorCiclo3	84,4	127,2	106,0	0,279	H0	0,493	H0	0,587	H0
Simple_DetectorCicloInvertido1	87,8	129,2	108,6	0,285	H0	0,499	H0	0,585	H0
Simple_DetectorCicloInvertido2	83,4	134,8	107,8	0,184	H0	0,431	H0	0,468	H0
Simple_DetectorCicloInvertido3	83,6	126,6	109,4	0,278	H0	0,399	H0	0,651	H0
Simple_Randômico	151,0	166,8	164,6	0,153	H0	0,246	H0	0,862	H0

Tabela 4.2: Estatística dos *Rewards* para os preditores 100% ZI, com limiar de 40 %

Preditores Limiar: 40%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Simple_Coin	-15,6	-12,4	-4,8	0,770	H0	0,197	H0	0,505	H0
Simple_ConstantDown	-76,8	-69,0	-87,2	0,612	H0	0,443	H0	0,140	H0
Simple_ConstanteUP	74,8	67,0	85,2	0,612	H0	0,443	H0	0,140	H0
Simple_DetectorCiclo1	-18,4	-83,2	-16,4	0,505	H0	0,982	H0	0,463	H0
Simple_DetectorCiclo2	-144,4	-62,0	-122,6	0,535	H0	0,855	H0	0,608	H0
Simple_DetectorCiclo3	-307,6	-277,8	-276,8	0,558	H0	0,327	H0	0,984	H0
Simple_DetectorCicloInvertido1	9,0	-14,2	-40,2	0,835	H0	0,598	H0	0,787	H0
Simple_DetectorCicloInvertido2	-119,8	-64,2	-138,8	0,659	H0	0,873	H0	0,515	H0
Simple_DetectorCicloInvertido3	-335,2	-285,6	-266,6	0,291	H0	0,060	H0	0,672	H0
Simple_Randômico	18,6	2,0	11,4	0,218	H0	0,522	H0	0,370	H0

As Figuras 4.2, 4.3, 4.4 e 4.5 representam respectivamente os *boxplots* dos valores dos *rewards*, mostrando a mediana e os comportamentos para os 19 preditores.

Observando os resultados obtidos, a maior quantidade de hipóteses nulas rejeitadas com essa população ocorreu com o limiar de 80% e entre as semanas 10 e 30. A pequena ocorrência de rejeição desse teste mostra que os tipos de preditores sofrem pouca influência da quantidade de informação disponível, já que os mesmos não executam nenhuma previsão. Então tal diferenciação pode ser considerada como variação ou flutuação estatística esperada.

#### 4.1.2 Simulações com agentes 50% ZI e 50% CPX

Para o caso de simulações com uma população de agentes com 50% ZI e 50% CPX, e considerando os resultados obtidos de todos os comprimentos de memórias encontram-se os seguintes resultados, conforme a Figura 4.6.

Assim como descrito na Subsecção 4.1.1, ocorre o mesmo comportamento de simetria dos valores em relação aos valores antagônicos dos limiares, é observado também um bom desempenho dos preditores autorregressivos. O comportamento dos preditores com suavização exponencial é de relativamente baixo desempenho nos limiares centrais e bom

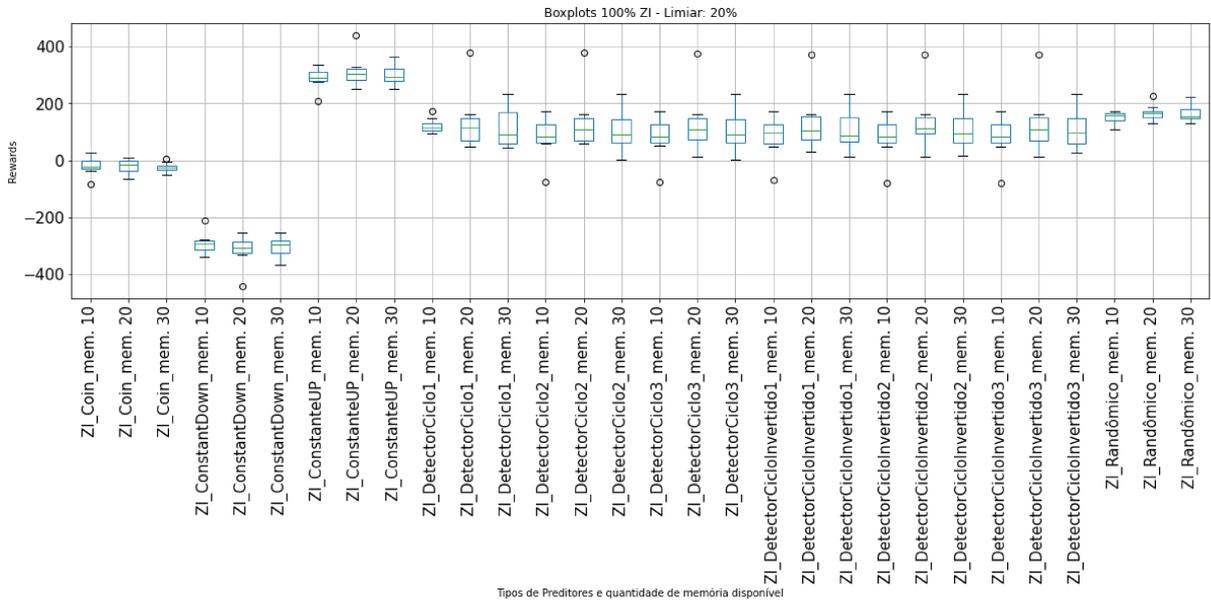


Figura 4.2: BoxPlots Rewards 100%ZI e Limiar 20%

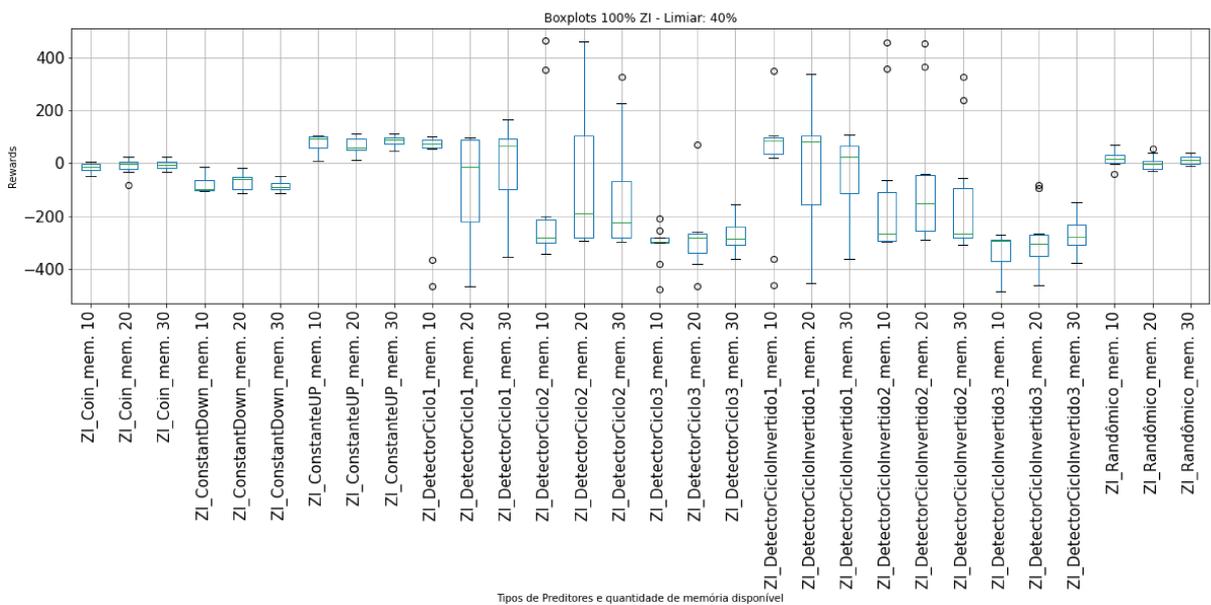


Figura 4.3: BoxPlots Rewards 100% ZI e Limiar 40%

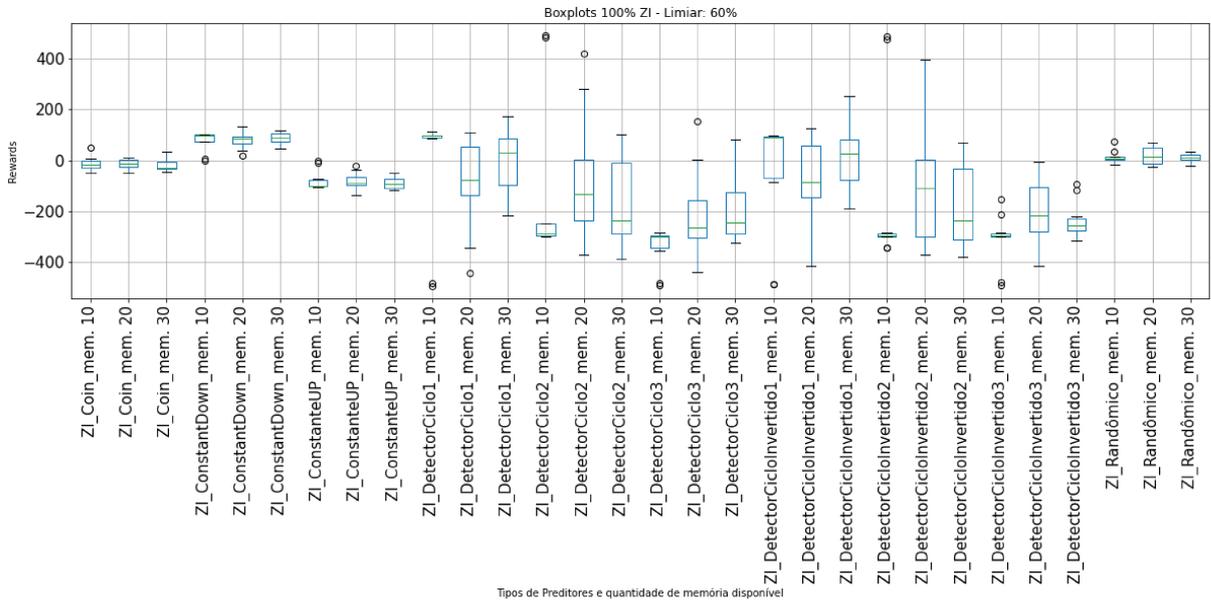


Figura 4.4: BoxPlots Rewards 100%ZI e Limiar 60%

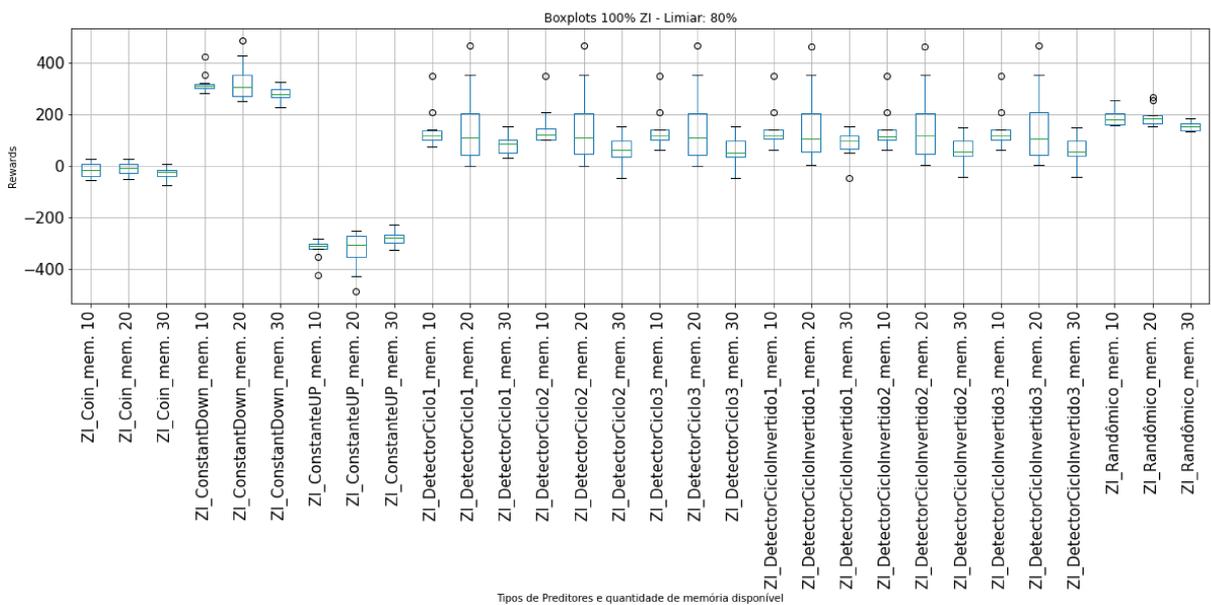


Figura 4.5: BoxPlots Rewards 100%ZI e Limiar 80%

Tabela 4.3: Estatística dos *Rewards* para os preditores 100% ZI, com limiar de 60 %

