UNIVERSIDADE NOVE DE JULHO - UNINOVE

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

DANIEL FERREIRA DE BARROS JUNIOR

APLICAÇÃO DE TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL NO APOIO À DECISÃO EM JOGO DE EMPRESAS

SÃO PAULO

2014

DANIEL FERREIRA DE BARROS JUNIOR

APLICAÇÃO DE TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL NO APOIO À DECISÃO EM JOGO DE EMPRESAS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Nove de Julho – UNINOVE, como requisito parcial para obtenção do grau de Mestre em Engenharia de Produção.

Prof. Sidnei Alves Araújo, Dr. - Orientador

SÃO PAULO

2014

DANIEL FERREIRA DE BARROS JUNIOR

APLICAÇÃO DE TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL NO APOIO À DECISÃO EM JOGOS DE EMPRESAS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Nove de Julho – UNINOVE, como requisito parcial para obtenção do grau de Mestre em Engenharia de Produção.

_____

Presidente: Prof. Dr. Sidnei Alves Araújo - Orientador, UNINOVE

_____

Membro interno: Prof. Dr. Wagner Cezar Lucato, Co-orientador, UNINOVE

_____

Membro interno: Prof. Dr. Leonardo Junqueira, UNINOVE

_____

Membro externo: Prof. Dr. Marcirio Silveira Chaves, UNINOVE

SÃO PAULO
2014

AGRADECIMENTOS

Agradeço a todos os amigos que me auxiliaram no caminho percorrido neste trabalho, aos meus colegas de trabalho e professores do programa de Mestrado, a minha esposa pelo apoio, compreensão e paciência, aos meus pais, irmãos e familiares, a meu orientador prof. Dr. Sidnei Alves Araújo por todo apoio, ajuda, orientação e zelo em todo decorrer deste trabalho, a meu co-orientador Prof. Dr. Wagner Cezar Lucato por seus conselhos e orientações, ao professor e irmão Amilton de Souza Rocha pela ajuda e parceria de longa data, aos professores Felipe Amendola e José Domingos Estivalli pelo apoio na coleta de dados e pela longa parceria no desenvolvimento do SAE e a Universidade Nove de Julho pela bolsa concedida. Obrigado a todos pelo apoio, paciência e força a mais uma jornada.

“Na sabedoria, nada mais odioso que julgar-se sábio.”
(SÊNECA)

RESUMO

Os jogos de empresas apresentam-se como ferramenta pedagógica diferenciada, por direcionar o foco da aula e a dinâmica de aprendizado do aluno. No entanto, um problema característico nestas ferramentas é o acesso do aluno ao *feedback* ou auxílio em tempo de execução da simulação, principalmente em decorrência do número de equipes envolvidas no jogo e do volume de dados gerados nas simulações. Este desafio foi observado no jogo empregado, denominado Simulador De Administração Empresarial (SAE), voltado para o ensino de conceitos de gestão da produção, vendas e estratégias de negócios. Neste trabalho investiga-se o uso de técnicas de Inteligência Computacional, por meio de experimentos, entre as quais, Redes Neurais Artificiais, Lógica *Fuzzy*, Árvores de Decisão, Sistemas Multiagentes e técnicas de Mineração de Dados, para o apoio à decisão dos jogadores e do professor durante as simulações no jogo, visando principalmente a redução dos problemas de *feedback* ao jogador e o incremento da dinâmica do jogo.

Palavras-chave: Jogo de empresas, Inteligência Computacional, Mineração de Dados, Redes Neurais Artificiais, Lógica *Fuzzy*, Árvores de Decisão, Sistemas Multiagentes.

ABSTRACT

The business games present themselves as differentiated pedagogical tool for directing the focus of the class and the dynamics of student learning. The efforts in developing business games result in several solutions. However, a typical problem in these teaching tools is the access of the student to feedback or online assistance of the simulation, mainly due to the number of teams involved in the game and the amount of data generated by simulations. This challenge was observed in the game, called SIMULADOR DE ADMINISTRAÇÃO EMPRESARIAL (SAE), for teaching the concepts of production management, sales and business strategies. This study investigates the use of computational intelligence techniques, including Artificial Neural Networks, *Fuzzy* Logic, Decision Trees, Multiagent Systems and techniques of the Data Mining, to support the decision of the players and the teacher during the simulations in the game, mainly aiming at reducing the problems of feedback to the player and increasing dynamics of the game.

Keywords: Business Games, Computational Intelligence, Data Mining, Artificial Neural Networks, Fuzzy Logic, Decision Trees, Multiagent Systems.

SUMÁRIO

1 INTRODUÇÃO 1

1.1 JUSTIFICATIVA E MOTIVAÇÃO 5

1.2 OBJETIVOS 7

1.2.1 Objetivo Geral 7

1.2.2 Objetivos Específicos 7

2 FUNDAMENTAÇÃO TEÓRICA 9

2.1 JOGOS DE EMPRESAS 9

2.2 TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL 14

2.2.1 Árvores de Decisão 14

2.2.2 Redes Neurais Artificiais 16

2.2.3 Lógica *Fuzzy* 18

2.2.4 Sistemas Multiagentes 21

2.3 MINERAÇÃO DE DADOS 23

2.4 TRABALHOS CORRELATOS 25

3 MATERIAIS E MÉTODOS 28

3.1 CARACTERIZAÇÃO DA PESQUISA 28

3.2 JOGO DE EMPRESAS UTILIZADO NOS EXPERIMENTOS 28

3.3 COMPOSIÇÃO DO CONJUNTO DE DADOS PARA OS EXPERIMENTOS 39

3.4 METODOLOGIA PARA CONDUÇÃO DOS EXPERIMENTOS 40

4 RESULTADOS 42

4.1 EXPERIMENTO 1 – MINERAÇÃO DE DADOS PARA INVESTIGAR A EXISTÊNCIA DE PADRÕES NAS DECISÕES TOMADAS PELOS DIFERENTES GRUPOS DE JOGADORES 42

4.1.1 Tratamento dos dados para composição do Conjunto_MD1 43

4.1.2 Tratamento dos dados para composição do Conjunto_MD2 43

4.1.3 Avaliação de desempenho dos classificadores 44

4.1.4 Análise da similaridade dos padrões com relação à variabilidade dos valores das variáveis de decisão. 45

4.1.5 Análise da similaridade dos padrões com relação ao posicionamento dos valores das variáveis de decisão 47

4.2 EXPERIMENTO 2 - APLICAÇÃO DE LÓGICA FUZZY PARA AUXÍLIO À TOMADA DE DECISÕES DOS JOGADORES 49

4.3 EXPERIMENTO 3 - APLICAÇÃO DE SISTEMAS MULTIAGENTES PARA SIMULAÇÃO DO MERCADO CONSUMIDOR 56

4.4 DISCUSSÃO DOS RESULTADOS 66

5 CONCLUSÕES E TRABALHOS FUTUROS 68

6 REFERÊNCIAS BIBLIOGRÁFICAS 70

ANEXO A: TRABALHOS RESULTANTES DESTA DISSERTAÇÃO 80

ANEXO B: MAPEAMENTO DAS AÇÕES NO SAE 81

LISTA DE FIGURAS

Figura 1. Modelo de jogo de empresas 10

Figura 2. Árvore de decisão. 15

Figura 3. Estágios de um controlador *fuzzy* 20

Figura 4. Tela principal do SAE. 30

Figura 5. Decisões estratégicas. 31

Figura 6. Decisões Operacionais (SAE) 33

Figura 7. Roteiro de participação do aluno no SAE. 33

Figura 8. Arquitetura atual do SAE. 34

Figura 9. Dinâmica de atividades do facilitador. 35

Figura 10. Indicadores de Desempenho SAE. 38

Figura 11. Histograma da variável de decisão CMPS. 50

Figura 12. Histograma da variável PVL 51

Figura 13. Funções de pertinência associadas à variável PVL. 52

Figura 14. Variáveis de entrada/saída do mecanismo de inferência *fuzzy*. 52

Figura 15. Regras de inferência *Fuzzy*. 53

Figura 16. Regras do modelo *fuzzy*. 54

Figura 17. Notas Real VS Nota Estimada pelo modelo *Fuzzy*. 55

Figura 18. Demanda sazonal estimada por intervalo mensal. 58

Figura 19. Modelo de interação de um agente. 59

Figura 20. Modelagem de mercado consumidor em *NetLOGO*. 61

Figura 21. Simulação de demanda e cenários. 63

Figura 22. Tendência de demanda em um único período. 65

Figura 23. Nova arquitetura proposta para o SAE. 67

Figura 24. Mapeamento de ações do Professor. 81

Figura 25. Mapeamento de ações do Aluno. 82

Figura 26. Mapeamento de ações de uma jogada. 83

LISTA DE TABELAS

Tabela 1. Variáveis de decisão do jogo de empresas. 32

Tabela 2. Universo da coleta de dados. 39

Tabela 3. Matriz de confusão. 44

Tabela 4. Matriz de confusão da classificação dos dados do Conjunto_MD1 pela árvore de decisão ID3 45

Tabela 5. Matriz de confusão da classificação dos dados do Conjunto_MD1 pela rede neural MLP 45

Tabela 6. Matriz de confusão da classificação dos dados do Conjunto_MD2 pela árvore de decisão ID3 47

Tabela 7. Matriz de confusão da classificação dos dados do Conjunto_MD2 pela rede neural MLP 47

Tabela 8. Característica de influência do consumo. 57

Tabela 9. Parâmetros empregados nos cenários simulados. 62

LISTA DE ABREVIATURAS E SIGLAS

AD - Árvore de Decisão.

BSC - *Balanced Scorecard.*

EGS - Exercício de Gestão Simulada.

FN - Falso Negativo.

FP - Falso Positivo.

Fuzzy - Lógica *Fuzzy*.

IA - Inteligência Artificial.

JIT - *Just In Time.*

MD - Mineração de Dados.

MLP - *Multilayer Perceptron.*

MMG - *Multinational Management Game.*

RNA - Rede Neural Artificial.

SAE - Simulador de Administração Empresarial.

SMA - Sistemas Multiagentes.

SOM - *Self-Organized Map.*

TI - Tecnologia da Informação.

TQM - *Total Quality Management.*

VN - Verdadeiro Negativo.

VP - Verdadeiro Positivo.

1 INTRODUÇÃO

O jogo de empresas pode ser caracterizado como um processo simulado de tomada de decisão gerencial, envolvendo um cenário e contexto empresarial em um ambiente econômico predefinido. Nesta imersão de informações, os participantes, reunidos geralmente em grupos, realizam suas análises, constroem suas estratégias e tomam suas decisões com base nas variáveis disponíveis no jogo de empresas.

Atualmente, é cada vez mais presente e relevante o uso de jogos de empresas em universidades como uma importante ferramenta de apoio ao ensino e aprendizagem (OLIVEIRA; SAUAIA, 2009). Observa-se que tomadas de decisões, para uso em jogos de empresas, requerem do aluno o resgate, a consolidação e a aplicação de conceitos teóricos apresentados durante o curso, os quais muitas vezes são fragmentados. O uso do jogo permite que as informações se enriqueçam por meio da dinâmica empregada, da visão sistêmica necessária à resolução dos problemas, da participação coletiva dos alunos e da relação de causa e efeito diante das decisões tomadas. O desempenho do aluno no jogo de empresa não está necessariamente associado diretamente ao seu desempenho acadêmico, o que torna a simulação ainda mais desafiadora (SAUAIA, 2006).