Preditores Limiar: 60%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Simple_Coin	-13,8	-15,2	-18,0	0,897	H0	0,719	H0	0,779	H0
Simple_ConstantDown	76,0	79,2	86,8	0,847	H0	0,469	H0	0,569	H0
Simple_ConstanteUP	-78,0	-81,2	-88,8	0,847	H0	0,469	H0	0,569	H0
Simple_DetectorCiclo1	-17,8	-92,8	-4,4	0,452	H0	0,881	H0	0,223	H0
Simple_DetectorCiclo2	-130,4	-64,4	-176,2	0,617	H0	0,704	H0	0,270	H0
Simple_DetectorCiclo3	-341,2	-210,4	-201,0	0,050	H1	0,009	H1	0,892	H0
Simple_DetectorCicloInvertido1	-51,4	-89,6	17,2	0,691	H0	0,440	H0	0,153	H0
Simple_DetectorCicloInvertido2	-149,8	-72,4	-185,0	0,577	H0	0,772	H0	0,290	H0
Simple_DetectorCicloInvertido3	-311,2	-215,6	-235,0	0,097	H0	0,076	H0	0,701	H0
Simple_Randômico	12,0	17,6	9,4	0,690	H0	0,784	H0	0,523	H0

Tabela 4.4: Estatística dos *Rewards* para os preditores 100% ZI, com limiar de 80 %

Preditores Limiar: 80%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Simple_Coin	-17,4	-10,6	-28,8	0,575	H0	0,355	H0	0,112	H0
Simple_ConstantDown	320,8	328,2	280,0	0,791	H0	0,019	H1	0,088	H0
Simple_ConstanteUP	-322,8	-330,2	-282,0	0,791	H0	0,019	H1	0,088	H0
Simple_DetectorCiclo1	143,0	157,6	80,4	0,792	H0	0,046	H1	0,150	H0
Simple_DetectorCiclo2	148,4	159,0	62,0	0,846	H0	0,011	H1	0,083	H0
Simple_DetectorCiclo3	142,4	158,2	60,2	0,776	H0	0,019	H1	0,081	H0
Simple_DetectorCicloInvertido1	143,4	158,4	86,4	0,783	H0	0,089	H0	0,178	H0
Simple_DetectorCicloInvertido2	142,0	159,8	62,8	0,746	H0	0,022	H1	0,080	H0
Simple_DetectorCicloInvertido3	141,8	157,8	62,2	0,772	H0	0,021	H1	0,086	H0
Simple_Randômico	187,6	191,2	153,0	0,827	H0	0,009	H1	0,019	H1

nos limiares extremos, e também é observado baixo desempenho do preditor Simple\_DetectorCiclo1 e o bom desempenho em relação ao Simple\_DetectorCiclo2.



Figura 4.6: Comparativo do desempenho dos preditores com agentes 50% ZI e 50% CPX

### Variações do desempenho dos preditores pela variação da quantidade de informações disponíveis

As Tabelas 4.5, 4.6, 4.7 e 4.8 mostram respectivamente para os limiares de 20%, 40%, 60%, e 80% para o conjunto de agentes mistos CPX e ZI, considerando as memórias de 10, 20, e 30 semanas, comparando-as em dupla (memórias de 10-20, 10-30 e 20-30 semanas):

Tabela 4.5: Estatística dos *Rewards* para os preditores 50% ZI e 50% CPX, com limiar de 20 %

Preditores Limiar: 20%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Complex_AR	166,6	153,11	125,78	0,327	H0	0,000	H1	0,067	H0
Complex_ARIMA001	162,44	148,22	122,6	0,317	H0	0,001	H1	0,085	H0
Complex_ARIMA101	75,56	42,44	1,78	0,073	H0	0,001	H1	0,061	H0
Complex_ARMA	-24,0	-60,6	-91,0	0,091	H0	0,000	H1	0,141	H0
Complex_EWM025	29,78	62,6	43,11	0,038	H1	0,341	H0	0,285	H0
Complex_EWM05	11,56	55,4	43,8	0,020	H1	0,007	H1	0,513	H0
Complex_EWM075	79,4	80,0	57,2	0,978	H0	0,125	H0	0,309	H0
Complex_EWMhalf3	53,56	83,2	68,89	0,261	H0	0,458	H0	0,549	H0
Complex_EWMhalf5	76,25	82,6	47,6	0,779	H0	0,193	H0	0,053	H0
Complex_EWhalf1	159,2	136,8	103,78	0,084	H0	0,000	H1	0,020	H1
Complex_EXPSMDAN	69,4	36,67	2,44	0,122	H0	0,002	H1	0,143	H0
Complex_Holt2	168,0	154,4	130,2	0,270	H0	0,000	H1	0,065	H0
Complex_MediaMove12	77,0	90,8	68,44	0,483	H0	0,542	H0	0,284	H0
Complex_MediaMove14	-111,5	-129,75	-176,6	0,612	H0	0,014	H1	0,170	H0
Complex_MediaMove1Len	14,2	65,8	75,56	0,014	H1	0,001	H1	0,568	H0
Complex_SES	159,0	153,4	129,8	0,642	H0	0,002	H1	0,073	H0
Complex_UNOBCOMP1	168,0	156,89	130,67	0,395	H0	0,001	H1	0,070	H0
Complex_UNOBCOMP2	150,8	129,33	93,11	0,174	H0	0,000	H1	0,039	H1
Complex_UNOBCOMP3	31,2	0,22	-22,4	0,155	H0	0,005	H1	0,270	H0
Simple_Coin	-17,8	-27,2	-27,2	0,319	H0	0,335	H0	1,000	H0
Simple_ConstantDown	-170,0	-156,4	-132,2	0,270	H0	0,000	H1	0,065	H0
Simple_ConstantUP	168,0	154,4	130,2	0,270	H0	0,000	H1	0,065	H0
Simple_DetectorCiclo1	-103,4	-122,6	-176,6	0,536	H0	0,003	H1	0,073	H0
Simple_DetectorCiclo2	63,2	60,6	80,2	0,942	H0	0,583	H0	0,581	H0
Simple_DetectorCiclo3	-40,4	-28,4	-53,8	0,669	H0	0,734	H0	0,557	H0
Simple_DetectorCicloInvertido1	18,8	-35,4	-33,4	0,282	H0	0,289	H0	0,966	H0
Simple_DetectorCicloInvertido2	47,4	38,2	46,0	0,867	H0	0,974	H0	0,880	H0
Simple_DetectorCicloInvertido3	-57,2	-66,2	-63,8	0,766	H0	0,827	H0	0,937	H0
Simple_Randômico	79,2	71,6	54,6	0,512	H0	0,026	H1	0,137	H0

As Figuras 4.7, 4.8, 4.9 e 4.10 mostram os *boxplots* contendo os valores das medianas, quartis dos *rewards* para este tipo de preditores (50%ZI e 50%CPX). É observado grande incidência de rejeição da hipótese H0 nos limiares de 20% e 40% com o conjunto de teste de 10 - 30 semanas e com o limiar de 60% com 10-20 semanas. Com o limiar de 80% quase não se observa rejeição do H0.