Seu uso é recomendado como ferramenta de treinamento e desenvolvimento em virtude da construção de uma aprendizagem significativa, por retratar o cotidiano de colaboradores em uma organização, permitindo a criação, aquisição e transferência de conhecimento e reflexão sobre as decisões tomadas (SOUZA; CHAGAS; SILVA, 2011).

Um jogo de empresas pode variar quanto à quantidade de decisões a serem tomadas, consequentemente, essa maior disponibilidade de variáveis exigirá do professor um maior apoio, em benefício do aprendizado dos alunos, demandando mais tempo para análise, estudos e inferências (D´IPOLITTO, 2012; ROSAS; SAUAIA, 2006b).

O emprego de indicadores de desempenho em um jogo pode auxiliar e orientar as ações dos alunos. Por exemplo, o *Balanced Scorecard* (BSC), oferece um meio para aferir o desempenho da empresa virtual (COSTA, 2006). As metas e objetivos dos alunos podem ser previamente estabelecidos e medidos ao longo das simulações no jogo e podem ser utilizadas como instrumentos avaliativos.

O conteúdo e análise a serem desenvolvidos no jogo, necessários para realizar as tomadas de decisão, variam de acordo com o curso ou especialidade do aluno. Há aplicações de jogos de empresa voltados para temas nas áreas de logística, recursos humanos, administração geral, gestão da produção industrial, empreendedorismo, tecnologia da informação, dentre outras (D´IPOLITTO, 2012; MEDEIROS; ORNELLAS; RAMOS, 2006; NASCIMENTO, 2011; RIBEIRO; FOUTO, 2013; SILVESTRE, 2004)

Na realização das atividades de jogos de empresa diversos dados estão disponíveis no intuito de medir e quantificar o estado da empresa virtual. Observa-se que estas informações geralmente apresentam uma situação isolada da empresa, com poucos dados de seu micro universo ou mercado virtual, a exemplo de indicativos de *MarketShare*.

Admitindo a importância e relevância da concorrência e competitividade para uma empresa real, espera-se que os jogos de empresas possam refletir e simular parcialmente, dentro de seus limites, a competitividade empresarial por meio de informações e metas, disponibilidade de ações e procedimentos, no intuito de caracterizar a importância da competitividade na tomada de decisão, nas ações e nos resultados de uma empresa.

No que se refere a jogos de empresas voltados para administração de negócios, na literatura poucos trabalhos se aprofundam ou relatam sobre a demanda e o processo decisório do mercado, seja ele um mercado consumidor virtual ou mercado atacadista virtual (HONAISER; SAUAIA, 2008; LOPES et al., 2005; MADKUR; LOPES, 2010; SILVA;

SAUAIA, 2012). Normalmente, cabe ao professor determinar a demanda (mercado consumidor) e aferir as tomadas de decisões dos alunos para determinar seus resultados, ou seja, a quantidade de produtos vendidos. Os critérios para definição do mercado consumidor normalmente são norteados por cenários explanados durante a simulação ou delimitados no jogo de empresas. No entanto, algumas dificuldades são observadas nas simulações, quando observadas do ponto de vista do professor, entre as quais:

- A grande quantidade de decisões a tomar em relação à demanda a ser atendida, para simulação do mercado;
- Necessidade da ação do professor para finalização das rodadas.

Estas características limitam a modelagem de sistema de jogos de empresas quanto à dinâmica de períodos, sua massificação e exploração de grande número de equipes em tempo real, ou seja, neste modelo é necessário um período adequado de pausa para contabilizar as demandas atendidas em relação às decisões das empresas simuladas.

Em adição, é comum em jogos de empresas um grande volume de dados gerados nas simulações, característico deste método de ensino. No momento de sua aplicação, realizar as mais diversas inferências, em curto período de tempo, é um desafio relevante para todos os envolvidos. Ao professor, recai a responsabilidade do adequado andamento do jogo. Para tanto, observar e analisar as diversas operações e informações é essencial (NASCIMENTO, 2011; ZAMBELO; RODRIGUES, 2010).

Neste sentido, classificar e tipificar as ações tomadas pelos participantes visando balizar a avaliação, bem como propor cenários diversificados e adequados são tarefas complexas. Inferências a partir de padrões extraídos da base de decisões poderiam possibilitar uma melhor orientação e acompanhamento de tomadas de decisões futuras dos jogadores. Não obstante, o professor poderia utilizar-se destas inferências para enriquecer a dinâmica do jogo. A carência

de habilidades na condução e a falta de uma adequada preparação é tida como um dos principais problemas quanto à aplicação de jogos de empresas (ROSAS; SAUAIA, 2006a).

Em jogos de empresas normalmente o aluno (ou grupo de alunos) assume o papel de jogador e o professor atua como facilitador. O jogador deve tomar decisões diante de diversos cenários e suas escolhas interferem diretamente nos resultados de seus indicadores de desempenho, disponíveis na simulação, e inclusive em sua nota de avaliação na disciplina. Para acompanhar seu desenvolvimento, o jogador pode recorrer ao facilitador da simulação, para obter orientação e um *feedback* em relação ao seu desempenho. Neste momento, o facilitador pode se ver sobrecarregado de atividades, principalmente nos casos onde a simulação possua muitos jogadores. O tempo de resposta e análise normalmente não é imediato e obedece ao tempo destinado às rodadas da simulação. Soma-se a este desafio o trabalho de geração de dados para o jogo de empresas, por exemplo, os cenários econômicos, os cenários externos, os informativos, os relatórios e, em especial, as demandas e contexto de um mercado consumidor. Como se pode observar, a gestão do tempo e a preparação da simulação desafia o facilitador em diversos aspectos.

Neste contexto, o uso de técnicas de inteligência computacional pode ser uma alternativa para auxiliar no *feedback* ao aluno em relação ao seu desempenho na simulação e no enriquecimento do jogo, com a geração de mecanismos para auxílio à tomada de decisões dos jogadores e facilitadores. Neste trabalho investigou-se o uso das técnicas de inteligência computacional, tais como as Redes Neurais Artificiais (RNA), Árvore de Decisão e Lógica *Fuzzy* (*Fuzzy*) em mecanismos de apoio à tomada de decisões do aluno, além de Sistemas Multiagentes (SMA) direcionados para apoio aos professores, enriquecendo a dinâmica do jogo de empresas. Para tanto foi utilizado nos experimentos um jogo para apoio ao ensino de conceitos de gestão da produção, vendas e estratégias de negócios, denominado Simulador De Administração Empresarial (SAE). A utilização de outras técnicas computacionais, como a

metodologia de Mineração de Dados, visou colaborar na descoberta e composição das informações relativas às tomadas de decisões dos jogadores. Assim, foram realizados três experimentos, cada um com foco em uma dificuldade característica da simulação, com base em dados obtidos do SAE.

1.1 JUSTIFICATIVA E MOTIVAÇÃO

Jogos de empresas podem ser considerados um ferramental importante na construção e absorção de conhecimento, da experiência vivencial, do processo de tomada de decisões gerenciais, bem como na prática do trabalho em equipe. Encontrados no referencial bibliográfico, os jogos de empresas possuem importante impacto na percepção do aluno quanto à revisão de conteúdo acadêmico, bem como nos ganhos obtidos nas dinâmicas em grupos. A geração de informações sobre seus resultados, apresentados pelo professor, torna-se cada vez mais relevante para que o aluno possa entender e tomar novas e melhores decisões em futuras simulações.

Nos modelos e descrições de jogos de empresas encontrados na literatura, não foram encontrados detalhes específicos visando um processamento automático quanto à tomada de decisões. O jogo de empresas torna-se mais complexo quando o simulador é utilizado por um grande número de jogadores simultâneos, devido à interação entre os grupos participantes. Assim, o tempo necessário entre os cálculos, a fim de determinar os resultados das empresas virtuais, concorrem diretamente com o tempo de dedicação e orientação aos alunos.

Por esta análise, o tempo disponível do professor para interação com o jogo na proposição de diferentes cenários, incluindo a gestão da demanda virtual representada por um mercado consumidor virtual, e também para fornecer *feedback* aos alunos sobre os resultados de suas ações, ainda no momento da simulação, torna-se reduzido em função do tempo de

resposta requerido e do número de jogadores envolvidos. Em alguns casos gera-se até fila de atendimento de alunos.

Isso ocorre, por exemplo, no SAE e constitui o problema de pesquisa deste trabalho. A hipótese inicial levantada neste trabalho é que o emprego de técnicas de inteligência computacional pode proporcionar a construção de mecanismos automáticos de apoio ao *feedback* e às tomadas de decisões dos jogadores e a geração de um mercado consumidor virtual para controle da demanda, para apoio ao professor.

O desenvolvimento e emprego de técnicas de Inteligência Computacional, como as Redes Neurais Artificiais, Sistemas Multiagentes e Lógica *Fuzzy* em um ambiente simulado de aprendizagem tão rico quanto os jogos de empresas, particularmente no SAE, até então sem a disponibilização de mecanismos de apoio a decisão, em conjunto à expertise e à vivência em ambos ambientes, foi o principal fator que motivou a escolha deste tema de pesquisa e a realização deste trabalho.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Investigar e desenvolver módulos de apoio aos alunos e professores em um jogo de empresas direcionado ao ensino de conceitos de gestão da produção, vendas e estratégias de negócios, com a finalidade de disponibilizar *feedback* aos alunos, a cerca de suas tomadas de decisões e apoio aos professores, quanto a informações a respeito de mercados consumidores virtuais. Para tanto, técnicas de inteligência computacional e de mineração de dados são utilizadas na descoberta de informações e inferências acerca das tomadas de decisões.

1.2.2 Objetivos Específicos

- Para auxílio na descoberta de padrões nas tomadas de decisões dos jogadores, este trabalho tem como objetivo investigar, desenvolver e avaliar o uso de técnicas de Mineração de Dados, com o emprego de algoritmos como as Árvores de decisão e Redes Neurais Artificiais, sobre o conjunto de decisões tomadas pelos diferentes grupos de jogadores do SAE. Tais padrões são utilizados como subsídios e apoio na concepção dos mecanismos de apoio à decisão.
- Para auxílio e *feedback* do desempenho do aluno em jogo de empresas, este trabalho tem como objetivo investigar, desenvolver e avaliar um mecanismo de Inferência *Fuzzy* para auxílio à tomada de decisão dos jogadores. Este mecanismo é destinado exclusivamente para inferência do desempenho dos alunos, com base nas tomadas de decisões, ainda em tempo de execução da simulação.

- Para auxílio na definição de um mercado consumidor virtual em jogo de empresas, este trabalho tem como objetivo investigar, desenvolver e avaliar um módulo baseado em Sistemas Multiagentes, para uso do professor, direcionado à demanda de mercado. A finalidade deste módulo é simular o comportamento de um mercado consumidor virtual parametrizável a diversos cenários externos e econômicos, a disponibilizar estes dados e cenários posteriormente no jogo de empresas.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados conceitos acerca de jogos de empresas, Mineração de Dados e sobre técnicas de inteligência computacional tais como: Árvores de Decisão, Redes Neurais Artificiais, Lógica *Fuzzy* e Sistemas Multiagentes, imprescindíveis para o entendimento das propostas apresentadas neste trabalho.

2.1 JOGOS DE EMPRESAS

Jogos de empresas são ferramentas educacionais direcionadas ao processo de aprendizagem, de forte apelo à vivência e caráter prático, agregando a visão sistêmica, multidisciplinar, e o processo de tomada de decisão à base teórica apresentada ao aluno. Geralmente aplicados em cursos de graduação, os jogos de empresas apresentam oportunidades da execução do trabalho em equipe, onde cada aluno assume momentaneamente papéis predefinidos de gestão na empresa virtual (ROSAS; SAUAIA, 2006a; OLIVEIRA; SAUAIA, 2011).