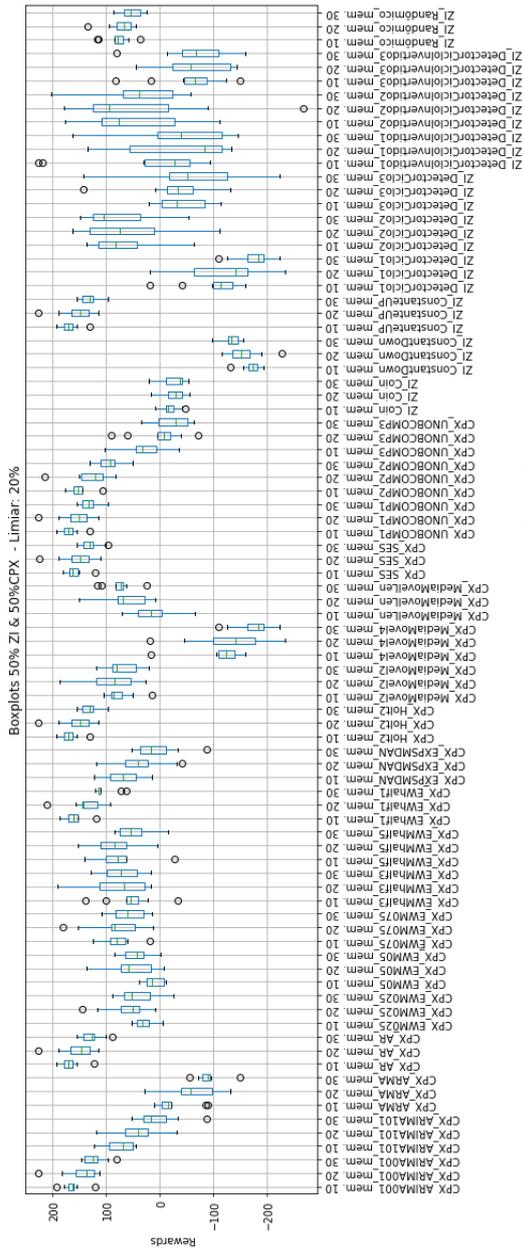


Figura 4.7: BoxPlots Rewards 50%ZI & 50%CPX Limiar 20%

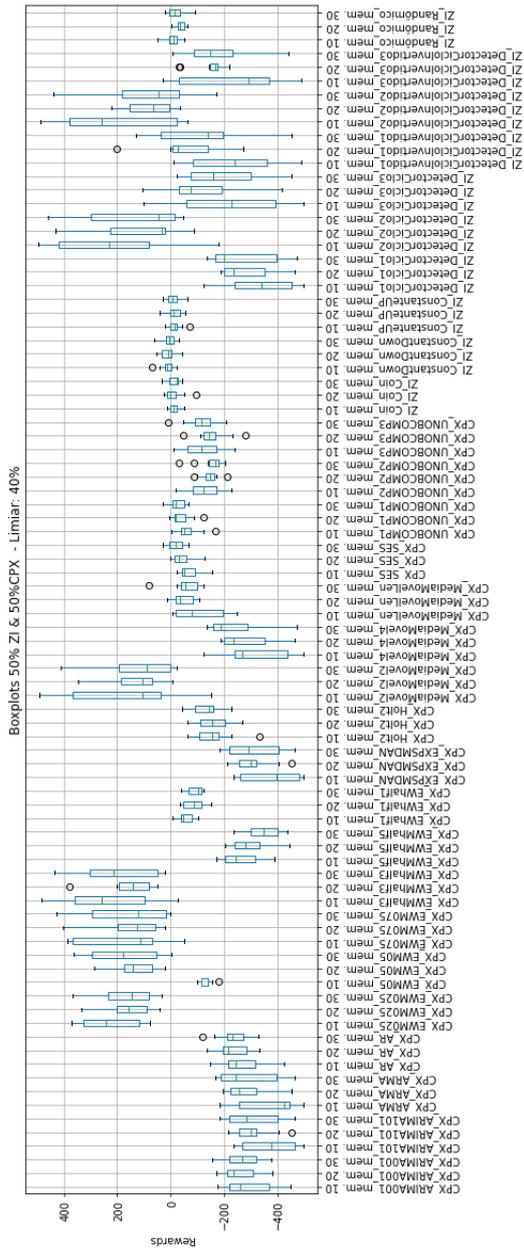


Figura 4.8: BoxPlots Rewards 50%ZI & 50%CPX e Limiar 40%

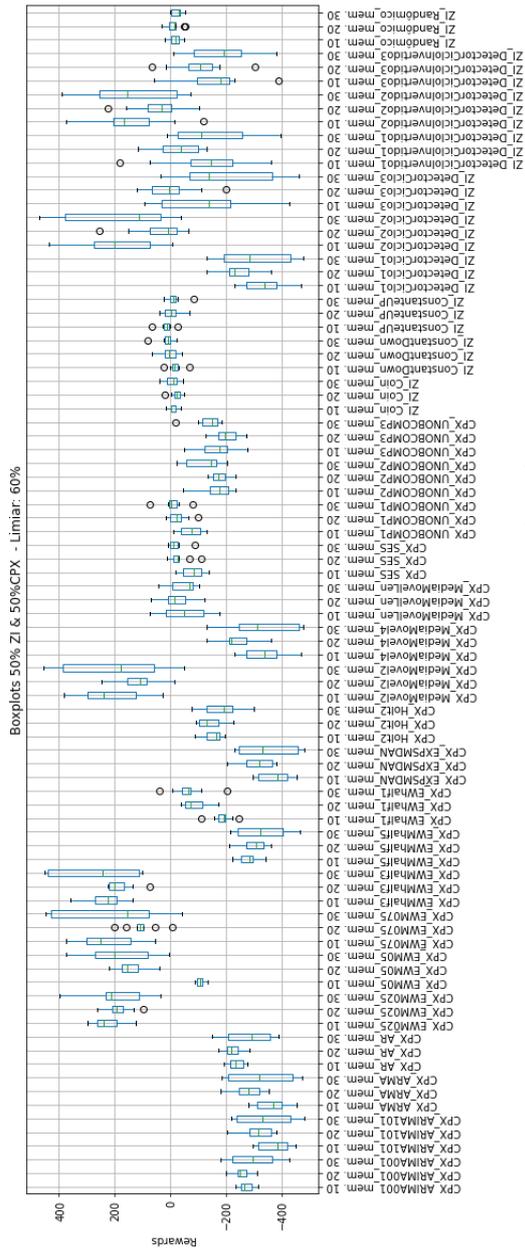


Figura 4.9: BoxPlots Rewards 50%ZI & 50%CPX e Limiar 60%

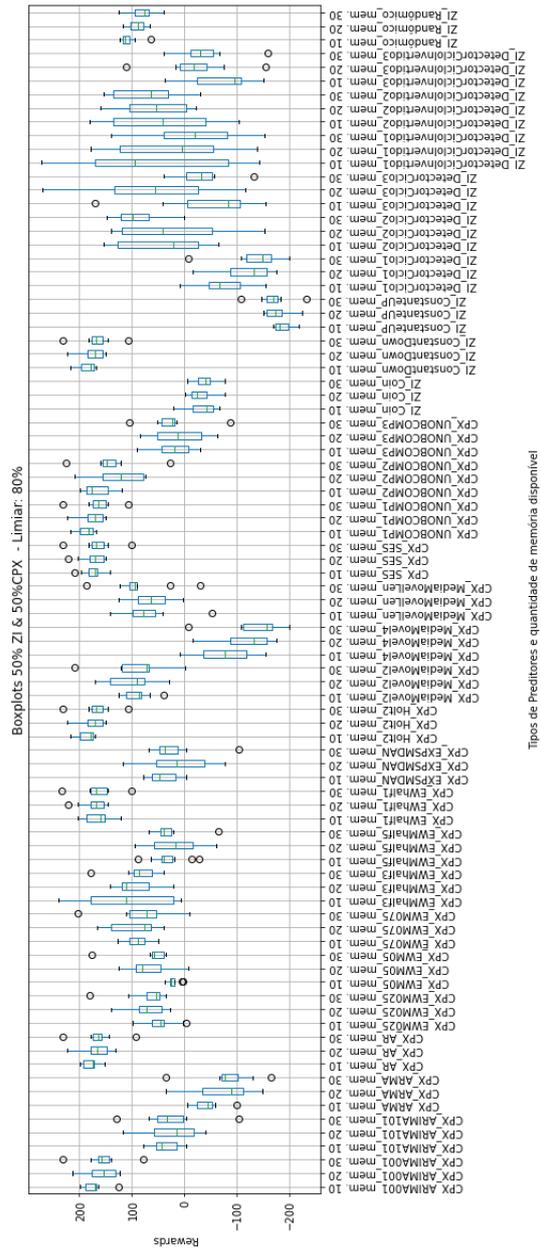


Figura 4.10: BoxPlots Rewards 50%ZI & 50%CPX e Limiar 80%

Tabela 4.6: Estatística dos *Rewards* para os preditores 50% ZI e 50% CPX, com limiar de 40 %

Preditores Limiar: 40%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Complex_AR	-255,56	-229,0	-230,8	0,492	H0	0,499	H0	0,952	H0
Complex_ARIMA001	-292,67	-257,11	-272,67	0,392	H0	0,617	H0	0,656	H0
Complex_ARIMA101	-365,8	-306,8	-303,33	0,159	H0	0,221	H0	0,938	H0
Complex_ARMA	-362,22	-277,78	-291,6	0,093	H0	0,204	H0	0,770	H0
Complex_EWM025	226,8	163,4	169,33	0,212	H0	0,290	H0	0,904	H0
Complex_EWM05	-128,25	139,11	172,44	0,000	H1	0,000	H1	0,539	H0
Complex_EWM075	176,75	162,89	164,2	0,858	H0	0,879	H0	0,985	H0
Complex_EWMhalf3	239,8	152,89	200,2	0,199	H0	0,595	H0	0,435	H0
Complex_EWMhalf5	-260,8	-292,0	-345,43	0,348	H0	0,037	H1	0,164	H0
Complex_EWhalf1	-56,8	-84,8	-89,6	0,109	H0	0,032	H1	0,777	H0
Complex_EXPSMDAN	-367,33	-306,6	-313,6	0,181	H0	0,298	H0	0,869	H0
Complex_Holt2	-162,67	-157,4	-134,0	0,883	H0	0,394	H0	0,439	H0
Complex_MediaMovel2	188,44	128,67	126,89	0,490	H0	0,514	H0	0,978	H0
Complex_MediaMovel4	-320,89	-277,2	-245,78	0,430	H0	0,235	H0	0,554	H0
Complex_MediaMovelLen	-104,75	-46,75	-55,6	0,165	H0	0,245	H0	0,717	H0
Complex_SES	-70,25	-41,4	-18,2	0,182	H0	0,017	H1	0,184	H0
Complex_UNOBCOMP1	-64,4	-40,0	-22,22	0,262	H0	0,037	H1	0,344	H0
Complex_UNOBCOMP2	-124,44	-146,0	-150,0	0,392	H0	0,362	H0	0,847	H0
Complex_UNOBCOMP3	-122,0	-152,8	-111,78	0,394	H0	0,779	H0	0,187	H0
Simples_Coin	-12,2	-11,2	-13,0	0,940	H0	0,939	H0	0,900	H0
Simples_ConstantDown	13,6	10,6	6,0	0,817	H0	0,548	H0	0,728	H0
Simples_ConstanteUP	-15,6	-12,6	-8,0	0,817	H0	0,548	H0	0,728	H0
Simples_DetectorCiclo1	-334,4	-277,2	-265,4	0,286	H0	0,260	H0	0,824	H0
Simples_DetectorCiclo2	218,8	112,8	130,8	0,247	H0	0,365	H0	0,824	H0
Simples_DetectorCiclo3	-223,0	-106,2	-196,67	0,158	H0	0,746	H0	0,200	H0
Simples_DetectorCicloInvertido1	-230,0	-63,0	-119,6	0,028	H1	0,207	H0	0,472	H0
Simples_DetectorCicloInvertido2	204,6	84,2	95,8	0,131	H0	0,252	H0	0,867	H0
Simples_DetectorCicloInvertido3	-226,4	-146,2	-174,6	0,237	H0	0,501	H0	0,567	H0
Simples_Randômico	-6,0	-35,8	-18,0	0,016	H1	0,402	H0	0,167	H0

### 4.1.3 Simulações com agentes 100% CPX

Para o caso de simulações com uma população de agentes com 100% CPX, e considerando os resultados obtidos considerando todas os valores de memórias encontram-se os seguintes resultados, conforme a Figura 4.11. Observa-se relativamente baixo desempenho de quase todos os preditores nos limiares de 20% e 80% e bons desempenhos para os preditores autorregressivos nos limiares de 40% e 60%.

#### Variações do desempenho dos preditores pela variação da quantidade de informações disponíveis

Para esse tipo de população, apenas CPX, estão compilados os dados presentes nas Tabelas 4.9, 4.10, 4.11 e 4.12, para os limiares de 20%, 40%, 60% e 80% respectivamente, considerando as memórias de 10, 20 e 30 semanas.

Tabela 4.7: Estatística dos *Rewards* para os preditores 50% ZI e 50% CPX, com limiar de 60 %

Preditores Limiar: 60%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Complex_AR	-238,0	-226,22	-282,22	0,457	H0	0,171	H0	0,093	H0
Complex_ARIMA001	-272,6	-257,33	-301,2	0,280	H0	0,346	H0	0,166	H0
Complex_ARIMA101	-375,4	-314,4	-338,0	0,033	H1	0,345	H0	0,542	H0
Complex_ARMA	-362,0	-281,78	-322,8	0,011	H1	0,374	H0	0,352	H0
Complex_EWM025	227,0	183,11	203,56	0,108	H0	0,625	H0	0,660	H0
Complex_EWM05	-108,0	142,6	184,2	0,000	H1	0,000	H1	0,348	H0
Complex_EWM075	227,2	104,67	207,56	0,007	H1	0,788	H0	0,150	H0
Complex_EWMhalf3	234,0	183,56	264,22	0,132	H0	0,601	H0	0,157	H0
Complex_EWMhalf5	-281,0	-305,8	-325,6	0,204	H0	0,188	H0	0,564	H0
Complex_EWhalf1	-188,44	-87,0	-66,0	0,000	H1	0,000	H1	0,447	H0
Complex_EXPSMDAN	-375,8	-314,44	-348,75	0,042	H1	0,544	H0	0,448	H0
Complex_Holt2	-153,6	-145,2	-191,4	0,666	H0	0,169	H0	0,120	H0
Complex_MediaMovel2	215,2	114,8	208,0	0,034	H1	0,918	H0	0,163	H0
Complex_MediaMovel4	-338,2	-239,25	-321,56	0,011	H1	0,745	H0	0,129	H0
Complex_MediaMovelLen	-47,11	-27,56	-45,78	0,579	H0	0,968	H0	0,498	H0
Complex_SES	-81,0	-29,6	-18,67	0,008	H1	0,001	H1	0,482	H0
Complex_UNOBCOMP1	-73,0	-27,75	-7,4	0,045	H1	0,005	H1	0,282	H0
Complex_UNOBCOMP2	-165,71	-177,0	-120,22	0,678	H0	0,191	H0	0,041	H1
Complex_UNOBCOMP3	-166,8	-201,0	-133,25	0,233	H0	0,277	H0	0,016	H1
Simple_Coin	-9,56	-23,2	-8,0	0,150	H0	0,883	H0	0,186	H0
Simple_ConstantDown	-16,6	2,4	12,8	0,145	H0	0,021	H1	0,445	H0
Simple_ConstanteUP	14,6	-4,4	-14,8	0,145	H0	0,021	H1	0,445	H0
Simple_DetectorCiclo1	-338,2	-243,8	-306,8	0,008	H1	0,525	H0	0,198	H0
Simple_DetectorCiclo2	193,6	38,6	181,0	0,013	H1	0,874	H0	0,065	H0
Simple_DetectorCiclo3	-130,8	0,0	-199,0	0,064	H0	0,408	H0	0,008	H1
Simple_DetectorCicloInvertido1	-133,0	-29,6	-159,6	0,100	H0	0,711	H0	0,031	H1
Simple_DetectorCicloInvertido2	149,0	43,8	140,6	0,076	H0	0,908	H0	0,145	H0
Simple_DetectorCicloInvertido3	-155,11	-104,8	-187,6	0,377	H0	0,605	H0	0,138	H0
Simple_Randômico	-16,8	-13,6	-22,89	0,767	H0	0,527	H0	0,379	H0

As Figuras 4.12, 4.13, 4.14 e 4.15 representam respectivamente os *boxplots* de valores dos *rewards* para essa população. Nesse tipo de população é observado que o fator de memória ocorre entre as memórias de 10-20 e 10-30, sendo pouco observado entre as semanas 20-30.

Em relação ao aumento de memória, observando as Tabelas 4.1 a 4.12, verifica-se que o aumento da memória tem pouca influência nos valores obtidos do *rewards*. São observado alguns pontos (principalmente com população 50%ZI e 50%CPX, e variações entre 10 e 30 semanas).

De forma geral, o desempenho dos preditores, em relação aos *rewards* se manteve constante com as seguintes observações:

- É observado que os valores dos preditores são simétricos em relação aos valores dos limiares. O eixo de simetria seria o valor central do *attendance*;
- Bom desempenho dos preditores autorregressivos;
- Os preditores com detectores de ciclo de 2 semanas também tiveram bom desempenho;

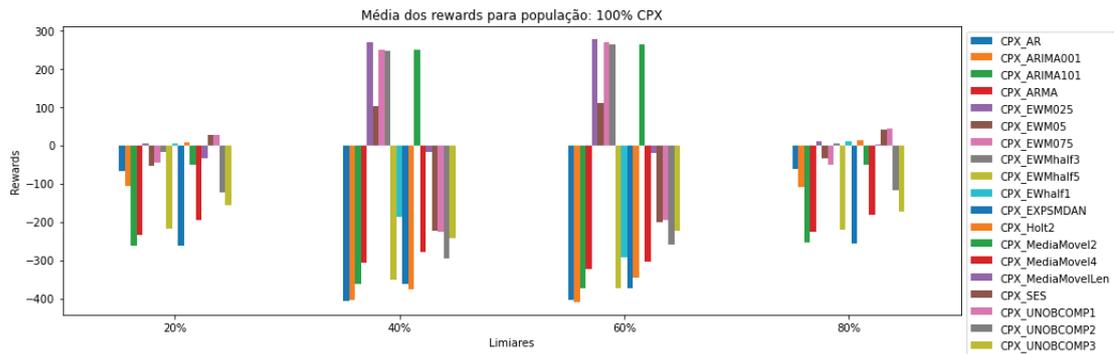


Figura 4.11: Comparativo do desempenho dos preditores com agentes 100% CPX

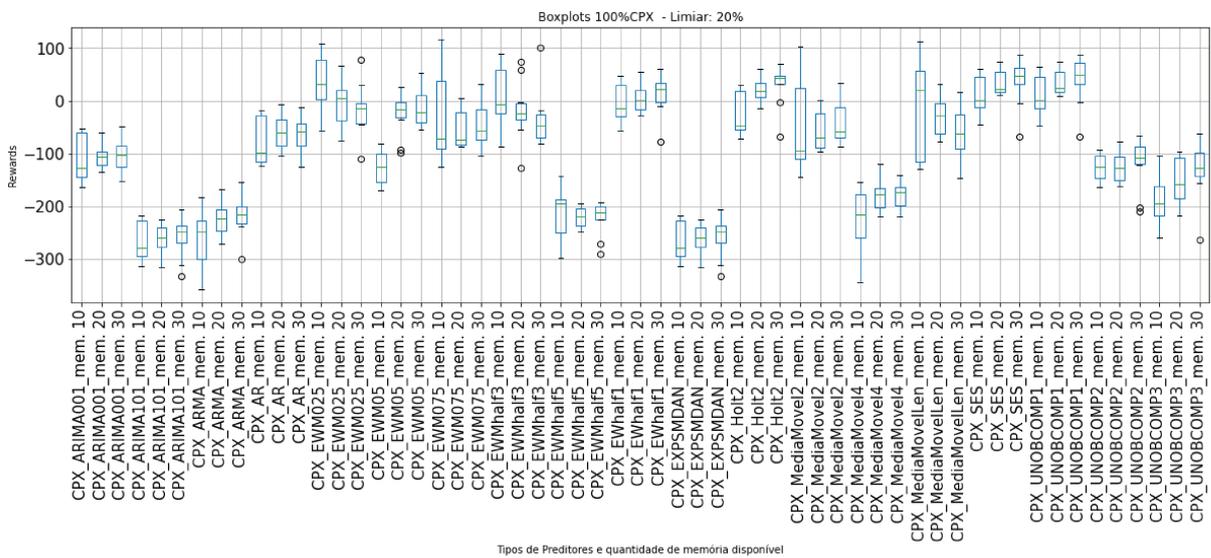


Figura 4.12: BoxPlots Rewards 100%CPX Limiar 20%

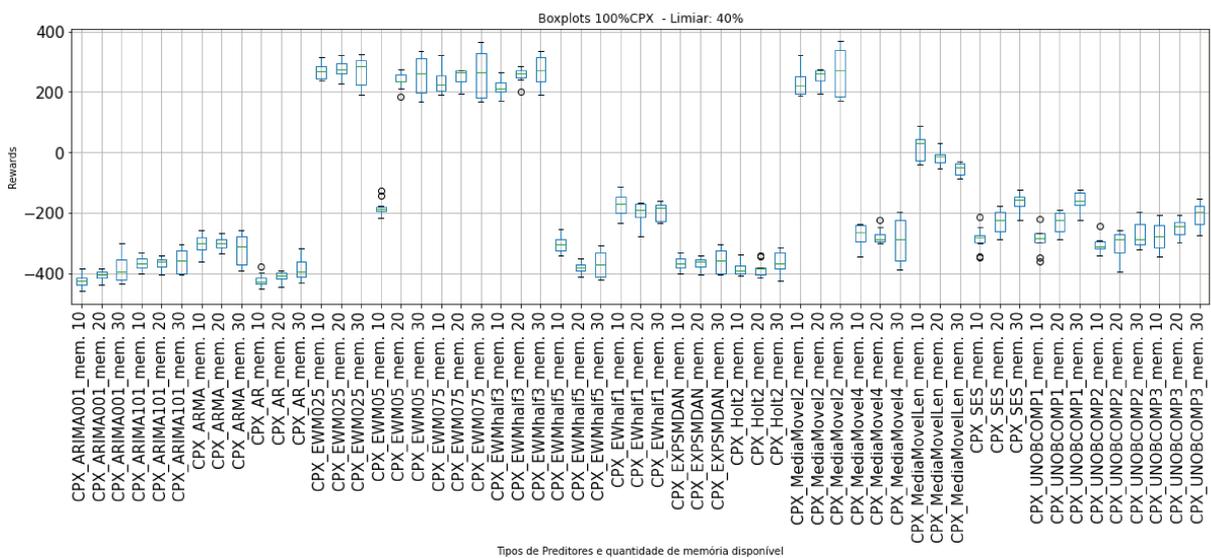


Figura 4.13: BoxPlots Rewards 100%CPX e Limiar 40%

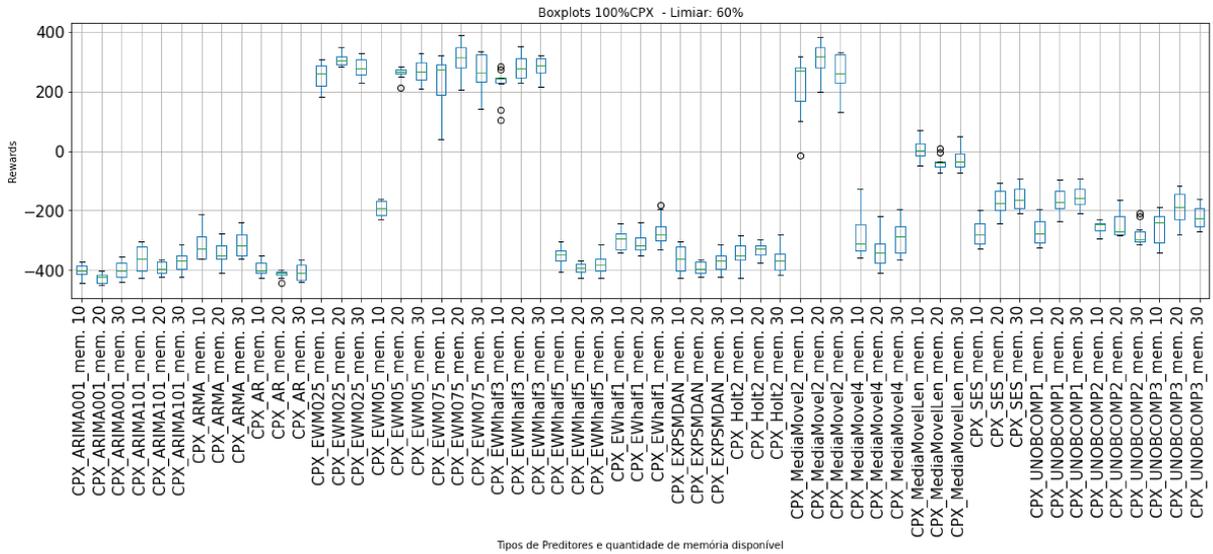


Figura 4.14: BoxPlots Rewards 100%CPX e Limiar 60%

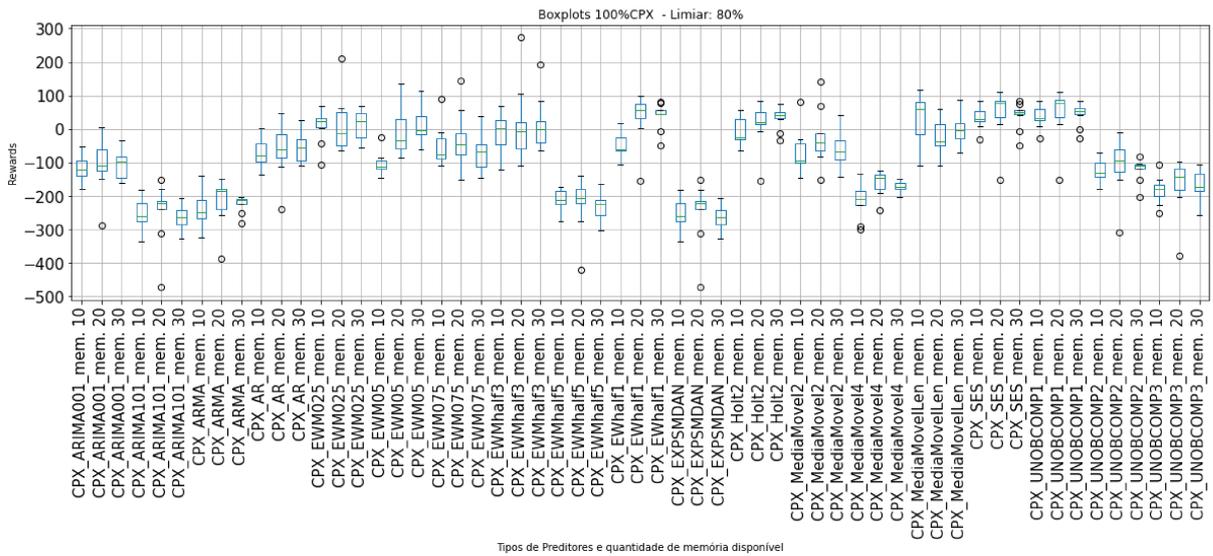


Figura 4.15: BoxPlots Rewards 100%CPX e Limiar 80%

Tabela 4.8: Estatística dos *Rewards* para os preditores 50% ZI e 50% CPX, com limiar de 80 %

Preditores Limiar: 80%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Complex_AR	178,22	168,0	163,75	0,329	H0	0,345	H0	0,799	H0
Complex_ARIMA001	171,56	160,0	155,56	0,374	H0	0,311	H0	0,797	H0
Complex_ARIMA101	36,67	24,44	26,6	0,567	H0	0,643	H0	0,936	H0
Complex_ARMA	-42,8	-74,67	-82,8	0,153	H0	0,048	H1	0,748	H0
Complex_EWM025	45,33	69,8	69,8	0,122	H0	0,183	H0	1,000	H0
Complex_EWM05	21,2	68,4	63,78	0,005	H1	0,019	H1	0,813	H0
Complex_EWM075	89,2	94,4	80,0	0,762	H0	0,665	H0	0,562	H0
Complex_EWMhalf3	109,2	93,8	88,44	0,636	H0	0,523	H0	0,780	H0
Complex_EWMhalf5	33,2	16,6	26,29	0,401	H0	0,731	H0	0,678	H0
Complex_EWhalf1	163,11	171,6	164,57	0,479	H0	0,936	H0	0,693	H0
Complex_EXPSMDAN	40,4	11,71	17,43	0,324	H0	0,363	H0	0,869	H0
Complex_Holt2	186,25	174,8	167,0	0,258	H0	0,124	H0	0,542	H0
Complex_MediaMovel2	88,89	100,6	87,78	0,502	H0	0,959	H0	0,602	H0
Complex_MediaMovel4	-77,0	-115,0	-136,89	0,196	H0	0,057	H0	0,406	H0
Complex_MediaMovelLen	69,0	64,0	88,2	0,847	H0	0,495	H0	0,313	H0
Complex_SES	173,6	173,78	166,0	0,986	H0	0,540	H0	0,565	H0
Complex_UNOBCOMP1	186,89	174,8	164,29	0,218	H0	0,184	H0	0,535	H0
Complex_UNOBCOMP2	163,78	124,6	139,8	0,049	H1	0,209	H0	0,500	H0
Complex_UNOBCOMP3	20,8	7,11	24,6	0,544	H0	0,850	H0	0,466	H0
Simple_Coin	-34,8	-30,6	-39,6	0,734	H0	0,674	H0	0,377	H0
Simple_ConstantDown	185,4	174,8	167,0	0,266	H0	0,126	H0	0,542	H0
Simple_ConstanteUP	-187,6	-176,8	-169,0	0,257	H0	0,123	H0	0,542	H0
Simple_DetectorCiclo1	-75,2	-115,0	-137,4	0,123	H0	0,019	H1	0,368	H0
Simple_DetectorCiclo2	40,6	24,2	93,6	0,708	H0	0,115	H0	0,076	H0
Simple_DetectorCiclo3	-49,6	66,0	-31,8	0,040	H1	0,615	H0	0,048	H1
Simple_DetectorCicloInvertido1	59,4	27,8	-17,2	0,612	H0	0,197	H0	0,333	H0
Simple_DetectorCicloInvertido2	43,4	54,6	72,4	0,776	H0	0,470	H0	0,543	H0
Simple_DetectorCicloInvertido3	-74,0	-20,6	-39,6	0,086	H0	0,199	H0	0,495	H0
Simple_Randômico	107,6	89,8	79,8	0,031	H1	0,016	H1	0,332	H0

- Os preditores com valores constantes possuem desempenho antagônico dependendo do limiar;
- Desempenho dos preditores são espelhados em relação ao limiar;
- Os preditores com comportamento *Simple\_Randomico* possuem bom desempenho em relação aos limiares de 20% e 80%;
- Já o preditor que simula o jogar de uma moeda possui um desempenho nulo, o que é esperado em relação à aleatoriedade;
- Pelos valores, não é possível aferir que o aumento da memória disponível melhore o desempenho dos preditores em relação aos *rewards*.