Jogo de empresas também pode ser definido como uma simulação na qual as pessoas participam ativamente como tomadores de decisões dentro do sistema organizacional simulado (NAYLOR et al., 1971). As simulações caracterizam-se por uma situação em que o cenário simulado representa modelos reais, tornando possível a reprodução do cotidiano (DUGAICH, 2005; GRAMIGNA, 2007).

Ainda de acordo com Sauaia (1995), os jogos de empresas são ferramentas educacionais direcionadas ao processo de aprendizagem, de forte apelo ao aprendizado vivencial e que auxiliam na percepção da visão sistêmica e na experimentação do processo de tomada de decisão empresarial.

A figura 1 ilustra o ciclo de informação de um modelo de jogo de empresas.

Figura 1. Modelo de jogo de empresas

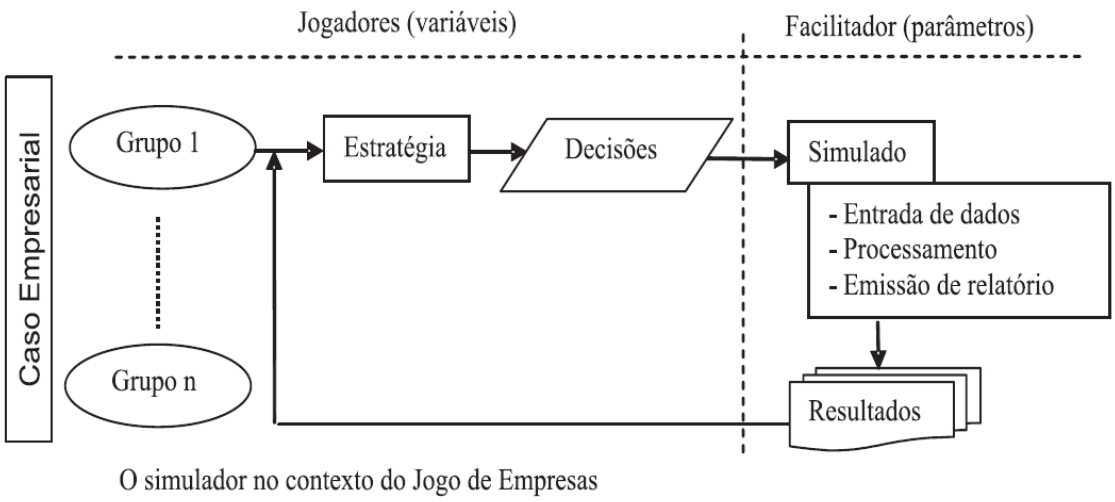

Fonte: (ROSAS; SAUAIA, 2006a)

Os desafios em um jogo de empresa se apresentam por meio de objetivos a serem cumpridos, em intervalos de tempo predefinidos a simular períodos contábeis, ou ciclos de produção (SAUAIA, 1995).

O conteúdo a ser desenvolvido, necessário para realizar as tomadas de decisão, varia de acordo com o curso ou especialidade do aluno. De acordo com Dugaich (2005), há aplicações de jogos de empresas e simuladores voltados às diversas áreas, dentre elas, comercial, industrial, de serviços, financeira, de marketing, com níveis variantes de dificuldades. Os trabalhos a seguir tratam da conceituação, modelagem ou benefícios da aplicação de jogos de empresas.

Um estudo da satisfação e aprendizagem, na aplicação de jogos de empresas, é apresentado por Sauaia (1995). O autor se aprofunda, com base na teoria da aprendizagem vivencial, na experiência e processo educacional do jogo de empresas.

Aplicações de jogos de empresas são geradas para análise de conceitos como o *Balanced Scorecard* (BSC), como demonstra Costa (2006) em sua pesquisa sobre a aderência e entendimento desta metodologia (BSC), em relação a alunos que não participaram do simulado. Os resultados da pesquisa mostraram-se positivos, pois o jogo de empresas apresentou-se satisfatório para conceituação e apresentação do BSC.

O uso de jogos de empresas como ferramenta de validação de gestão empresarial é descrito por KÁLLAS, CARLOS e SAUAIA (2006). Os autores utilizaram como estudo de caso empresas reais e simuladas para demonstrar a aplicação do BSC.

Uma evolução tecnológica importante, relacionada ao meio de acesso e disponibilidade ao jogo de empresas, dá-se com sua possibilidade de aplicação por meio da internet, associada a jogabilidade e disponibilidade do simulador (GERBER, 2000).

Há estudos onde se propõe um modelo de jogo de empresas voltado à gestão da produção e operações, elencando as principais decisões destinadas para este fim (OLIVARES; CAMPOS, 2004).

Jogos de empresas não se aplicam exclusivamente em programas de computadores. Por exemplo, a adaptação do “Jogo do Barco” envolve, além das abordagens JIT, *Lean manufacturing* e TQM, parâmetros extras quanto à qualidade, produção e custos, onde os próprios alunos monitoram e registram seus desempenhos em fichas de desempenho (BATISTA at. al, 2011).

A relevância e demanda de novos estudos acerca dos jogos de empresas geram novos contornos com a criação e disponibilidade, no meio acadêmico, de laboratórios específicos. Entre eles, pode-se citar:

- Laboratório de Gestão – SIMULAB (FEA/USP).
- Núcleo de Estudos em Simulação Gerencial – NESIG (UFSC)

Entre as atividades de operação e manutenção de jogos de empresas, estes laboratórios criam ambiente favorável à pesquisa e novos desenvolvimentos, propiciando ao corpo docente subsídio para realização de trabalhos nesta área de pesquisa. Este ambiente cooperativo ultrapassa as barreiras das instituições, conforme apresentado por Oliveira e Sauaia (2011), cuja colaboração fez uso de parceria internacional Brasil – Espanha, disponibilizando a plataforma de gestão a estudantes estrangeiros.

Em um estudo comparativo a respeito das variáveis macro e microeconômicas, três jogos de empresas foram analisados: o Exercício de Gestão Simulada (EGS), o Jogo de Empresa Multinacional (MMG) e o Simulab (SAUAIA; WADT, 2010). Neste artigo alguns fatores são descritos quanto à determinação da demanda, entre eles:

- Índice de inflação.
- Taxa de câmbio.
- Índice de atividade econômica presente.
- Índice de atividade econômica previsto.
- Índice de variação estacional.
- Multiplicador da demanda.

Variáveis controladas pelas empresas simuladas influenciam nas preferências dos consumidores, ajustadas direta ou indiretamente, a diversas variáveis tais como Propaganda, Investimento em processo técnico, Investimento em meio ambiente (BARROS JR et al., 2013).

Há estudos que indicam não haver correlação entre o conhecimento teórico prévio e o desempenho na prática gerencial, ou seja, um melhor preparo teórico acerca do processo gerencial não resulta necessariamente em um desempenho prático compatível. Esta indicação

orienta a relevância dos jogos de empresas, no intuito de estimular a tomada de decisão, atitude fundamental da prática gerencial (ROMÃO at. al, 2012).

O uso do jogo de empresas é recomendado como ferramenta de treinamento e desenvolvimento em virtude da construção de uma aprendizagem significativa, por retratar o cotidiano de colaboradores em uma organização, permitindo a criação, aquisição e transferência de conhecimento e reflexão sobre suas decisões (SOUZA at. al, 2011).

Um aspecto importante é o papel dos facilitadores quanto à prática dos jogos de empresas e dos benefícios aos alunos quanto ao desenvolvimento de suas competências gerenciais. Oliveira e Sauaia (2011) apontam diversas sugestões para inclusão no jogo de empresas, alinhadas às disciplinas ministradas. Com percepções diversas, pode-se identificar 4 grupos distintos de professores: os pragmáticos, os apoiadores, os analíticos (mais críticos ao jogo) e os integradores (mais entusiasmados ao jogo) (OLIVEIRA; SAUAIA, 2009, 2011).

2.2 TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL

Inteligência computacional pode ser definida como o estudo da resolução de problemas complexos, tendo como inspiração as técnicas de resolução de problemas utilizadas por seres humanos. Seu desenvolvimento permite oferecer as mais variadas técnicas e abordagens computacionais, sendo utilizada nas mais diversas áreas do conhecimento, incluindo os jogos de empresas. Há diversas técnicas de Inteligência Computacional, contudo, nas subseções a seguir, são descritas apenas aquelas empregadas neste trabalho (MARTÍNEZ-LÓPEZ; CASILLAS, 2013; NESPOLI, 2004).

2.2.1 Árvores de Decisão

Árvore de Decisão (AD) é uma técnica muito abrangente e poderosa, utilizada em tarefas de classificação e associação. As estruturas principais das árvores são as podas e os ramos. Sua utilização torna-se atraente no contexto de Mineração de Dados devido ao fato do conhecimento adquirido ser representado por meio de regras que facilitam o entendimento do usuário. Esta característica se deve à sua criação ser baseada na importância dos atributos para a classificação dos padrões (RUSSEL; NORVIG, 1995)

Por exemplo, como se pode observar na árvore de decisão ilustrada na figura 2 o ramo *Wind* (vento) possui duas podas *Strong* e *Weak* (forte e fraco) e, em suas terminações, há indicação de *No* e *Yes* (Não e Sim), indicando, neste caso de uma aplicação em um jogo de tênis proposta por (MITCHELL, 1997; QUINLAN, 1986): se houver vento forte, não jogar tênis, se houver vento fraco, pode-se jogar tênis.

Figura 2. Árvore de decisão.

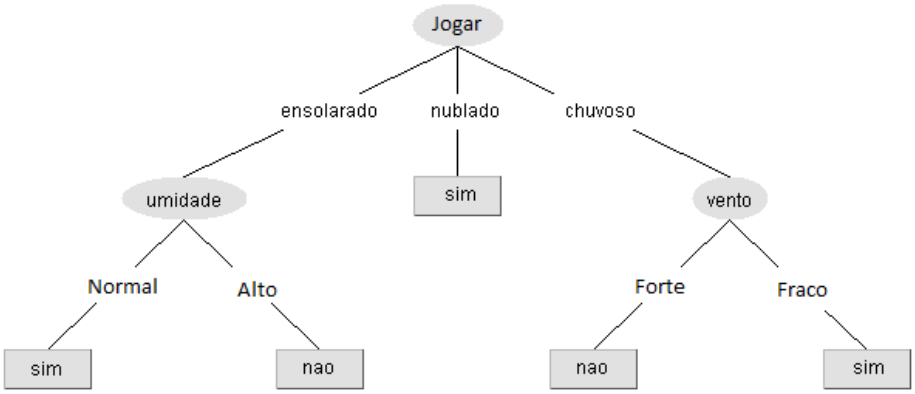

Fonte: Adaptado de Mitchell (1997)

São vários os algoritmos utilizados para construção de uma AD. A chave para o sucesso de um algoritmo de AD é como gerar a árvore, ou seja, como fazer a escolha dos atributos mais importantes para gerar as regras de decisão. O algoritmo ID3, por exemplo, realiza o cálculo dos pesos das variáveis envolvidas, para quantificar quais valores serão representados nos ramos. Para tanto, é feita uma pesquisa Top-Down, ou seja, qualifica as informações de “cima” para “baixo” no grafo, por meio de cálculo de entropia. Ele utiliza ainda o método de hipóteses simples (navalha de Occam) para descrever seus eventos (MITCHELL, 1997; QUINLAN, 1986; RUSSEL; NORVIG, 1995).