Os resultados encontrados neste experimento possibilitará em futuros trabalhos a inclusão de novos parâmetros como o nível de carga das bateria dos drones, taxa de consumo de bateria conforme o nível de trabalho pelo uso da Tabela 3.3 e pela variação dos valores

Tabela 4.9: Estatística dos *Rewards* para os preditores 100% CPX, com limiar de 20 %

Preditores Limiar: 20%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Complex_AR	-77,0	-58,0	-63,8	0,307	H0	0,475	H0	0,702	H0
Complex_ARIMA001	-110,2	-104,4	-104,0	0,727	H0	0,726	H0	0,975	H0
Complex_ARIMA101	-266,6	-260,8	-257,0	0,703	H0	0,589	H0	0,806	H0
Complex_ARMA	-261,2	-222,4	-217,8	0,077	H0	0,056	H0	0,779	H0
Complex_EWM025	33,6	-4,6	-17,4	0,118	H0	0,049	H1	0,553	H0
Complex_EWM05	-126,4	-24,8	-12,0	0,000	H1	0,000	H1	0,473	H0
Complex_EWM075	-32,4	-52,2	-46,8	0,531	H0	0,657	H0	0,775	H0
Complex_EWMhalf3	5,4	-18,2	-35,6	0,381	H0	0,124	H0	0,484	H0
Complex_EWMhalf5	-214,0	-220,8	-222,0	0,716	H0	0,697	H0	0,922	H0
Complex_EWhalf1	-4,6	5,6	12,4	0,507	H0	0,332	H0	0,655	H0
Complex_EXPSMDAN	-266,6	-260,8	-257,0	0,703	H0	0,589	H0	0,806	H0
Complex_Holt2	-25,0	21,8	31,2	0,007	H1	0,006	H1	0,533	H0
Complex_MediaMove12	-51,6	-56,0	-41,8	0,894	H0	0,770	H0	0,441	H0
Complex_MediaMove14	-227,0	-175,6	-179,2	0,044	H1	0,051	H0	0,785	H0
Complex_MediaMove1Len	-13,33	-27,4	-61,6	0,681	H0	0,186	H0	0,097	H0
Complex_SES	9,0	34,4	36,4	0,094	H0	0,155	H0	0,901	H0
Complex_UNOBCOMP1	9,6	35,0	40,0	0,103	H0	0,132	H0	0,767	H0
Complex_UNOBCOMP2	-125,4	-126,6	-119,4	0,924	H0	0,738	H0	0,695	H0
Complex_UNOBCOMP3	-187,2	-152,8	-129,2	0,107	H0	0,022	H1	0,310	H0

internos do Equilíbrio de Nash da tabela, alterar o comportamento interno (microscópico) dos drones.

Lembrando que essa análise, até o momento, não considera o desempenho macroscópico do sistema, como análise das médias dos valores do *attendance*.

## 4.2 Como o sistema se comporta alterando os parâmetros implementados neste modelo?

Nesta Seção, são estudados os comportamentos macroscópicos da simulação, relativos aos valores do histórico do *attendance*.

Para isto, foram realizados 108 experimentos, com 10 repetições. Os parâmetros foram descritos na Tabela 3.5.

O resultado esperado é um sumário estatístico dos valores dos históricos do *attendance*, que podem ser compilados na Tabela 4.13 e os gráficos *boxplots* que representam o resumo estatístico (média e desvio padrão) presentes na Figura 4.16. As Figuras 4.16a, 4.16b, 4.16c e 4.16d mostram tais resultados para todos os 27 casos, sendo que o conjunto de parâmetros são constituídos de três tipos de populações/agentes (100 %ZI, 50 %ZI & 50 %CPX, e 100 %CPX), três quantidades de memória disponíveis para os agentes (10, 20 e 30 semanas) e três tipo de

Tabela 4.10: Estatística dos *Rewards* para os preditores 100% CPX, com limiar de 40 %

Preditores Limiar: 40%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Complex_AR	-422,6	-410,0	-384,2	0,171	H0	0,018	H1	0,081	H0
Complex_ARIMA001	-422,8	-407,4	-383,8	0,107	H0	0,031	H1	0,159	H0
Complex_ARIMA101	-366,0	-366,2	-359,0	0,983	H0	0,638	H0	0,624	H0
Complex_ARMA	-302,8	-301,0	-320,2	0,879	H0	0,367	H0	0,285	H0
Complex_EWM025	269,4	275,0	268,2	0,653	H0	0,949	H0	0,713	H0
Complex_EWM05	-182,4	239,0	254,4	0,000	H1	0,000	H1	0,487	H0
Complex_EWM075	236,0	251,4	262,2	0,326	H0	0,363	H0	0,686	H0
Complex_EWMhalf3	214,2	256,6	268,8	0,001	H1	0,013	H1	0,524	H0
Complex_EWMhalf5	-301,4	-381,4	-370,0	0,000	H1	0,001	H1	0,462	H0
Complex_EWhalf1	-172,0	-197,8	-194,6	0,135	H0	0,165	H0	0,824	H0
Complex_EXPSMDAN	-366,0	-366,2	-359,0	0,983	H0	0,638	H0	0,624	H0
Complex_Holt2	-384,2	-383,0	-361,4	0,909	H0	0,102	H0	0,128	H0
Complex_MediaMove12	229,4	251,4	266,0	0,191	H0	0,219	H0	0,589	H0
Complex_MediaMove14	-272,8	-277,0	-290,0	0,770	H0	0,510	H0	0,599	H0
Complex_MediaMoveLen	16,2	-15,4	-54,2	0,065	H0	0,000	H1	0,002	H1
Complex_SES	-284,4	-228,6	-160,4	0,006	H1	0,000	H1	0,000	H1
Complex_UNOBCOMP1	-289,33	-232,0	-159,2	0,007	H1	0,000	H1	0,000	H1
Complex_UNOBCOMP2	-305,0	-305,8	-272,4	0,963	H0	0,068	H0	0,120	H0
Complex_UNOBCOMP3	-278,0	-248,4	-205,6	0,111	H0	0,002	H1	0,016	H1

políticas (política 1, 2 ou 3) para os quatro limiares (20%, 40%, 60%, e 80%). As linhas verticais vermelhas representam a divisão entre os três tipos de populações.

Observando os dados presentes na Figura 4.16, verifica-se que os agentes que possuem preditores CPX em sua constituição têm melhor desempenho em relação aos resultados. Seus valores médios do *attendance* são mais próximo dos limiares em todos os casos, o que apenas acontece com os preditores ZI em relação ao uso da política 2.

Em relação ao efeito do uso de mais ou menos a quantidade de memória, não são observadas variações significativas nas populações 100%ZI e 50% ZI & 50% CPX em relação aos valores médios encontrados na simulação. Desta forma, pode-se concluir que a quantidade de informação disponível para os agentes tomarem sua decisão não tem, ou pouco tem, influência na performance macroscópica do sistema. Já nas populações 100%ZI observa-se que o aumento da quantidade de informação disponível permitiu melhoria significativa no desempenho, principalmente para os limiares de 40% e de 60%.

Em relação às políticas, observa-se maior influência das mesmas em relação aos agentes que são constituídos com preditores ZI (sendo as políticas 1 e 3 com grande variações com essas políticas), conforme observado na Figura 4.16, sendo observado menor influência do tipo de política ao utilizar preditores CPX.

Em relação ao desvio padrão é observado que a Política 2 tem menor taxa de variação nas populações que contêm apenas ZI e mista, e a maior variação na população naquela que

Tabela 4.11: Estatística dos *Rewards* para os preditores 100% CPX, com limiar de 60 %

Preditores Limiar: 60%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Complex_AR	-392,0	-413,0	-405,2	0,038	H1	0,292	H0	0,450	H0
Complex_ARIMA001	-402,4	-426,2	-400,8	0,019	H1	0,895	H0	0,034	H1
Complex_ARIMA101	-361,6	-392,2	-370,0	0,071	H0	0,636	H0	0,084	H0
Complex_ARMA	-311,78	-343,0	-312,8	0,165	H0	0,964	H0	0,112	H0
Complex_EWM025	249,8	307,2	278,0	0,003	H1	0,133	H0	0,032	H1
Complex_EWM05	-193,2	261,8	267,8	0,000	H1	0,000	H1	0,666	H0
Complex_EWM075	232,6	309,6	264,2	0,037	H1	0,385	H0	0,105	H0
Complex_EWMhalf3	222,6	283,4	282,6	0,016	H1	0,013	H1	0,964	H0
Complex_EWMhalf5	-348,6	-393,6	-378,8	0,001	H1	0,044	H1	0,231	H0
Complex_EWhalf1	-298,6	-309,4	-268,2	0,479	H0	0,120	H0	0,041	H1
Complex_EXPSMDAN	-361,6	-392,2	-370,0	0,071	H0	0,636	H0	0,084	H0
Complex_Holt2	-346,2	-330,6	-363,6	0,323	H0	0,373	H0	0,052	H0
Complex_MediaMovel2	218,8	309,2	262,4	0,033	H1	0,295	H0	0,104	H0
Complex_MediaMovel4	-281,4	-338,6	-292,8	0,070	H0	0,706	H0	0,086	H0
Complex_MediaMovelLen	3,8	-39,6	-27,8	0,008	H1	0,068	H0	0,412	H0
Complex_SES	-273,4	-170,0	-159,0	0,000	H1	0,000	H1	0,573	H0
Complex_UNOBCOMP1	-268,0	-164,8	-151,4	0,000	H1	0,000	H1	0,475	H0
Complex_UNOBCOMP2	-254,75	-245,8	-280,8	0,590	H0	0,085	H0	0,079	H0
Complex_UNOBCOMP3	-255,56	-190,8	-219,4	0,019	H1	0,120	H0	0,196	H0

contém apenas CPX. Outra observação é que a política 1 possui os melhores resultados com os preditores CPX, possivelmente devido a não ocorrer trocas de preditores durante a simulação.

### 4.3 Como utilizar o PEFB em uma analogia para simular as recargas de baterias para um enxame de drones?

A Subseção 3.3.3 descreve o procedimento para a criação de uma analogia entre o PEFB e a coordenação do carregamento/re-carregamento de um enxame de drones. A partir das 108 variantes de simulação, variando os parâmetros descritos na Tabela 3.5.

Os resultados obtidos para essa simulação são os descritos a seguir:

- Valores médios e desvio padrão do *attendance* para cada conjunto dos parâmetros (resultados já descritos na Seção 4.2);
- Percentual de vezes que ocorreu o recarregamento em cada caso (Valores do *attendance* menor do que o limiar).

Para essa analogia, um bom modelo deve conter os seguintes resultados:

- Os valores médios do *attendance* devem ser próximos dos valores de cada limiar, para que não ocorra subutilização do sistema (se poucos agentes forem, o carregador (bar) vai

Tabela 4.12: Estatística dos *Rewards* para os preditores 100% CPX, com limiar de 80 %

Preditores Limiar: 80%	Mem. 10	Mem. 20	Mem. 30	10-20		10-30		20-30	
	Média	Média	Média	p-val.	Hipót.	p-val.	Hipót.	p-val.	Hipót.
Complex_AR	-71,0	-60,2	-55,4	0,710	H0	0,439	H0	0,871	H0
Complex_ARIMA001	-116,6	-103,4	-105,2	0,650	H0	0,542	H0	0,952	H0
Complex_ARIMA101	-253,2	-246,6	-265,6	0,837	H0	0,504	H0	0,547	H0
Complex_ARMA	-243,2	-212,8	-222,8	0,296	H0	0,299	H0	0,681	H0
Complex_EWM025	8,6	13,6	12,2	0,873	H0	0,866	H0	0,963	H0
Complex_EWM05	-102,2	-5,8	9,6	0,002	H1	0,000	H1	0,594	H0
Complex_EWM075	-53,6	-30,0	-68,8	0,476	H0	0,570	H0	0,239	H0
Complex_EWMhalf3	-11,8	12,0	12,8	0,566	H0	0,451	H0	0,985	H0
Complex_EWMhalf5	-209,2	-221,2	-232,4	0,663	H0	0,159	H0	0,695	H0
Complex_EWhalf1	-47,2	36,6	39,2	0,006	H1	0,000	H1	0,922	H0
Complex_EXPSMDAN	-253,2	-246,8	-265,6	0,842	H0	0,504	H0	0,550	H0
Complex_Holt2	-6,8	15,78	34,0	0,410	H0	0,026	H1	0,490	H0
Complex_MediaMove12	-69,2	-25,4	-60,0	0,199	H0	0,730	H0	0,277	H0
Complex_MediaMove14	-213,0	-161,25	-172,0	0,028	H1	0,035	H1	0,488	H0
Complex_MediaMove1Len	32,4	-25,56	-1,8	0,075	H0	0,259	H0	0,337	H0
Complex_SES	32,8	46,6	41,0	0,604	H0	0,613	H0	0,838	H0
Complex_UNOBCOMP1	36,4	47,6	45,4	0,676	H0	0,558	H0	0,935	H0
Complex_UNOBCOMP2	-123,2	-104,8	-121,33	0,533	H0	0,907	H0	0,580	H0
Complex_UNOBCOMP3	-182,8	-166,0	-168,8	0,570	H0	0,481	H0	0,926	H0

ficar ocioso e subutilizado) e se muitos drones forem, não ocorrerá a carga ou a recarga devido ao sobrecarregamento. O equilíbrio de *Nash* é esperado nesse caso e as simulações baseadas em agentes, em específico o Modelo do Problema *El Farol Bar* consegue simular bem esse comportamento. A Tabela 4.13 e a Figura 4.16, junto com a conclusão da Seção 4.2 já responderam essa questão;

- É avaliado qual conjunto dos parâmetros provém melhor taxa de abastecimento, ou seja, quais conjuntos que garantem a maior frequência de valores do *attendance* abaixo de cada limiar. A Tabela 4.14, junto com a Figura 4.17 contêm os dados para esse item.

A Tabela 4.14 e a Figura 4.17 resumizam os resultados da probabilidade de carga ou de recarga para os limiares de 20%, 40%, 60%, e 80% de forma tabular e gráfica. Em relação à Figura 4.17, assim como a Figura 4.16, também é subdividida em quadro figuras, mas a Figura 4.17 apresenta as probabilidades, ou melhor, a média das quantidades de vezes em que ocorram a carga ou a recarga da bateria dos drones. Já em relação ao eixo x, são representados os 27 conjuntos de parâmetros (tipos de populações/agentes (100 %ZI, 50 %ZI & 50 %CPX, e 100 %CPX), quantidades de memória disponíveis (10, 20 e 30 semanas) e tipo de políticas (política 1, 2 ou 3). As linhas verticais vermelhas representam a divisão entre os três tipos de populações.

A primeira conclusão é que a memória não possui efeito proeminentes nos resultados macroscópicos desta simulação. Sendo assim, uma menor quantidade de memória seria

Tabela 4.13: Resumo estatísticos (média e desvio padrão) dos valores médios dos *attendance* para as simulações

Conjunto de Parâmetros	Valor Médio				Desvio padrão			
	20	40	60	80	20	40	60	80
100%ZI Mem.10 Pol. 1	29,22	44,03	55,75	71,96	9,14	12,14	13,48	8,24
Mem.10 Pol. 2	22,14	40,05	59,94	78,23	6,11	4,59	4,52	6,09
Mem.10 Pol. 3	26,79	44,11	60,97	77,48	22,10	25,68	24,80	19,17
Mem.20 Pol. 1	28,93	44,53	56,64	72,50	8,13	11,80	11,96	7,82
Mem.20 Pol. 2	21,37	40,12	59,86	78,80	5,89	4,42	4,61	6,26
Mem.20 Pol. 3	26,90	44,05	61,03	77,34	22,95	25,14	24,57	20,26
Mem.30 Pol. 1	29,29	44,24	56,34	71,23	8,55	12,52	12,23	9,43
Mem.30 Pol. 2	22,15	39,93	59,87	78,18	6,30	4,59	4,70	6,53
Mem.30 Pol. 3	26,75	43,86	60,94	77,38	23,02	25,59	25,10	20,29
50% ZI50% CPX Mem.10 Pol. 1	24,75	41,33	58,52	75,49	8,07	11,95	11,66	8,90
Mem.10 Pol. 2	21,94	41,64	58,32	78,33	7,85	10,52	12,12	7,15
Mem.10 Pol. 3	22,70	41,13	59,63	77,96	12,30	15,18	16,60	13,75
Mem.20 Pol. 1	24,29	40,96	58,88	76,27	7,77	9,64	10,14	7,67
Mem.20 Pol. 2	21,52	40,85	59,08	78,50	6,46	10,99	9,91	6,49
Mem.20 Pol. 3	22,35	40,89	59,77	78,53	11,82	14,46	14,44	12,32
Mem.30 Pol. 1	24,03	40,98	59,15	75,92	7,81	10,45	10,41	8,11
Mem.30 Pol. 2	21,61	40,61	59,35	78,46	6,83	9,26	10,25	6,68
Mem.30 Pol. 3	22,00	40,80	59,96	78,75	10,69	13,35	13,17	11,79
100%CPX Mem.10 Pol. 1	23,84	41,00	58,42	76,32	15,05	19,12	21,13	15,78
Mem.10 Pol. 2	23,78	40,75	58,30	76,02	31,34	35,24	35,13	31,24
Mem.10 Pol. 3	23,48	41,10	58,68	76,16	22,30	27,09	26,65	23,75
Mem.20 Pol. 1	23,25	40,57	59,06	76,76	13,56	15,95	17,37	13,92
Mem.20 Pol. 2	21,55	40,38	59,34	78,24	24,56	31,88	32,03	25,19
Mem.20 Pol. 3	22,10	40,55	59,26	77,70	19,30	21,85	21,73	19,21
Mem.30 Pol. 1	23,36	40,40	59,44	76,76	14,17	15,17	15,42	13,68
Mem.30 Pol. 2	21,19	40,31	59,57	78,70	22,89	32,66	32,57	23,95
Mem.30 Pol. 3	21,72	40,38	59,46	78,06	17,50	19,93	19,61	18,07

interessante devido à menor quantidade de processamento para arquivar e processar mais dados, resultando em uma redução do consumo de bateria por parte dos drones.

Sobre o tipo de população (ZI ou CPX) existem dois tipos de comportamentos, com os limiares de 20% e de 40% é possível verificar que os preditores CPX possuem melhor desempenho de forma global e de forma estável, sendo por exemplo, no caso do limiar de 20%, os agentes ZI possuem um dos melhores (política 2) os piores (política 1) resultados da probabilidade de abastecimento. Nos casos de limiares de 60% e 80% o desempenho dos agentes é mais balanceada.

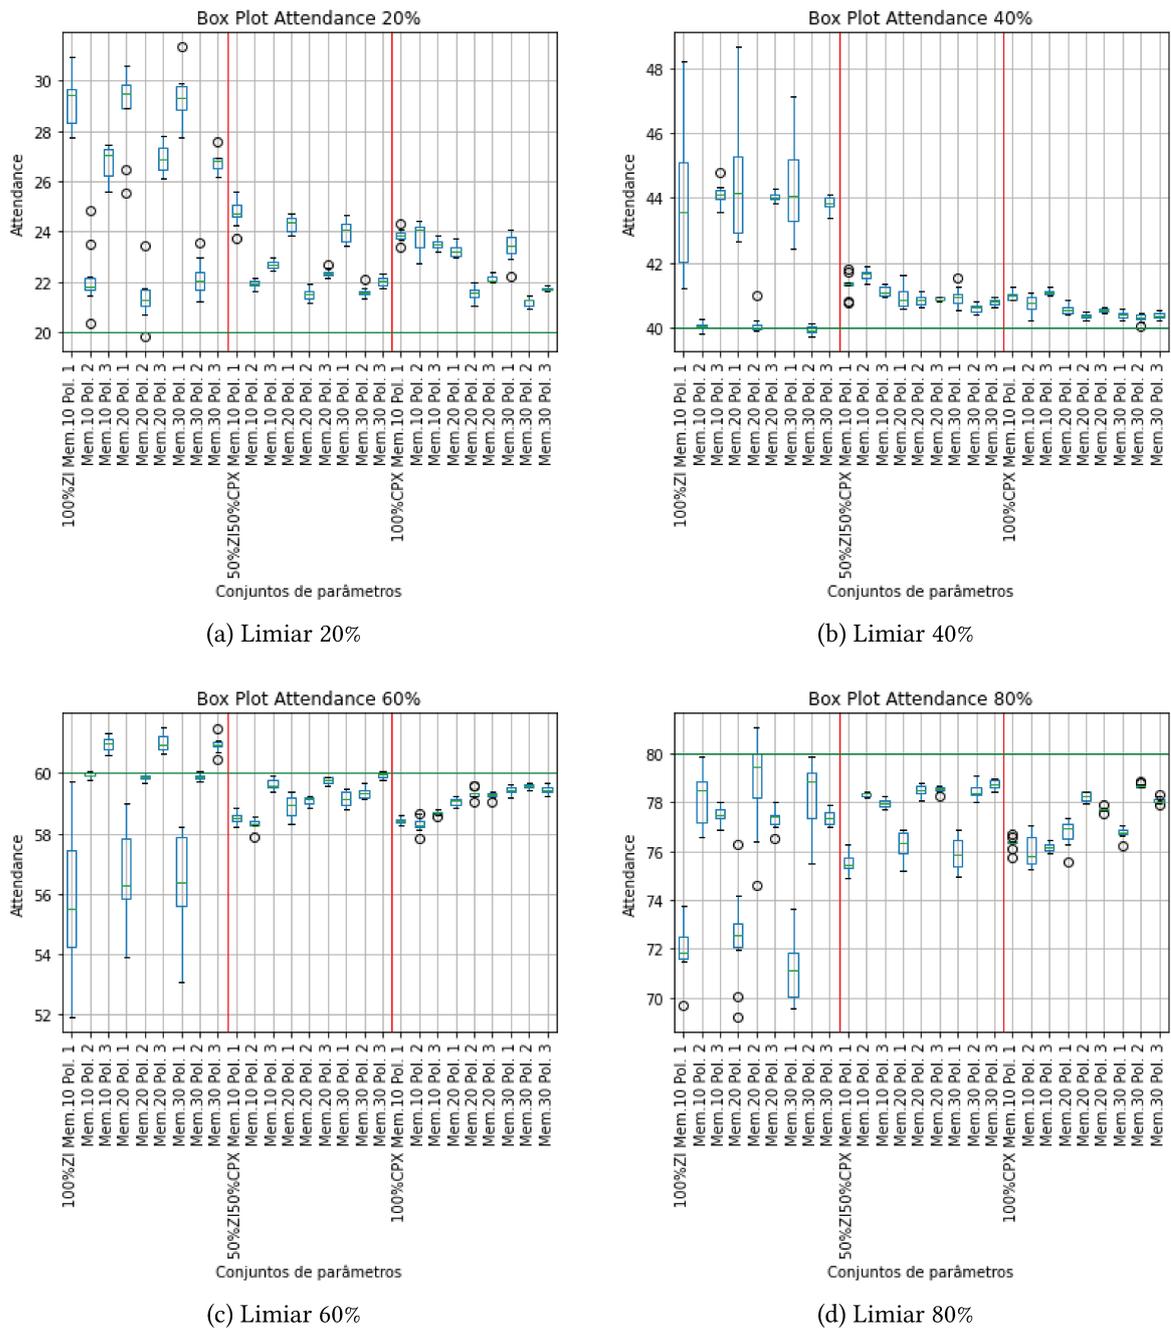


Figura 4.16: *Boxplots* dos valores do *Attendance* para todos limiares

Outra observação é que os drones CPX possuem melhor desempenho utilizando as políticas 2 e 3, mostrando que esse tipo de população tem melhor comportamento quando o mesmo possui mais preditores por agentes.

Os resultados descritos mostram os melhores conjuntos de simulação que otimizam os dois objetivos citados. O Equilíbrio de Nash é procurado para que não haja subutilização do sistema (os drones deixam de ir ao bar), nem superutilização, onde os drones não recarregam pois o sistema está cheio.

Tabela 4.14: Média das probabilidades de recarga dos drones para cada conjunto de parâmetros

Conjunto de Parâmetros	Valor Médio			
	20	40	60	80
100%ZI Mem.10 Pol. 1	17,43	40,94	56,97	78,92
Mem.10 Pol. 2	34,97	45,89	46,05	56,53
Mem.10 Pol. 3	45,63	47,31	46,15	45,73
Mem.20 Pol. 1	15,27	40,80	55,47	79,94
Mem.20 Pol. 2	34,25	47,58	45,87	70,26
Mem.20 Pol. 3	52,46	46,37	45,61	39,76
Mem.30 Pol. 1	15,99	39,44	57,25	75,75
Mem.30 Pol. 2	33,11	43,63	45,45	66,49
Mem.30 Pol. 3	53,69	51,62	42,91	38,86
50%ZI50%CPX Mem.10 Pol. 1	28,38	48,82	45,63	64,15
Mem.10 Pol. 2	46,31	57,17	39,04	39,80
Mem.10 Pol. 3	45,81	49,00	47,94	48,86
Mem.20 Pol. 1	29,42	47,62	46,41	63,05
Mem.20 Pol. 2	46,31	56,09	38,82	41,76
Mem.20 Pol. 3	47,27	48,92	48,52	47,66
Mem.30 Pol. 1	31,20	47,39	48,84	61,70
Mem.30 Pol. 2	45,73	50,36	36,69	41,36
Mem.30 Pol. 3	45,87	49,20	47,88	46,89
100%CPX Mem.10 Pol. 1	45,55	55,63	43,87	51,96
Mem.10 Pol. 2	66,85	60,70	41,06	34,29
Mem.10 Pol. 3	51,78	50,24	48,60	45,65
Mem.20 Pol. 1	42,18	56,65	44,15	51,96
Mem.20 Pol. 2	65,27	59,58	38,42	32,51
Mem.20 Pol. 3	52,04	48,40	50,16	48,02
Mem.30 Pol. 1	43,85	53,35	43,33	51,54
Mem.30 Pol. 2	63,27	59,18	38,06	30,32
Mem.30 Pol. 3	51,02	48,04	49,42	47,41

Foram encontrados vários conjuntos onde a probabilidade de recarga ficou acima de 50%. Esse fenômeno permite identificar que tal analogia poderá ser útil para o sucesso da aplicação (recarga dos drones e poucas posições não utilizadas de recargas).

Pela observação dos resultados, é possível relacionar que os preditores de baixa complexidade possuem melhores desempenhos se a quantidade de estações de recargas é superior (maior de 50%). Tal resultado é esperado, pois os preditores CPX utilizam mais recursos computacionais e matemáticos para efetuar a predição, desta forma atuando melhor em situações com poucos recursos. Interessante também que, dependendo do limiar, a política utilizada é variável conforme o valor do limiar.