As árvores de decisão são capazes de gerar explicação razoável a respeito de previsões de informação, como exemplo o preço de ações, por meio de cálculos estatísticos. No entanto, apesar de ser uma técnica consagrada, o resultado das árvores de decisão normalmente consiste em muitos nós, o que pode dificultar sua análise e interpretação dos dados (LIN et al., 2013).

2.2.2 Redes Neurais Artificiais

As redes neurais artificiais representam um paradigma metodológico no campo da Inteligência Artificial no que tange ao desenvolvimento de sistemas computacionais capazes de simular tarefas intelectuais desenvolvidas pelo cérebro humano. Seu funcionamento difere das técnicas baseadas em lógica convencional e em processamento simbólico (KASABOV, 1996; LOESCH; SARI, 1996; SCHUMAN; BIRDWELL, 2013). Tais redes se inspiram na maneira como o cérebro é organizado e na forma como o mesmo executa as tarefas, tendo como uma das principais vantagens a capacidade de aprender por meio da experiência, ou treinamento, permitindo uma posterior generalização, classificação, previsão ou controle para tratar de problemas específicos (CHANG, 2011; OSIRO et al., 2013; SCHUMAN; BIRDWELL, 2013; THOMAS; THOMAS, 2011).

As pesquisas iniciais referentes às RNA's datam de 1943, com trabalhos de Warren McCulloch e Walter Pitts, os quais sugeriam uma modelagem lógico-matemática do neurônio biológico (KAUPA; SASSI, 2011).

As redes neurais artificiais são compostas de elementos simples, denominados neurônios, que se interconectam, formando redes capazes de armazenar e transmitir a informação provinda do exterior ou mesmo de outros neurônios. Considerando suas propriedades, podemos citar como relevante a capacidade de auto-organização, onde em seu processo de aprendizado suas interconexões podem estabelecer pesos diferentes entre seus elementos, caracterizando-se como um sistema conexionista. Outro ponto relevante é quanto a sua capacidade de generalização que as permitem produzir saídas adequadas para entradas que não foram previamente aprendidas (KASABOV, 1996; LOESCH; SARI, 1996).

O aprendizado de uma RNA é decorrente dos sucessivos ajustes dos pesos, e podem ser grupados em dois paradigmas, supervisionado e não-supervisionado. No aprendizado

supervisionado, o conjunto de dados de entrada e saída desejados deve ser conhecido. O processo de treinamento da rede se dá com um conjunto de dados de entrada confrontado a uma saída desejada e, havendo diferença, o erro é reprocessado com novos ajustes nos pesos da rede neural na expectativa de melhores resultados. Este processo é realizado até que o erro esteja em níveis aceitáveis. O aprendizado não-supervisionado não requer saídas desejadas para o conjunto de treinamento. O processo de treinamento da rede se dá com a disponibilidade de vários padrões a formar um conjunto de dados de treinamento, para que a rede organize padrões aleatórios em categorias, de acordo com sua programação de aprendizagem. Aos novos conjuntos de dados, a rede realiza uma classificação de acordo com as categorias encontradas anteriormente, consequentemente, uma nova categoria é criada (KOHONEN, 2001).

O *Multilayer Perceptron* foi proposto por Frank Rosemblatt no fim da década de 50. Com uma ideia inovadora para os problemas de reconhecimento de padrões e um novo método ao adicionar um algoritmo de aprendizagem. Este modelo de RNA de aprendizado supervisionado tem como vantagem a simplicidade. Possui poucos parâmetros de configuração, bem como um padrão de entrada de dados menos complexo. O processo de treinamento é repetido até que a margem de erro, vetores de treinamento, esteja em níveis adequados. Para tanto, utiliza-se de um algoritmo de retropropagação de erro (*error back-propagation*). Considerado eficiente para o treinamento de redes MLPs, o algoritmo consiste em dois passos (passo direto e passo reverso). No passo direto o padrão a ser aprendido é aplicado na camada de entrada e se propaga até o ultimo nó. No passo reverso o padrão a ser aprendido se inicia também nas camadas de entrada, no entanto, ao encontrar o sinal de erro, a propagação retorna ao passo anterior, um novo ajuste é realizado e a propagação segue o rumo normal, até encontrar o nó de saída. (KOHONEN, 2001).

Os Mapas Auto-Organizáveis ou redes de Kohonen são modelos de RNA’s não supervisionados e uma das suas principais características é a capacidade de auto-organização,

que sobre alguns aspectos os tornam mais interessantes que os modelos supervisionados (KOHONEN, 2001).

A rede de Mapas Auto-Organizáveis ou Self-organized Map (SOM) funciona basicamente da seguinte forma: quando um padrão *p* é apresentado à rede, um neurônio é escolhido para representar este padrão por meio de um processo de competição. Durante o treinamento, a rede aumenta a semelhança do neurônio escolhido e de seus vizinhos ao padrão ***p*.** Desta forma, é construído um mapa topológico onde neurônios que estão topologicamente próximos respondem de forma similar aos padrões de entrada que possuem características semelhantes. O processo de treinamento obtém do conjunto de dados suas características estatísticas e os agrupa em vetores semelhantes, com um alto grau de conectividade (KOHONEN, 2001).

2.2.3 Lógica *Fuzzy*

A Lógica *Fuzzy* ou lógica nebulosa pode ser vista como uma lógica que trata de modelos de raciocínio incerto, vagos ou aproximados (ZADEH, 1972). A teoria dos conjuntos *fuzzy* (nebulosos ou difusos) foi proposta por Lotfi A. Zadeh em 1965, na Universidade da Califórnia em Berkeley. A Lógica *Fuzzy* permite lidar com problemas de decisão que não sejam facilmente descritos por modelos matemáticos.

Um controle *fuzzy* tenta “imitar” um operador humano tomando como base uma representação descritiva e experimental de um determinado processo. Ainda, considera-se que em um evento de maior complexidade, a capacidade de sua descrição por um ser humano é reduzida (GAVIÃO; LIMA, 2013; ODERANTI; DE WILDE, 2010).

Uma variável linguística, elemento central na representação de conhecimento em Lógica *Fuzzy*, pode ser considerada como uma variável cujo valor é um número nebuloso ou

como uma variável cujos valores (intervalos) são definidos em termos linguísticos. Uma partição nebulosa determina quantos termos linguísticos devem existir em um conjunto de termos associado a uma variável linguística. Por exemplo: variável linguística: pressão; partição: alta, média e baixa (três termos linguísticos) (MORIM et al., 2012; RODRIGUES; SANTOS, 2004).

Os modificadores linguísticos têm a função de gerar um conjunto maior dos valores para uma variável linguística com uma coleção pequena de termos preliminares. Por exemplo, usando o modificador “muito” conjuntamente com “não”, “e”, e o termo preliminar “alto”, pode-se gerar os conjuntos *fuzzy* “muito alto”, “muito muito alto”, “não muito alto”, etc (MORIM et al., 2012).

Uma regra de controle *fuzzy* é uma declaração (sentença) condicional nebulosa na qual o antecedente é uma condição no seu domínio de aplicação e o consequente é uma ação de controle do sistema. Basicamente, as regras de controle *fuzzy* provêm meios convenientes para expressar políticas de controle e conhecimento a respeito do processo, por exemplo, uma regra de controle: SE <u>estatura</u> é alta E <u>peso</u> é alto ENTÃO <u>risco</u> é alto (ODERANTI; DE WILDE, 2010).

Em geral, os estágios de um controlador *Fuzzy* são Fuzzificação, Propagação e Defuzzificação.

a) Fuzzificação: Faz a conversão do valor fixo de entrada em graus de pertinência a cada termo linguístico;

b) Propagação: Consiste da aplicação das regras *fuzzy* nas variáveis linguísticas (inferência).

c) Defuzzificação: Conversão dos graus de pertinência em valores fixos.

Os estágios de fuzzificação, propagação e defuzzificação, ilustrados na figura 3, correspondem ao fato do programa ler, por exemplo, a temperatura de uma turbina a partir de um sensor, descobrir quão “quente”, “muito quente”, “normal” e “frio” (fuzzificação) ela está associada, aplicar as regras *fuzzy* para chegar em uma variável *fuzzy* (de saída), por exemplo, rotação, com valores “veloz”, “rápido”, “normal”, “devagar” e “muito devagar” e finalmente determinar um valor real (defuzzificação) como informação de saída que deverá ser usado para acelerar ou retardar a turbina (ODERANTI; DE WILDE, 2010; RODRIGUES; SANTOS, 2004).

Figura 3. Estágios de um controlador *fuzzy*

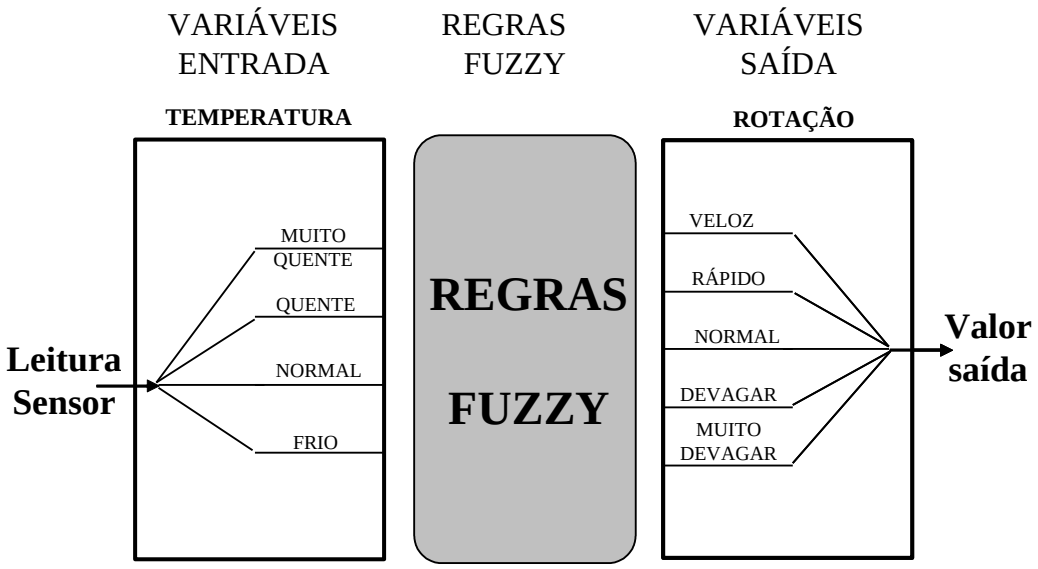

A inferência difusa consiste na aplicação de regras do tipo SE antecedentes (premissas) ENTÃO consequentes (ações) de forma que premissas e ações, e a própria sentença, sejam noções difusas. Desta forma torna-se mais fácil a interpretação matemática e a implementação de sistemas a partir do conhecimento humano (GAVIÃO; LIMA, 2013; MORIM et al., 2012; RODRIGUES; SANTOS, 2004).

2.2.4 Sistemas Multiagentes

Um agente pode ser interpretado como um software ou um procedimento computacional, projetado para tomar decisões autônomas, de acordo com objetivos e informações de seu conhecimento prévio ou obtidos de seu ambiente. Um Sistema Multiagentes é composto por um conjunto de agentes, e seu relacionamento representa uma comunidade de agentes inteligentes interagindo em um sistema de forma concorrente ou cooperativa, com o intuito de simular um comportamento social inteligente (SICHMAN, 2003).