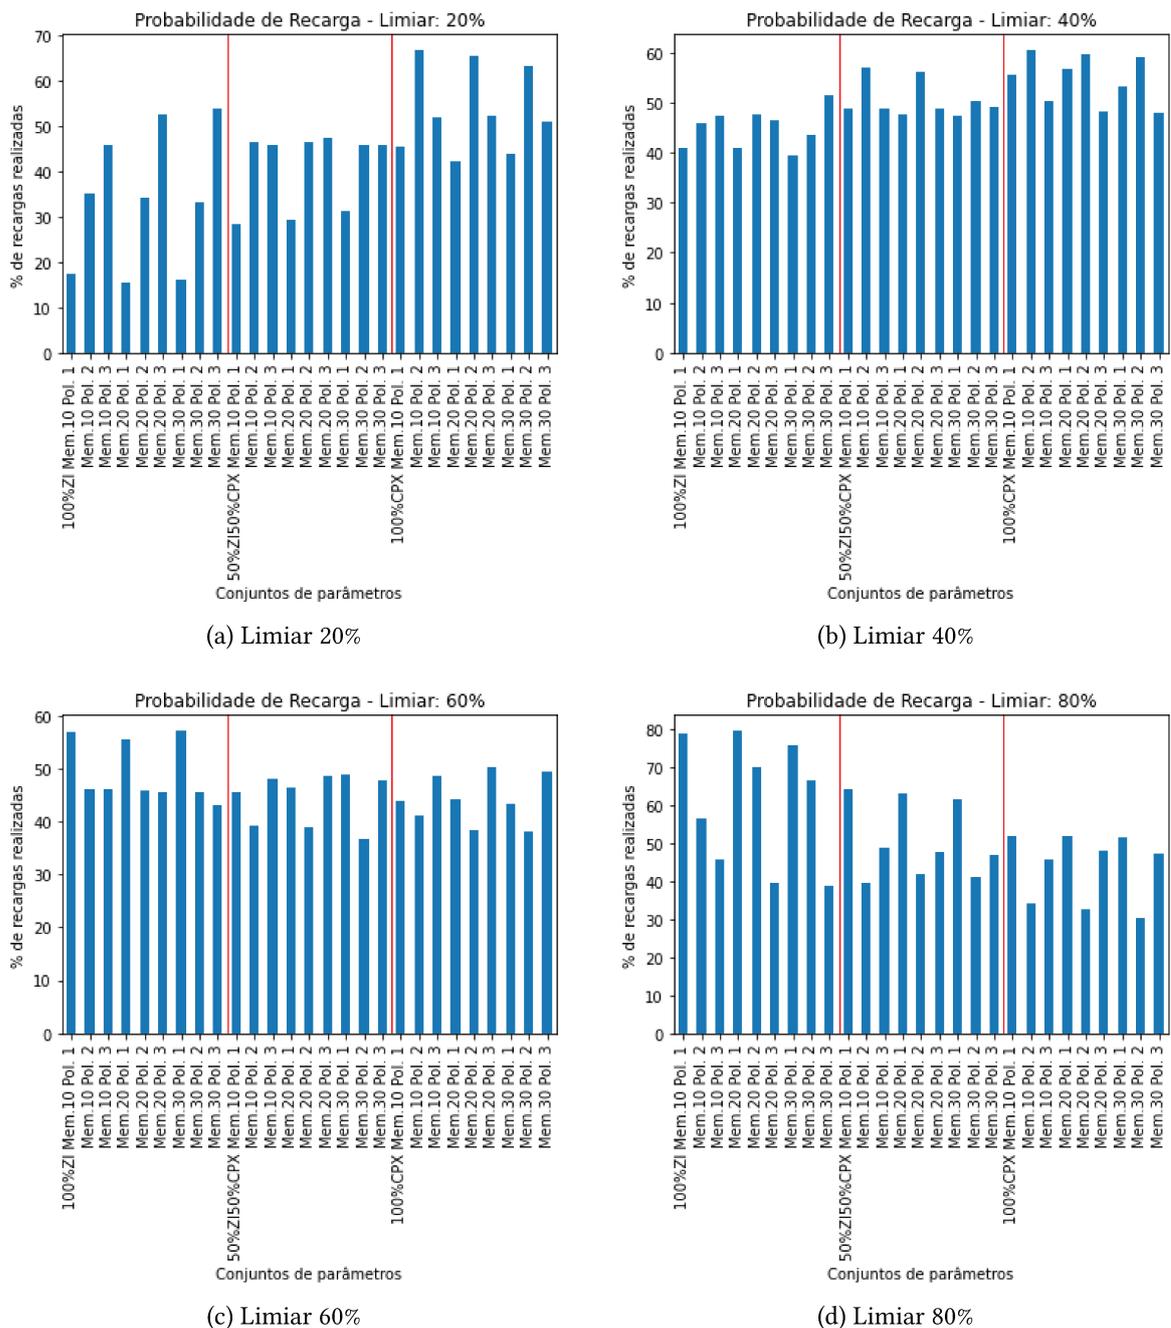


Figura 4.17: Probabilidades de recargas (valores menores do que o limiar).

De forma geral, podem-se elaborar alguns comentários finais referentes aos resultados obtidos:

- A política 2 possui grande desempenho devido à sua característica que permite uma evolução (apenas o melhor preditor irá ser escolhido) e em relação à diversidade em relação à política 1, devido a maior probabilidade de sorteio de preditores entre os agentes;

- A política 3 tem grande desempenho também, mas em certos casos, devido a existência de preditores de baixo desempenho, o que pode influenciar o resultado do modelo de forma geral;
- Para este problema, é esperado que os conjuntos de preditores proporcionem valores de *attendance* menores que o limiar. É observado que os agentes CPX possuem melhor desempenho devido aos valores obtidos estarem próximos do limiar e menor dispersão. Em relação à população ZI, o uso da política 2 também proporciona bons resultados relativos ;
- As análises dos resultados macroscópicos e as subseções 4.2 e 4.3, estão correlacionadas de forma direta;
- São observados que os tipos de políticas e de população possuem mais influência nos resultados finais do que a quantidade de memória (quantidade de informação armazenada e utilizada pelos preditores para a tomada de decisão) nos resultados macroscópicos deste estudo.

Uma outra vantagem na utilização deste modelo é o fato de não haver comunicação entre os drones em relação à coordenação de recarga das baterias, reduzindo assim o consumo desnecessário de baterias devido a essa comunicação, lembrando que outras comunicações podem ocorrer entre drones, mas para outras finalidades.

# Capítulo 5

## Conclusões

Este capítulo será dividido entre as conclusões baseadas nos resultados encontrados, as questões norteadoras deste trabalho e as propostas de trabalhos futuros.

### 5.1 Resultados finais e questões norteadoras

Neste capítulo são descritas conclusões relacionadas às três questões norteadoras deste trabalho.

#### 5.1.1 Como os aspectos microscópicos deste modelo podem ser utilizados em futuros parâmetros da simulação?

Este experimento mostrou as possibilidades da utilização do indicador *Rewards* para uso futuro de novos parâmetros para a simulação. Observou-se que algumas configurações de parâmetros possuem melhor desempenho e que a variação do parâmetro relativo à quantidade de informação disponível para os preditores pouco interfere nos resultados.

Pelos resultados, observa-se a facilidade de controle e monitoramento dos resultados microscópicos dos agentes. Itens como quantidade de carga da bateria, perfis de trabalho serão facilmente incorporados neste modelo.

### **5.1.2 Como o sistema se comporta alterando os parâmetros implementados neste modelo?**

Observou-se que alguns parâmetros possuem influência no desempenho final do experimento, tais como: os tipos de preditores, as composições dos tipos de agentes e as políticas empregadas. No entanto, a quantidade de informação disponível (memória) não mostrou grande influência no desempenho final.

Em relação ao principal objetivo deste trabalho que consiste na utilização do equilíbrio de Nash para melhorar estações de recarga de drones, pode-se dizer que obtivemos os melhores resultados em relação aos demais parâmetros estipulados para a simulação.

No texto são mostrados os conjuntos com melhores desempenhos em relação ao equilíbrio de Nash, considerando as políticas aplicadas. Foram encontrados vários conjuntos com alto valor relativo de probabilidade de sucesso para esse tipo de problema, que é maior do que 50%. Esse fenômeno permite grande incidência de sucesso na taxa de recarga dos drones e também que não ocorra grande quantidade de posições vazias no carregador (bar).

Em relação à complexidade dos preditores, os resultados obtidos estão relacionados com a quantidade (limiar) de posições disponíveis. Quando o número de posições é relativamente alto (mais do que 50 % do valor total do enxame), os agentes com preditores mais simples (ZI) possuem melhores resultados do que os mais complexos. Em ambientes mais restritos, os agentes com preditores mais complexos (CPX) possuem melhores desempenho. Tais resultados são esperados porque preditores mais complexos têm maior capacidade de tomada de decisão, trabalhando melhor nessas situações.

### **5.1.3 Como utilizar o PEFB em uma analogia para simular as recargas de baterias para um enxame de drones?**

Os resultados da simulação também mostraram que a quantidade disponível para a tomada de decisão dos preditores (memória disponível relacionada com o histórico de recargas bem ou mal sucedidas), possui pouca importância relativa. Usando pelo menos os 10 últimos valores do histórico de recarga, possuem resultados similares ao uso de 20 ou 30 valores retroativos. Dessa forma, é observado um possível ganho no desempenho do consumo de baterias, pois a menor quantidade de memória está correlacionada com menor quantidade de consumo de recursos computacionais, devido ao menor armazenamento e processamento.

Uma outra vantagem deste modelo é que o mesmo não necessita de comunicação entre os drones em relação à coordenação de recargas, evitando o consumo de bateria dos drones devido à ausência dessa comunicação (observar que outras comunicações são passíveis de ocorrerem).

Algumas contribuições adicionais deste trabalho podem ser citadas:

- Uso de apenas ferramentas de código aberto para a execução da simulação (*Netlogo* e *Python*) e análise de dados (*Python*);
- Uso de código *Python* dentro do *Netlogo* via uma extensão desenvolvida para o *Netlogo* por (HEAD, 2017), proporcionando o desenvolvimento de uma metodologia e expandindo as possibilidades para futuros trabalhos;
- Desenvolvimento de um modelo remixado do Problema *El Farol Bar* com o uso de diferentes formas de parâmetros;
- Uso de diferentes tipos de preditores, dividindo os agentes em formas de populações, quantidades de memórias variadas, e tipos de políticas (para a escolha de melhores preditores de acordo com os objetivos traçados) e para variados limiares;
- Modelagem do PEFB como uma forma de simular o processo de recarga de um enxame de drones, aproveitando a característica que o modelo tem em relação ao Equilíbrio de Nash.

Mais do que os resultados obtidos, este trabalho buscou o desenvolvimento de uma metodologia para permitir a utilização de modelos baseados em agentes para este problema.

Para obter melhores resultados, observa-se a necessidade de ajustes para uma melhora no desempenho da taxa de abastecimento, mas novos parâmetros e formas de coordenação podem ser pensadas em trabalhos posteriores, conforme descrito a seguir na Subseção 5.2.

## 5.2 Trabalhos Futuros

Seguem sugestões de trabalhos futuros:

Em relação ao modelo PEFB, são sugeridas algumas melhorias em relação a este trabalho:

- Modificar a forma de cálculo dos *rewards*, alterando a tabela de acertos;
- Incluir os *rewards* como forma de tomada de decisão para os melhores preditores;

- Incluir novos tipos de preditores;
- Incluir novas formas de políticas, com apoio de rede neurais, aprendizado por reforço, lógica difusa, etc.

Em relação à analogia do processo de coordenação de recargas de drones, são sugeridos:

- Incluir novos parâmetros nos agentes, tais como consumo de bateria, capacidade de bateria e perfis de trabalho para melhorar a escolha dos instantes para recarga;
- Desenvolver a capacidade de inclusão de novos drones conforme ocorra a inoperatividade dos drones atuais (por exemplo: inanição, quebra operacional, falta de bateria, etc.);
- Buscas de referências aos parâmetros técnicos e de voo reais para inclusão na simulação. Poderiam ser incluídos suprimentos individuais de recarga para os drones em vez de recarga de todo o enxame de uma única vez;
- Incluir a possibilidade de considerar a troca rápida de bateria em vez de apenas a recarga das baterias dos drones.
- Inclusão de novas políticas para a escolha dos melhores preditores.