Ainda de acordo com Sichman (2003), não há definição semântica precisa para Sistemas Multiagentes (SMA). No entanto, a técnica consiste em um paradigma da computação, uma possível ciência da interação entre personagens (agentes), disponibilizando recursos de análise e síntese a um sistema (ambiente dos agentes), com foco no esclarecimento e descobertas das relações de interações (interações entre agentes). Algumas características de SMA são pertinentes e se aproximam das características aferidas em jogos de empresa. Dentre as características de agentes podemos destacar a:

- Independência.
- Interferência social positiva
- Interferência social negativa.
- Colaboração simples.
- Colaboração coordenada.

A caracterização destas ocorrências se dá de maneira independente entre os agentes envolvidos, conscientes deste fato ou não, por representação de interações intencionais e não intencionais.

As simulações baseadas em agentes utilizam sua habilidade computacional de relacionamento e interação para simular os mais diversos ambientes e propósitos.

Outras características dos SMA, como a flexibilidade, adaptabilidade, pró-atividade, reatividade, autonomia e confiança, permitem que um processo de tomada de decisão possa ser representado por algoritmos complexos. A inter-relação entre agentes permite ainda estabelecer critérios de confiança entre si (RUIZ et al., 2011).

Dadas as características gerais dos SMA sua utilização em estudos para análise de comportamento de consumidores apoiando, por exemplo, estudos de marketing, torna-se factível. Cabe ressaltar que o custo computacional para simulações complexas pode se tornar proibitivo, no entanto, novas abordagens são temas de pesquisa, como a utilização da simulação por unidades de processamento gráfico ou GPU (Graphic Processing Unit) (VOICU, 2013).

O escopo amplo de características e atuação dos SMA permite sua utilização em cenários de aplicação e áreas como segurança, *e-commerce*, detecção de invasão, monitoramento ambiental, processamento de informações distribuídas, proteção de infraestruturas críticas e tomadas de decisões (BAIG, 2012; MAGLIOCCA; BROWN; ELLIS, 2013).

Como exemplo desta diversidade, um SMA foi modelado por (MARTINEZ-GIL; LOZANO; FERNÁNDEZ, 2014) para simulação do comportamento de grupo de pedestres, onde os agentes interagem com os demais integrantes do sistema. Como um agente autônomo, sua finalidade não se limita apenas a atravessar uma rua, mais inclui a habilidade de evitar colisões e obstáculos, proporcionando um ambiente de aprendizado interativo e social.

Ambientes de aprendizagem também se beneficiam de ambiente Multiagente. Interagindo com outras técnicas computacionais como árvores de decisão e Mineração de

Dados, os agentes fortalecem o potencial de aprendizado e aprimoram seus objetivos específicos (LIN et al., 2013).

2.3 MINERAÇÃO DE DADOS

A Mineração de Dados (MD) ou *Data Mining* pode ser definida como o processo de exploração e análise de grandes quantidades de dados, utilizando estratégias automatizadas, com o objetivo de descobrir padrões ou regras que permitam uma melhor compreensão da informação contida nos dados (CARVALHO, 2001; FAYYAD et al., 1996; HAN; KAMBER, 2011).

A MD baseia-se na utilização de algoritmos estatísticos e de inteligência artificial capazes de vasculhar grandes bases de dados de modo eficiente e revelar padrões interessantes e consistentes, tais como agrupamentos, hipóteses e regras de associação, visando detectar relacionamentos sistemáticos entre variáveis e auxiliando na descoberta de conhecimento.

As ferramentas de MD visam prever futuras tendências e comportamentos, auxiliando as empresas no processo de tomada de decisão, com base no conhecimento acumulado e muitas vezes desprezado, contido em seus próprios bancos de dados.

Além destas características, existem diversas funcionalidades ou tarefas de MD. Cada uma delas determina o tipo de problema que será resolvido. As principais são: classificação, descoberta de regras de associação e agrupamento de dados (LIN et al., 2013).

O principal objetivo da classificação é examinar o conjunto de dados de entrada e produzir descrições das características destes dados para cada classe. Para tanto é empregado um algoritmo classificador para determinar as regras de classificação. Com base nestas regras novos conjuntos de dados podem ser classificados de forma automática (FAYYAD et al., 1996).

Na descoberta de regras de associação, os padrões descobertos são apresentados na forma de regras de alto nível do tipo SE...ENTÃO. Normalmente os algoritmos empregados nesta tarefa produzem uma grande quantidade de regras e cabe ao usuário selecionar aquelas que ele julga serem mais úteis para uma determinada aplicação. A tarefa de agrupamento ou *clustering* de dados objetiva agrupar automaticamente um conjunto de dados em dois ou mais grupos, utilizando alguma medida de similaridade entre os valores das variáveis que constituem cada padrão do conjunto (MITCHELL, 1997; RUSSEL; NORVIG, 1995).

São muitos os algoritmos empregados nas tarefas de MD anteriormente descritas. Alguns amplamente utilizados são: Redes Bayesianas, Algoritmos Genéticos, Lógica *Fuzzy*, K-vizinhos mais próximos (KNN), Máquinas de Vetores-Suporte, Redes Neurais Artificiais e Árvores de Decisão (MITCHELL, 1997).

As Árvores de Decisão e as Redes Neurais Artificiais, por exemplo, são técnicas muito poderosas e utilizadas em tarefas de classificação e associação. A primeira é amplamente utilizada nestas tarefas devido ao fato do conhecimento adquirido ser representado por meio de regras que facilitam o entendimento do usuário. Por outro lado, diferentemente das Redes Neurais Artificiais, esta técnica nem sempre usa todos os atributos (variáveis) que representam um padrão para a criação das regras. Isso porque a criação da árvore é baseada na importância dos atributos para a classificação dos padrões (MITCHELL, 1997; RUSSEL; NORVIG, 1995).

2.4 TRABALHOS CORRELATOS

Na literatura podem ser encontrados diversos trabalhos relacionados a jogos de empresas e também sobre a utilização de técnicas de inteligência computacional. No entanto, quando estes temas são investigados em conjunto, poucos trabalhos semelhantes ao desenvolvido nesta dissertação são encontrados. Nos parágrafos a seguir são descritos os principais.

Em Borrajo at al. (2010) agentes virtuais foram modelados para participação no *Simulator for Business Administration* (SIMBA), com dois algoritmos distintos de aprendizagem e um humano especialista, visando maximização de lucros. O trabalho apresenta resultados melhores entre os agentes virtuais em relação aos participantes humanos.

O cenário de incertezas no processo de tomada de decisão em jogos de empresas é abordado em Oderanti (2013) e em Oderanti e De Wilde (2010). Neste estudo, um modelo *Fuzzy*, escrito em linguagem MatLab, foi proposto e modelado de acordo com inferências e experiências de especialistas humanos, determinando suas regras de inferência e desenvolvimento. Um algoritmo de aprendizado foi incrementado no processo de tomada de decisão com bons resultados apresentados. A ferramenta apresenta uso prático na tomada de decisão, no contexto modelado, a servir como aconselhamento em políticas, práticas comerciais e decisões estratégicas, bem como uma visão alternativa sobre a competitividade da empresa. Contudo, o modelo de decisão necessita de certo grau de adaptação e modificação de variáveis para atender a outros ambientes de negócio.

Renna e Argoneto (2010) apresentam uma abordagem baseada em arquitetura de Sistemas Multiagentes para simulação da tomada de decisão, que pode ser aplicada em jogos de empresas ou simuladores. Há pesquisas propondo abordagem entre o planejamento da

produção, negociação e um mercado eletrônico, com foco na relação entre cliente e fornecedores.

Em Zimmermann et al. (2001), é realizado um estudo com uma abordagem de Sistemas Multiagentes e redes neurais artificiais para a análise de preços de mercado e sua macro dinâmica, levando em conta uma dinâmica explícita e implícita para seu modelo de decisão de preço do mercado, considerando que o mercado é interpretado como uma rede consistente de um grande número de interações entre seus agentes.

Em Oderanti et al. (2012), a utilização de técnicas de inteligência computacional, como a lógica *fuzzy*, é empregada como alternativa para análise e no apoio a decisão em situações onde há naturalmente certo grau de incerteza, dado sua natureza técnica, como na negociação salarial entre empregadores e empregados. Diversas variáveis influenciam na composição do índice de reajuste, e para auxilio nesta inferência, um modelo *fuzzy* foi pesquisado sobre um determinado modelo econômico. Sua experimentação e disponibilidade em jogos de empresas são descritos como trabalhos futuros.

Oderanti e De Wilde (2012) consideram que os sistemas de apoio à decisão podem ser adaptados a diversos processos de decisão empresarial, principalmente onde certo grau de incerteza está presente no conjunto das informações disponíveis aos gestores. Situações envolvendo a concorrência de mercado e negociações, inclusive em questões salariais, políticas de marketing, estratégicas, previsão de demanda e custos de produção são objetos de estudo em um experimento utilizando-se de um sistema de inferência *fuzzy*, modelado e testado em um jogo de empresa. O ambiente da simulação comparou grupo de jogadores que testaram o modelo *fuzzy* com outro sem este apoio. Seus resultados foram satisfatórios, pois o emprego do sistema de inferência *fuzzy* permitiu ao grupo que o utilizou tomar decisões mais eficazes e eficientes, obtendo melhores resultados no ambiente da simulação.

Pesquisas realizadas envolvendo agentes virtuais autônomos competindo em um jogo de empresas, com liberdade nas tomadas de decisões, geralmente obtém bons resultados em relação aos jogadores humanos. No entanto, a finalidade competitiva destes agentes virtuais não é disponibilizar instruções e auxílio aos jogadores reais (alunos) durante o jogo.

Algumas destas pesquisas buscam realizar inferências acerca das melhores tomadas de decisão, em um jogo de empresas, a disponibilizar apoio aos alunos. No entanto, a base de inferência é construída por um especialista, a situações e cenários pré-determinados.

As pesquisas encontradas não abordam inferências sobre as tomadas de decisão, em um jogo de empresas, em seu próprio universo de decisões, ou seja, considerando as melhores tomadas de decisão em relação aos melhores resultados obtidos pelos alunos (notas de avaliação). Ainda, as pesquisas encontradas não abordam agentes virtuais modelados para geração de mercados consumidores virtuais, caracterizados para uso em jogos de empresas.

3 MATERIAIS E MÉTODOS

Nesta seção são apresentados a caracterização da pesquisa, a descrição do jogo utilizado para realização dos experimentos, o processo para extração dos dados utilizados nos experimentos, bem como a metodologia empregada para realização dos experimentos.

3.1 CARACTERIZAÇÃO DA PESQUISA

Quanto ao método de pesquisa, este trabalho utiliza-se da modelagem e simulação, uma vez que se pretende prever e realizar mudanças em um sistema e por permitir a construção de modelos visando o entendimento do comportamento de tomada de decisão em um determinado sistema. Quanto à abordagem do problema, este trabalho se caracteriza como uma pesquisa quantitativa, pois emprega meios estatísticos, tanto em sua coleta quanto no tratamento de dados e por procurar uma classificação entre as variáveis envolvidas na simulação (BERTRAND; FRANSOO, 2002; GIL, 2008; MORABITO; PUREZA, 2010).

3.2 JOGO DE EMPRESAS UTILIZADO NOS EXPERIMENTOS

Para a realização dos experimentos descritos neste trabalho foi utilizado um Jogo de Empresas, denominado Simulador de Administração Empresarial (SAE), aplicado no curso de Administração de Empresas da Universidade Nove de Julho - UNINOVE, o qual teve sua primeira versão estável em meados de 2003 e é de autoria e direitos dos professores José Domingos Estivalli, Felipe Amendola e Daniel Ferreira de Barros Jr (BARROS JR et al., 2013). Trata-se de um jogo onde se simula a administração de uma indústria de eletrodomésticos, no caso, de aspirador de pó, considerando duas linhas de produção, “Luxo” e “Standard”. A ação dos jogadores se dá por meio da tomada de decisões na simulação.

O SAE estimula a tomada de decisão, participação em grupo, e a visão sistêmica da gestão empresarial por meio do resgate, ponderação e reflexão dos conceitos de gestão de produção, vendas, marketing, finanças e estratégias de negócio diante dos cenários e desafios apresentados. O mesmo visa simular as decisões na operação de uma fábrica de eletrodomésticos, em um período anual, mês a mês, perfazendo doze rodadas de decisão. A primeira etapa é dedicada à explicação e testes dos alunos no jogo, a fim de se evitar problemas quanto à operação na simulação.

O SAE possui controle de acesso e nível de usuário, permitindo assim a definição de personagens claros: O Professor e o Estudante.

O professor é o facilitador do jogo de empresas, e tem por objetivo controlar a simulação, administrar o conteúdo e zelar pelo bom andamento das tomadas de decisões dos estudantes. Criar e administrar os cenários externos e internos às empresas também é atividade deste personagem. Para tanto, deve ter domínio dos cenários de demanda e do mercado atacadista.

O estudante é o administrador da empresa simulada, o jogador. Ele tem por objetivo cumprir as metas estabelecidas e realizar as tomadas de decisão da melhor forma possível. Ele possui papel central na simulação, pois é o foco desta dinâmica. Sua participação no jogo de empresas pode ocorrer de maneira individual ou em grupo. Habitualmente a participação em grupo é estimulada e praticada no SAE, sendo a participação individual uma exceção.

Neste primeiro contato, o jogador já possui acesso a suas metas objetivas prévias e valores mensuráveis, representadas pelos indicadores de desempenho. Os dados são relativos ao período mensal, finalizado por um resultado final anual. Esta divisão em períodos visa dar um contorno temporal, fracionando os dados para uma melhor análise das decisões e o relacionamento de causa e efeito nos resultados. A figura 4 apresenta a tela inicial do simulador,

onde há disponibilidade dos comandos e atalhos para as telas de tomada de decisão, relatórios e indicadores de desempenho.

Figura 4. Tela principal do SAE.

As metas dos indicadores de desempenho são ajustadas ainda nesta etapa inicial, balizadas por um planejamento estratégico e orçamentário, de cada empresa participante. Estes valores são analisados e ajustados pelo facilitador na simulação, e as novas metas e objetivos norteiam as ações no jogo de empresas.

Certos objetivos mensuráveis dos indicares de desempenho informam os valores e resultados obtidos por meio das decisões indiretas dos competidores. A estes são computados:

- Faturamento.
- Lucro.
- Quantidade de produtos entregues (vendidos).

- Lucratividade.
- Controle de estoque (Matéria prima e Produto acabado).

A orientação por metas ganha nova relevância, pois a composição da nota final de avaliação do competidor é baseada nos valores anuais obtidos pelos indicadores de desempenho, incluindo-se os resultados de investimentos de qualificação e melhoria da empresa. Os resultados destas qualificações apenas surtem efeito após incrementos de volume financeiro investido, divididos em cinco níveis, classificados nos indicadores de desempenho como estrelas, a exemplo da classificação dos hotéis, para demonstrar a qualidade. Os investimentos de melhoria levados em consideração no SAE são:

- Meio Ambiente.
- Tecnologia do Produto.
- Treinamento de mão de obra.
- Publicidade.

A figura 5 exemplifica a tela do simulador destinada aos investimentos de melhoria, descritos com decisões estratégicas.

Figura 5. Decisões estratégicas.

Espera-se do competidor o cumprimento de diversos objetivos, orientado por metas e indicadores periódicos. Para tanto, o jogador possui a seu dispor um conjunto de variáveis de decisão, as quais são apresentadas na tabela 1.

Tabela 1. Variáveis de decisão do jogo de empresas.

Descrição da variável de decisão	Abreviação da variável
Investimentos em processos relativos à gestão ambiental	MA
Investimentos em melhorias de processos de fabricação	TPROC
Investimentos em tecnologia e desenvolvimento de produto	TPROD
Investimentos em Publicidade	PUBL
Preço de venda produto Luxo	PVL
Preço de venda produto Standard	PVS
Contratação de funcionários para linha de produção Luxo	CL
Contratação de funcionários para linha de produção Standard	CS
Demissão de funcionários da linha de produção Luxo	DL
Demissão de funcionários da linha de produção Standard	DS
Compra de matéria prima para a produção de produtos Luxo	CMPL
Compra de matéria prima para a produção de produtos Standard	CMPS

Fonte: Adaptado de (Barros Jr et al., 2013)

A valoração do conjunto de variáveis de decisão se dá em rodadas, caracterizando os ciclos mensais do ano fiscal da empresa. Somam-se a estas as variáveis hora extra para linha de produção Luxo e Standard, além da decisão sobre qual qualidade e tipo de matéria prima deve ser adquirida para cada linha de produção. Esta qualidade de matéria prima está delimitada entre qualidade A ou B e representa, respectivamente, menor e maior quantidade de refugo (peças defeituosas) de produtos acabados.

As variáveis de investimentos, contratação e demissão possuem limites de incrementos fixos configuráveis, ao passo que as variáveis de preço e compra de matéria prima são valores inteiros livres ao competidor.

A Figura 6 apresenta a tela do SAE destinada as decisões operacionais.

Figura 6. Decisões Operacionais (SAE)

A dinâmica da participação do competidor se dá em etapas distintas, com finalidades diversas. A interação e ação do aluno no jogo é fator essencial em todas as etapas, tendo o facilitador como seu principal orientador. Característico dos jogos de empresas, o processo de aprendizagem vivencial tem como ponto principal o aluno. O roteiro da participação do aluno no SAE pode ser descrito conforme figura 7.

Figura 7. Roteiro de participação do aluno no SAE.

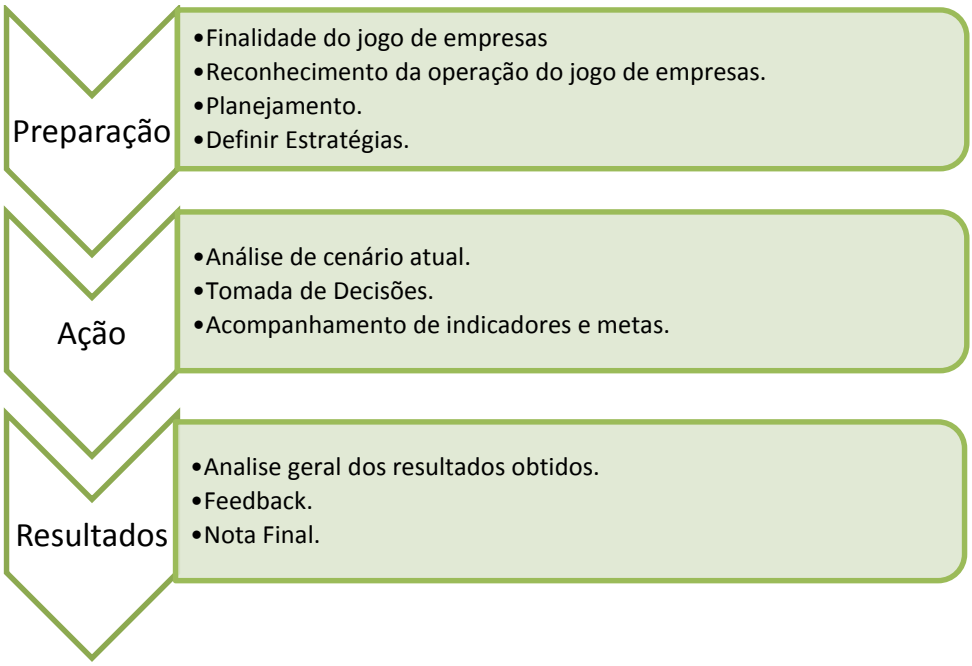

O fluxo de informações do SAE pode ser representado como mostra a figura 8, onde observa-se a interação dos jogadores e o simulador, bem como a interação do facilitador. Não há módulos extras e intermediários entre simulador e seus usuários, caracterizando uma utilização sem intermediários. Neste modelo há capacidade para acréscimo de módulos extras de apoio aos jogadores e facilitadores, que é o objeto de estudo deste trabalho.

Figura 8. Arquitetura atual do SAE.

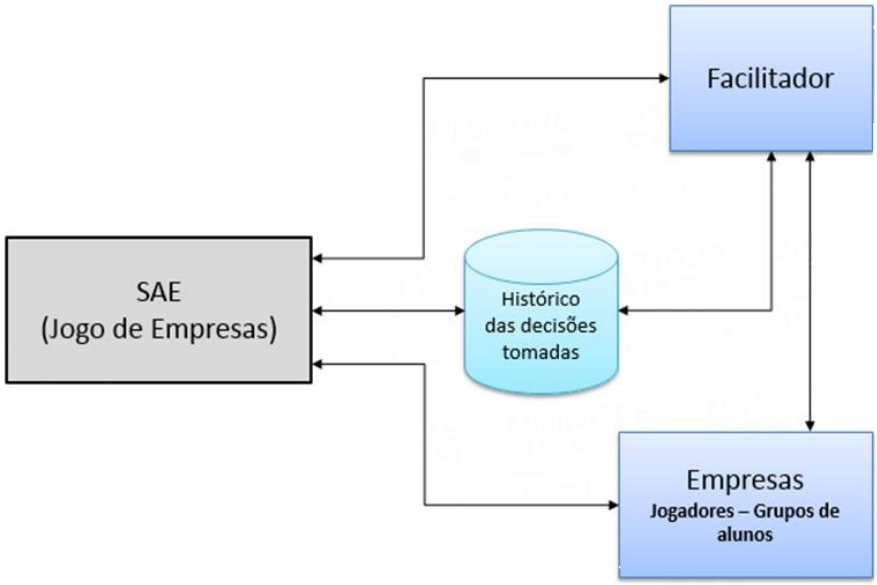

Ao facilitador cabe, além da orientação e dinâmica do jogo de empresas, algumas operações de apoio ao ambiente da simulação, dentre estas:

- Gestão dos cenários externos.
- Gestão da demanda.
- Gestão do ambiente de negociação.

Estas operações são de responsabilidade do facilitador e possuem condução e ações heterogêneas entre docentes distintos, até mesmo diante de um manual de orientação à

simulação. Um fator limitante à experiência e condução das atividades do facilitador está relacionado à quantidade de empresas, ou grupos participantes simultaneamente, dado a execução e gestão das diversas atribuições em curto espaço de tempo. A figura 9 exibe a dinâmica de atividades do facilitador.

Figura 9. Dinâmica de atividades do facilitador.

A gestão dos cenários externos, internos e sazonalidades, não são registradas e operadas no SAE, sendo seu comunicado informado por meio de “Jornal”, “Informativos” ou “Comunicados” aos participantes. As informações presentes relatam as características, dados técnicos e dificuldades sazonais relativos ao mês corrente na simulação.