## Referências bibliográficas

- ABIDIN, Z. Z.; ARSHAD, M. R.; NGAH, U. K. An introduction to swarming robotics: application development trends. *Artificial Intelligence Review*, v. 43, n. 4, p. 501–514, 2015. ISSN: 15737462. DOI: 10.1007/s10462-013-9397-8.
- ARTHUR, W. B. Inductive reasoning and bounded rationality. *American economic review*, American Economic Association, v. 84, n. 2, p. 406–411, 1994.
- BACCAN, D. D.; MACEDO, L. Revisiting the El Farol Problem: A Cognitive Modeling Approach. In: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. [S.l.: s.n.], 2013. v. 7838, p. 56–68. DOI: 10.1007/978-3-642-38859-0{\\_}5.
- BELL, A. M.; SETHARES, W. A. The {E}l {F}arol Problem and the Internet: Congestion and Coordination Failure. In: *Fifth International Conference of the Society for Computational Economics*. [S.l.: s.n.], 1999.
- BOGGIO-DANDRY, A.; SOYATA, T. Perpetual Flight for UAV Drone Swarms Using Continuous Energy Replenishment. *2018 9th IEEE Annual Ubiquitous Computing, Electronics and Mobile Communication Conference, UEMCON 2018*, p. 478–484, 2018. DOI: 10.1109/UEMCON.2018.8796684.
- CARA, M. de; PLA, O.; GUINEA, F. Competition, efficiency and collective behavior in the “El Farol” bar model. *The European Physical Journal B*, EDP Sciences, v. 10, n. 1, p. 187–191, jul. 1999. ISSN: 1434-6028. DOI: 10.1007/s100510050843.
- CARABALLO, L.-E. et al. Autonomous Planning for Multiple Aerial Cinematographers. Section V, 2020. Disponível em: <<http://arxiv.org/abs/2005.07237>>.
- CHAKRABORTI, A. et al. Statistical mechanics of competitive resource allocation using agent-based models. *Physics Reports*, v. 552, p. 1–25, 2015. DOI: 10.1016/j.physrep.2014.09.006.
- CHALLET, D.; ZHANG, Y.-C. Emergence of cooperation and organization in an evolutionary game. *ELSEVIER Physica A*, v. 246, n. 407, 1997.
- CHALLET, D.; MARSILI, M.; OTTINO, G. Shedding light on El Farol. *Physica A: Statistical Mechanics and its Applications*, v. 332, n. 1-4, p. 469–482, 2004. DOI: 10.1016/j.physa.2003.06.003.
- CHALLET, D.; MARSILI, M.; ZHANG, Y.-C. Modeling market mechanism with minority game. *Physica A*, v. 276, p. 284–315, 2000.

- CHEN, S.; LV, G.; WANG, X. Offensive strategy in the 2D soccer simulation league using multi-group ant colony optimization. *International Journal of Advanced Robotic Systems*, v. 13, n. 1, 2016. ISSN: 17298814. DOI: 10.5772/62167.
- CHEN, S. H.; GOSTOLI, U. On the complexity of the El Farol Bar game: a sensitivity analysis. *Evolutionary Intelligence*, v. 9, n. 4, p. 113–123, 2016. DOI: 10.1007/s12065-016-0138-1.
- CHEN, S.-H.; GOSTOLI, U. Coordination in the El Farol Bar problem: The role of social preferences and social networks. *Journal of Economic Interaction and Coordination*, v. 12, p. 59–93, 2015. DOI: 10.1007/s11403-015-0150-z.
- COLLINS, A. J. Strategically forming groups in the El farol bar problem. *ACM International Conference Proceeding Series*, 2017. DOI: 10.1145/3145574.3145575.
- DE CARA, M. A.; PLA, O.; GUINEA, F. Competition, efficiency and collective behavior in the "El Farol" bar model. *European Physical Journal B*, v. 10, n. 1, p. 187–191, 1999. ISSN: 14346028. DOI: 10.1007/s100510050843. arXiv: 9811162v2 [cond-mat].
- DUFFY, J. AGENT-BASED MODELS AND HUMAN SUBJECT EXPERIMENTS. v. 2, n. 05, 2006. DOI: 10.1016/S1574-0021(05)02019-8.
- DURBIN, J.; KOOPMAN, S. J. *Time Series Analysis by State Space Methods*. Edição de Oxford University Press. 2nd. [S.l.: s.n.], 2012. p. 368.
- EDMONDS, B. Gossip, Sexual Recombination and the El Farol Bar: Modelling the Emergence of Heterogeneity. *IFAC Proceedings Volumes*, Elsevier, v. 31, n. 16, p. 219–224, jun. 1998. ISSN: 1474-6670. DOI: 10.1016/S1474-6670(17)40485-X.
- EREV, I.; ROTH, A. E. Predicting How People Play Games: Reinforcement Learning in Experimental Games with Unique, Mixed Strategy Equilibria. *American Economic Review*, v. 88, n. 4, p. 848–881, 1998. ISSN: 00028282. DOI: 10.2307/117009.
- FOGEL, D. B.; CHELLAPILLA, K.; ANGELINE, P. J. Inductive reasoning and bounded rationality reconsidered. *IEEE Transactions on Evolutionary Computation*, v. 3, n. 2, p. 142–146, 1999. DOI: 10.1109/4235.771167.
- FOMBY, T. The Unobservable Components Model, p. 1–42, 2008.
- FRANKE, R. Reinforcement learning in the El Farol model. *Journal of Economic Behavior & Organization*, North-Holland, v. 51, n. 3, p. 367–388, jul. 2003. ISSN: 0167-2681. DOI: 10.1016/S0167-2681(02)00152-X.
- GAROFALO, M. Modeling the 'El Farol Bar Problem' in NetLogo. *Preprint*, 2006.
- HEAD, B. *Netlogo - Python-Extension*. [S.l.: s.n.], 2017. Disponível em: <<https://github.com/NetLogo/Python-Extension>>.
- HOLLAND, J. H. *Studying Complex Adaptive Systems*. v. 19. [S.l.], 2006. p. 1–8.
- HORIO, N.; ARITOMI, H.; KUBO, M.; SATO, H. EasyChair Preprint Disaster Response Simulation by Drones Using Group Decision Making Model BRT, 2019.

- KARABOGA, D.; AKAY, B. A survey: Algorithms simulating bee swarm intelligence. *Artificial Intelligence Review*, v. 31, n. 1-4, p. 61–85, 2009. ISSN: 02692821. DOI: 10 . 1007 / s10462 - 009 - 9127 - 4.
- KLUGL, F.; BAZZAN, A. L. C. *Agent-Based Modeling and Simulation*. [S.l.]: American Association for Artificial Intelligence, set. 2012. v. 33, p. 29–40. ISBN: 9781137453624. DOI: 0738-4602.
- LUŞ, H.; CEVAT ONUR AYDIN, S. K.; ÜNSAL, H. I.; ATILGAN, A. R. El Farol revisited. *Physica A: Statistical Mechanics and its Applications*, v. 346, n. 3-4, p. 651–656, 2005. ISSN: 03784371. DOI: 10 . 1016 / j . physa . 2004 . 09 . 040.
- LUSTOSA, B. C.; CAJUEIRO, D. O. Constrained information minority game: How was the night at El Farol? *Physica A*, v. 389, p. 1230–1238, 2010. DOI: 10 . 1016 / j . physa . 2009 . 11 . 034.
- MACAL, C. M.; NORTH, M. J. Toward teaching agent-based simulation. *Proceedings - Winter Simulation Conference*, p. 268–277, 2010. ISSN: 08917736. DOI: 10 . 1109 / WSC . 2010 . 5679158.
- MANRIQUE, P. D.; JOHNSON, D. D.; JOHNSON, N. F. Using competition to control congestion in autonomous drone systems. *Electronics (Switzerland)*, v. 6, n. 2, 2017. ISSN: 20799292. DOI: 10 . 3390 / electronics6020031.
- MARSILI, M.; CHALLET, D.; ZECCHINA, R. Exact solution of a modified El Farol's bar problem: Efficiency and the role of market impact. *Physica A: Statistical Mechanics and its Applications*, v. 280, n. 3, p. 522–553, 2000.
- MAZUR, M.; WIŚNIEWSKI, A. *Drones as emergency ad-hoc networks*. [S.l.: s.n.], 2018. Disponível em: <[https : / / www . pwc . pl / en / drone - powered - solutions / Articles / 2018 / drone - as - emergency - ad - hoc - networks . html](https://www.pwc.pl/en/drone-powered-solutions/Articles/2018/drone-as-emergency-ad-hoc-networks.html)>.
- MITCHELL, M. *Complexity: A Guided Tour* (. Edição de Oxford University Press. 1. ed. [S.l.: s.n.], 2011. p. 368.
- PAPAKONSTANTINOU, A. *The El Farol Bar Problem for next generation systems*. 2006. Tese (Doutorado) – The University of York.
- PONSIGLION, C.; ROMA, V.; ZAMPELLA, F.; ZOLLO, G. *The Fairness/Efficiency Issue Explored Through El Farol Bar Model*. [S.l.]: J. Gil-Aluja et al. (eds.), Scientific Methods for the Treatment of Uncertainty in Social Sciences, Advances in Intelligent Systems e Computing 377, 2015. 309~329. ISBN: 9783319197036.
- PROVDANOV, C. C.; FREITAS, E. C. D. *Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico*. [S.l.: s.n.], 2013. p. 276. ISBN: 9788577171583. DOI: 10 . 1017 / CBO9781107415324 . 004.
- RAND, W. Machine learning meets agent-based modeling: When not to go to a bar. *the Proceedings of Agent*, p. 9, 2006.
- RAND, W.; WILENSKY, U. *NetLogo El Farol model*. [S.l.: s.n.], 2007.

- RAND, W.; STONEDAHL, F. the El Farol Bar Problem and Computational Effort: Why People Fail To Use Bars Efficiently, 2009. Disponível em: <[https://cc1.northwestern.edu/2007/Rand&Stonedahl\\_ElFarolBar.pdf](https://cc1.northwestern.edu/2007/Rand&Stonedahl_ElFarolBar.pdf)>.
- RYAN MCCUNE, R.; MADEY, G. R. Swarm control of UAVs for cooperative hunting with DDDAS. *Procedia Computer Science*, Elsevier B.V., v. 18, p. 2537–2544, 2013. ISSN: 18770509. DOI: 10.1016/j.procs.2013.05.436.
- SEABOLD, S.; PERKTOLD, J. Statsmodels: Econometric and Statistical Modeling with Python. *Proceedings of the 9th Python in Science Conference*, v. 57, Scipy, p. 61, 2010.
- SECRETARY, U. S. U. et al. Drone Swarms : A New Challenge For Air Defence Part-I Stigmergy anyone ? Is there enough juice ?, 2018.
- SHARIF, O.; HUYNH, N.; VIDAL, J. M. Application of El Farol model for managing marine terminal gate congestion. *Research in Transportation Economics*, v. 32, p. 81–89, 2011. DOI: 10.1016/j.retrec.2011.06.004.
- SHMUELI, G.; LICHTENDAHL JR, K. *Practical Time Series Forecasting with R*. Second. [S.l.: s.n.], 2018. Disponível em: <[www.forecastingbook.com](http://www.forecastingbook.com)>.
- SIEBERS, P. O. et al. Discrete-event simulation is dead, long live agent-based simulation! *Journal of Simulation*, Palgrave Macmillan UK, v. 4, n. 3, p. 204–210, set. 2010. DOI: 10.1057/jos.2010.14.
- SZILAGYI, M. N. The EL Farol Bar problem as an iterated N-person game. *Complex Systems*, v. 21, n. 2, p. 153–164, 2012. ISSN: 08912513.
- TAHIR, A. et al. Swarms of Unmanned Aerial Vehicles — A Survey. *Journal of Industrial Information Integration*, Elsevier, v. 16, March 2018, p. 100106, 2019. ISSN: 2452414X. DOI: 10.1016/j.jii.2019.100106.
- TOGOOTOGTOKH, E.; MICHELONI, C.; FORESTI, G. L.; MARTINEL, N. An Efficient UAV-based Artificial Intelligence Framework for Real-Time Visual Tasks, p. 1–8, 2020.
- VISERAS, A. et al. Beehive-inspired information gathering with a swarm of autonomous drones. *Sensors (Switzerland)*, v. 19, n. 19, 2019. ISSN: 14248220. DOI: 10.3390/s19194349.
- WHITEHEAD, D. The El Farol Bar Problem Revisited: Reinforcement Learning in a Potential Game Citation for published version: Whitehead, D 2008 'The El Farol Bar Problem Revisited: Reinforcement Learning in a Potential Game' ESE The El Farol Bar Problem Revisited: Reinf, 2008.
- WILENSKY, U.; RAND, W. *An Introduction to Agent-Based Modeling Modeling Natural, Social, and Engineered Complex Systems with NetLogo*. Cambridge, Massachusetts London: The MIT Press, 2015. p. 505. Disponível em: <<https://mitpress.mit.edu/books/introduction-agent-based-modeling>>.
- WOLPERT, D. H.; TUMER, K. Optimal Payoo Functions for Members of Collectives, 2001. Disponível em: <<http://jmvidal.cse.sc.edu/library/wolpert01a.pdf>>.

ZABALETA, O. G.; ARIZMENDI, C. M. Evolutionary quantum minority game: A wireless network application. *Citation: Chaos*, v. 28, p. 75506, 2018. DOI: 10.1063/1.5027739.

ZHANG, W.; SUN, Y.; FENG, X.; XIONG, X. Evolutionary Minority Game with searching behavior. *Physica A*, v. 436, p. 694–706, 2015. DOI: 10.1016/j.physa.2015.05.096.

ZORICAK, M. DroneCharge : A Python Framework for Automated Quadcopter Charging, p. 1–7, 2013.