Outra dinâmica importante é a comercialização no ambiente simulado. As empresas participantes negociam seus produtos manufaturados a um ou mais revendedores (atacadistas) definidos pelo facilitador, os quais realizam a venda ao consumidor final (fictício). O atacadista

é interpretado pelo próprio facilitador, a realizar a negociação individualmente com cada participante ou em leilões simulados para compra de grandes lotes de produtos manufaturados. Os critérios para decisão da quantidade comercializada são balizados nas características atuais de cada participante, bem como nos cenários vigentes e objetivos da simulação. No entanto, ela é efetuada fora do ambiente da simulação, e caracterizada por certa subjetividade e temporalidade.

A definição do tamanho da demanda, o consumidor final, bem como suas características, necessidades, preferências, relações de consumo e sociabilidade não são mensurados na simulação. As características deste mercado são apontadas nos relatórios e comunicados de forma generalizada, a fim de explicitar e orientar as ações estratégicas e de marketing dos participantes. Não há no simulador um módulo destinado ao facilitador para tratar destes dados e resultados.

A relação com os fornecedores de matéria prima na simulação recebe o mesmo tratamento e operação dos atacadistas, ou seja, suas particularidades e decisões são de responsabilidade do facilitador.

No encerramento do período de decisão, o aluno obtém um resultado final de suas metas, por meio dos indicadores de desempenho. No Anexo B é apresentado um diagrama informativo que descreve o fluxo de ação no SAE.

Este resultado deve contemplar a auto avaliação de suas ações com incremento do *feedback* do facilitador. Por reflexo de sua participação e resultado, o critério de avaliação final do aluno, e nota da atividade no jogo de empresas, é composta por diversos atributos. Um critério desenvolvido ao longo do tempo, e de caráter empírico, e a adoção dos resultados e metas informados nos indicadores de desempenho para composição da nota final do aluno.

Este critério de notas propõe mensurar sua participação e decisões. Os indicadores observados, definidos ainda na construção do simulador, são apresentados a seguir:

- Faturamento.
- Lucro.
- Quantidade Entregue (vendida).
- Lucratividade.
- Controle de estoque (Matéria prima e Produto acabado).
- Investimento em Meio Ambiente.
- Investimento em Tecnologia do Produto.
- Investimento em Treinamento.
- Investimento em Publicidade.

A figura 10 exemplifica a utilização dos indicadores de desempenho no SAE, orientando as ações dos alunos, resultados e norteando as futuras ações gerenciais. Estes indicadores de desempenho são convencionados no SAE como componentes de um BSC, no entanto, o simulador não trata de todas as perspectivas correspondentes ao *Balanced Scorecard* proposto por Kaplan e Norton (1997), sendo elas as perspectivas financeira, clientes, processos internos e de aprendizado e crescimento. Este trabalho não trata desta simplificação ou do mérito sobre a falta de algumas perspectivas, apenas aceita estes valores como indicadores de desempenho.

Figura 10. Indicadores de Desempenho SAE.

BALANCED SCORECARD GRUPO 8

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ	TOTAL
FATURAMENTO (000)													
Previsto	1.600,0	1.800,0	2.300,0	2.250,0	2.850,0	1.900,0	2.000,0	2.300,0	2.000,0	2.500,0	2.700,0	3.200,0	**27.400,0**
Realizado	1.724,11	1.404,00	2.104,10	1.067,20	2.850,93	2.418,08	4.190,56	3.845,87	2.686,70				**22.291,54**
Variação	108%	78%	91%	47%	100%	127%	210%	167%	134%				**81%**
LUCRO (000)													
Previsto	95,0	130,0	210,0	180,0	200,0	120,0	135,0	220,0	150,0	230,0	260,0	300,0	**2.230,0**
Realizado	-115,95	-102,90	249,09	-281,58	300,42	84,88	443,70	402,94	230,92				**1.211,52**
Variação	-122%	-79%	119%	-156%	150%	71%	329%	183%	154%				**54%**
QUANT. ENTREGUE													
Previsto	4.719	5.506	6.665	6.620	8.193	5.217	5.713	6.665	6.085	7.283	7.825	9.310	**79.801**
Realizado	5.529	4.100	6.300	3.316	10.102	8.506	13.253	12.077	8.812				**71.995**
Variação	117%	74%	95%	50%	123%	163%	232%	181%	145%				**90%**
Estoque Matéria Prima													
Metas	500	500	500	500	500	500	500	500	500	500	500	500	**500**
Real													
Estoque Produto Acabado													
Metas	500	500	500	500	500	500	500	500	500	500	500	500	**500**
Real													
Lucratividade													
Previsto	5,9%	7,2%	9,1%	8,0%	7,0%	6,3%	6,8%	9,6%	7,5%	9,2%	9,6%	9,4%	**8,1%**
Realizado	-7%	-7%	12%	-26%	11%	4%	11%	10%	9%	#DIV/0!	#DIV/0!	#DIV/0!	**5%**
	-114%	-102%	130%	-330%	151%	56%	156%	109%	115%	#DIV/0!	#DIV/0!	#DIV/0!	**67%**

As composições das notas finais recebem valores ponderados de acordo com os objetivos traçados no início da simulação. Esta prática procura encontrar uma forma de classificar não apenas a participação e o aprendizado vivencial do aluno, mas incluir o mérito mensurável de seus resultados objetivos na simulação.

For fim, um breve relato sobre as percepções, recomendações individuais ou coletivas (pontos a desenvolver ou fortalecer), associações, o resgate de conceitos obtidos durante o curso vigente, suas relações e proximidades quanto a situações reais no ambiente empresarial real, e as diversas experiências na simulação encerram a dinâmica neste jogo de empresas.

3.3 COMPOSIÇÃO DO CONJUNTO DE DADOS PARA OS EXPERIMENTOS

Para os experimentos descritos neste trabalho empregaram-se dados extraídos da base de decisões SAE. Os dados coletados das simulações são do segundo semestre de 2012, no qual 33 turmas de oitavo semestre dos cursos de Administração de Empresas, Administração de Empresa com ênfase em Marketing e Administração de Empresas com ênfase em Comércio Exterior (COMEX) da Universidade Nove e Julho utilizaram o jogo. As simulações foram conduzidas por 17 professores diferentes e envolveram mais de 1600 alunos matriculados nas 4 unidades da instituição. A tabela 2 relaciona o universo de alunos matriculados nos cursos envolvidos.

Tabela 2. Universo da coleta de dados.

Curso	Turmas	Alunos
Administração	25	1312
COMEX	4	188
Marketing	4	168

O conjunto de dados coletados para os experimentos foi extraído a partir de um universo de 14 turmas de graduação, 42,4% do total de turmas que utilizaram o jogo no semestre considerado. A condução destas simulações se deu por 3 professores distintos, representando 17,6% do total de professores. Os alunos são representativos de três campi e correspondem a um total de 48,5% dos alunos destes cursos.

A escolha das turmas para extração do conjunto de dados se deu principalmente pela expertise dos professores correspondentes, pois possuem domínio na condução e na dinâmica do SAE.

Inicialmente o conjunto de dados foi composto a partir de um total de 180 grupos participantes. Após a realização de pré-processamento e análise da consistência dos dados, foram eliminados os grupos que não jogaram em dois ou mais meses (rodadas), restando o total de 129 grupos selecionados.

Em processo semelhante na análise e consistência de dados, foram eliminadas decisões incompletas ou irrelevantes, caracterizadas por possuírem sempre o mesmo valor. Sendo assim, cada grupo participante realizou 12 tomadas de decisões objetivas a cada ciclo mensal (variáveis de decisão mostradas na Tabela 1), totalizando 144 decisões no final da simulação, perfazendo um total de 18.576 tomadas de decisões registradas no conjunto de dados. A totalidade destes dados caracteriza o conjunto de dados primário, tendo em vista que os demais experimentos geram outros conjuntos de dados (secundários) a partir dele.

3.4 METODOLOGIA PARA CONDUÇÃO DOS EXPERIMENTOS

Neste trabalho foram conduzidos três experimentos envolvendo a aplicação de técnicas de Inteligência Computacional no SAE.

O primeiro deles, denominado experimento 1, envolveu a aplicação de Mineração de dados (classificação e associação usando árvore de decisão (Algoritmo ID3) e uma rede neural artificial MLP) para investigar a existência de padrões nas decisões tomadas pelos diferentes grupos de jogadores. A ideia foi partir desta investigação e disponibilizar os padrões descobertos para realização de inferências nos dois outros experimentos. Nesta etapa foi utilizado o software WEKA para a condução do experimento.

No experimento 2 foi proposto um mecanismo de Inferência *Fuzzy* para auxílio aos jogadores. Para a definição das regras de inferência do modelo *fuzzy* proposto foram utilizadas as regras geradas pela árvore de decisão (ID3) do experimento 1. A finalidade do modelo *fuzzy*

é inferir o desempenho do jogador com base nos valores decididos por ele para as variáveis de decisão da Tabela 1. A ideia é fornecer uma ajuda, um *feedback*, para o jogador balizar suas decisões no jogo. Neste experimento utilizou-se o software Matlab, por meio da *toolbox fuzzy*, para a construção do mecanismo de inferência.

O experimento 3 utilizou-se de um descritivo básico do comportamento de um mercado consumidor para modelá-lo por meio de Sistemas MultiAgentes. O modelo leva em consideração o relacionamento entre os consumidores, cenário externo e sazonalidades, parametrizáveis no modelo. A finalidade deste módulo é auxiliar o facilitador do jogo, uma vez que ele pode parametrizar algumas poucas variáveis e gerar diferentes mercados para o jogo. Em outras palavras, o facilitador passa a ter uma ferramenta que o auxilia na proposição de mercados com os quais os jogadores devem interagir. Nesta etapa foi utilizado o software NetLogo para condução do experimento.

4 RESULTADOS

Nesta seção são apresentados e discutidos os resultados obtidos com os três experimentos mencionados nas seções anteriores.

4.1 EXPERIMENTO 1 – MINERAÇÃO DE DADOS PARA INVESTIGAR A EXISTÊNCIA DE PADRÕES NAS DECISÕES TOMADAS PELOS DIFERENTES GRUPOS DE JOGADORES

Para realização deste experimento foram empregados recursos de classificação por árvore de decisão (Algoritmo ID3) e por uma rede neural artificial *Multilayer Perceptron* (MLP). Na verdade, foram realizados dois estudos, um com foco na análise da variabilidade dos valores das variáveis de decisão (Estudo 1) e o outro com base nos valores médios das variáveis de decisão de cada grupo com relação aos valores médios destas variáveis considerando todos os grupos de jogadores (Estudo 2). Os dois conjuntos de dados utilizados nos estudos 1 e 2 foram derivados do conjunto de dados Primário e denominados Conjunto_MD1 e Conjunto_MD2.

Para realização dos testes empregou-se o WEKA (HALL et al. 2009), uma das mais populares ferramentas de Mineração de Dados em ambiente acadêmico, e que disponibiliza diversos algoritmos provenientes da estatística e da inteligência artificial.

Em uma primeira fase procedeu-se o processo de extração, limpeza e tratamento dos dados brutos da base de dados do SAE com a finalidade de compor os dois conjuntos de dados a serem analisados pelos algoritmos de Mineração de Dados (MD).

Para cada experimento, os valores das variáveis mostradas na Tabela 1, os quais compõem os conjuntos de dados, foram transformados, normalizados, discretizados e

categorizados, de acordo com o objetivo do experimento, conforme descrito nas subseções 4.1.1 e 4.1.2.

Ambos os conjuntos de dados (Conjunto_MD1 e Conjunto_MD2) foram compostos por 129 registros (padrões), cada um deles com 13 atributos, 12 representando as variáveis de decisão (Tabela 1) e um atributo representando a classe do padrão.

4.1.1 Tratamento dos dados para composição do Conjunto_MD1

Transformação: calculou-se, para cada grupo, o desvio padrão de cada uma das variáveis de decisão considerando os valores informados nos doze períodos;

Normalização: dividiu-se o valor de cada variável de decisão pelo valor máximo encontrado para a mesma variável considerando os 129 grupos. Assim, os valores das variáveis foram normalizados para o intervalo [0,1].

Discretização e categorização: com base no histograma de cada variável de decisão, foram definidos três intervalos, os quais foram categorizados como {Pequeno, Médio, Grande}. A variável Nota_Grupo, que define a classe do padrão, foi categorizada como {Baixa, Média, Alta}.

4.1.2 Tratamento dos dados para composição do Conjunto_MD2

Transformação: calculou-se, para cada grupo, um coeficiente dividindo-se o valor médio de cada variável ao longo de doze períodos pela média geral da mesma variável considerando os 129 grupos de jogadores. Este coeficiente serviu, por exemplo, para posicionar o valor médio de uma variável de decisão praticado por um grupo considerando os valores médios praticados pelos seus concorrentes. Assim, valores próximos de 1 indicavam que o valor

praticado pelo grupo estava na média geral. Valores muito maiores que 1, acima da média geral e valores muito menores que 1, abaixo da média geral.

Normalização: Não foi necessária, pois o resultado da transformação já permitiu categorizar os dados.

Discretização e categorização: com base no histograma de cada variável, foram definidos três intervalos, os quais foram categorizados como {Abaixo, Média, Acima}. A exemplo do conjunto anterior a variável NOTA_GRUPO foi categorizada como {Baixa, Média, Alta}.

4.1.3 Avaliação de desempenho dos classificadores

Para a avaliação do desempenho dos algoritmos empregados nos experimentos realizados em BARRO JR et al. (2013) (árvores de decisão – ID3 e redes neurais artificiais – Multilayer Perceptron) empregou-se a taxa de acertos (equação 1).

$$\text{Taxa de Acertos(TA)} = \frac{VP}{VP + FN} \times 100 \qquad (1)$$

A taxa de acertos é calculada a partir da matriz de confusão ou tabela de contingência (FAWCETT, 2006), mostrada na Tabela 3 e pode ser definida como a razão entre o número de classificações corretas realizadas pelo algoritmo e o total de padrões analisados.

Tabela 3. Matriz de confusão.

Classe predita pelo algoritmo	Classe verdadeira	
	Positivo	Negativo
Positivo	Verdadeiro Positivo (VP)	Falso Positivo (FP)
Negativo	Falso Negativo (FN)	Verdadeiro Negativo (VN)

Fonte: (BARROS JR et al., 2013)

Com base na matriz de confusão também são derivadas as medidas precisão, acurácia, curvas *recall-precision* e curvas ROC (*Receiver Operating Characteristic*), entre outras.

Nas subseções 4.1.4 e 4.1.5 são apresentados os resultados dos estudos com os conjuntos de dados MD1 e MD2. Em ambos os estudos foram realizadas tarefas de classificação dos dados e geração de regras de associação. A classificação teve como objetivo avaliar a similaridade dos dados pertencentes à mesma classe (definida pela variável Nota_Grupo) em cada conjunto. Também foram feitos experimentos envolvendo as regras de associação com intuito de descobrir associações e correlações entre os dados objetivando derivar novos conhecimentos a partir dos conjuntos de dados analisados.

4.1.4 Análise da similaridade dos padrões com relação à variabilidade dos valores das variáveis de decisão.

Neste experimento considerou-se o Conjunto_MD1, no qual os atributos representam os desvios padrões das variáveis de decisão. As tabelas 4 e 5 mostram as matrizes de confusão das classificações feitas pela árvore de decisão (algoritmo ID3) e pela rede neural *Multilayer Perceptron* (MLP).

Tabela 4. Matriz de confusão da classificação dos dados do Conjunto_MD1 pela árvore de decisão ID3

Classe predita pelo algoritmo	Classe verdadeira		
	Baixa	Média	Alta
Baixa	10	4	3
Média	1	38	5
Alta	5	12	51

Tabela 5. Matriz de confusão da classificação dos dados do Conjunto_MD1 pela rede neural MLP

Classe predita pelo algoritmo	Classe verdadeira		
	Baixa	Média	Alta
Baixa	7	4	6
Média	0	37	7
Alta	2	11	55

Fonte: Adaptado de (Barros Jr et al., 2013)

Nas matrizes de confusão mostradas nas tabelas 5 e 6, as classificações corretas são localizadas nas diagonais principais. Como pode ser visto nestas tabelas, embora os acertos tenham sido diferentes entre as classes, ID3 e MLP tiveram a mesmo número de 99 acertos entre 129 classificações, o que corresponde a uma taxa de acertos de 76,7%, considerados como bons resultados em relação aos resultados com outros algoritmos.

A questão do número de acertos de ID3 e MLP serem diferentes para uma mesma classe está relacionada ao número e ordem das variáveis de decisão utilizadas no processo de classificação.

Pode-se perceber também que, para ambos os classificadores, o número de erros para a classe Baixa foi muito mais alto que para as demais classes. Isso significa que, utilizando os desvios padrões das variáveis de decisão, fica difícil predizer a tendência de aproveitamento de um grupo para padrões similares aos da classe Baixa.

Com relação às regras de associação, aplicando o algoritmo "*Predictive Apriori*" do WEKA no Conjunto_MD1 foram geradas 100 regras, entre as quais estão as mostradas a seguir:

1. **SE** TPROC=Pequeno **E** PUBL=Medio **ENTÃO** NOTA_GRUPO=Alta (TA=94%)

2. **SE** MA=Grande **E** TPROC=Medio **E** PUBL=Grande **ENTÃO** NOTA_GRUPO=Alta (TA=89%)

3. **SE** TPROC=Medio **E** Tecnol_Prod=Pequeno **ENTÃO** NOTA_GRUPO=Baixa (TA=86%)

4. **SE** PVL=Medio **E** CMPL=Medio **ENTÃO** NOTA_GRUPO=Media (TA=78%)

5. **SE** PVS=Pequeno **E** CMPS=Medio **ENTÃO** NOTA_GRUPO=Alta (TA=64%)

Estas e outras regras geradas poderiam ser utilizadas no jogo tanto para auxiliar os jogadores quanto o professor, já que revelam conhecimentos que não estão explícitos no conjunto de dados.

4.1.5 Análise da similaridade dos padrões com relação ao posicionamento dos valores das variáveis de decisão

Neste experimento considerou-se o Conjunto_MD2, no qual os atributos representam os posicionamentos dos valores médios das variáveis de decisão de cada grupo com relação às médias gerais destas variáveis (considerando os 129 grupos). As tabelas 6 e 7 mostram as matrizes de confusão das classificações feitas pela árvore de decisão e pela rede neural.

Tabela 6. Matriz de confusão da classificação dos dados do Conjunto_MD2 pela árvore de decisão ID3

Classe predita pelo algoritmo	Classe verdadeira		
	Baixa	Média	Alta
Baixa	17	0	0
Média	1	43	0
Alta	0	5	63

Tabela 7. Matriz de confusão da classificação dos dados do Conjunto_MD2 pela rede neural MLP

Classe predita pelo algoritmo	Classe verdadeira		
	Baixa	Média	Alta
Baixa	17	0	0
Média	1	38	5
Alta	0	1	67

Fonte: Adaptado de (Barros Jr et al., 2013)

Os resultados descritos nas tabelas 6 e 7 mostram que os acertos de ID3 (123/129 ou 95,3%) foram ligeiramente maiores que os de MLP (122 acertos entre 129 classificações ou 94.6%).

A alta taxa de acertos para ambos os classificadores sinaliza que, utilizando os posicionamentos dos valores médios das variáveis de decisão com relação às médias gerais, pode-se predizer, com alto grau de certeza, a tendência de aproveitamento de um grupo.

Com relação às regras de associação, aplicando o algoritmo "*Predictive Apriori*" do WEKA no Conjunto_MD2, foram geradas 100 regras, entre as quais estão as mostradas a seguir:

1. **SE** MA=Acima **E** TPROC=Media **ENTÃO** NOTA_GRUPO=Alta (TA=91%)

2. **SE** MA=Acima **E** TPROC=Acima **E** PUBL=Media **ENTÃO** NOTA_GRUPO=Media (TA=91%)

3. **SE** PVL=Abaixo **E** CL=Abaixo **E** CMPL=Abaixo **ENTÃO** NOTA_GRUPO=Baixa (TA=95%)

4. **SE** PVS=Media **E** CMPS=Acima **ENTÃO** NOTA_GRUPO=Alta (TA=99%)

5. **SE** PVS=Abaixo **E** CMPS=Abaixo **ENTÃO** NOTA_GRUPO=Baixa (TA=87%)

A exemplo das regras geradas a partir do Conjunto_MD1, estas regras poderiam ser utilizadas no jogo para auxiliar tanto os jogadores quanto o professor.

Com base nos resultados apresentados, pode-se dizer que a metodologia empregada na composição do Conjunto_MD2 apresentou melhores resultados para predição de tendências no jogo.

Não obstante, as regras geradas pelos classificadores são de extrema importância porque, uma vez aplicadas ao jogo, podem enriquecer sua dinâmica no sentido de torná-lo "inteligente" ao ponto de dar indícios para os jogadores sobre seus rendimentos com relação às suas metas.

Cabe ressaltar que estas regras, principalmente as de associação, podem também auxiliar o professor na proposição de novos cenários.

4.2 EXPERIMENTO 2 - APLICAÇÃO DE LÓGICA FUZZY PARA AUXÍLIO À TOMADA DE DECISÕES DOS JOGADORES

Para condução do experimento 2, utilizou-se o Conjunto_MD2 como fonte de dados, devido aos melhores resultados obtidos na tarefa de classificação realizada no experimento 1. Para a definição das regras de inferência do modelo *fuzzy* foram utilizadas as regras geradas pela árvore de decisão (ID3) do experimento 1.

No desenvolvimento deste experimento utilizou-se o software *Matlab*, por meio da *toolbox fuzzy*, para a construção do mecanismo de inferência.

As variáveis selecionadas pelo algoritmo ID3, para classificação dos dados, compreendem as decisões mais relevantes dos alunos para determinação dos seus desempenhos. Do total de 12 variáveis de decisão, o algoritmo ID3 selecionou um conjunto de 10 variáveis relevantes. São elas:

- Lucro.
- Investimentos em Tecnologia de Processo.
- Compra de Matéria-Prima Standard.
- Contratação para linha de produção Standard.
- Preço de Venda da linha Luxo.
- Investimentos em Meio Ambiente.
- Contratação para linha de produção Luxo.
- Compra de Matéria-Prima Luxo.
- Demissão da linha de produção Standard.

- Preço de Venda da linha Standard.

A variável Lucro é um indicador de desempenho informado no SAE. As demais variáveis são variáveis de decisão, determinado pelos próprios alunos, as respectivas empresas.

Para cada variável selecionada pelo algoritmo, foi gerado um histograma, com intuito de modelar os conjuntos *fuzzy*. Por exemplo, o histograma da variável compra de matéria-prima Standard (CMPS) a figura 11 ilustra a frequência desta variável.

Figura 11. Histograma da variável de decisão CMPS.

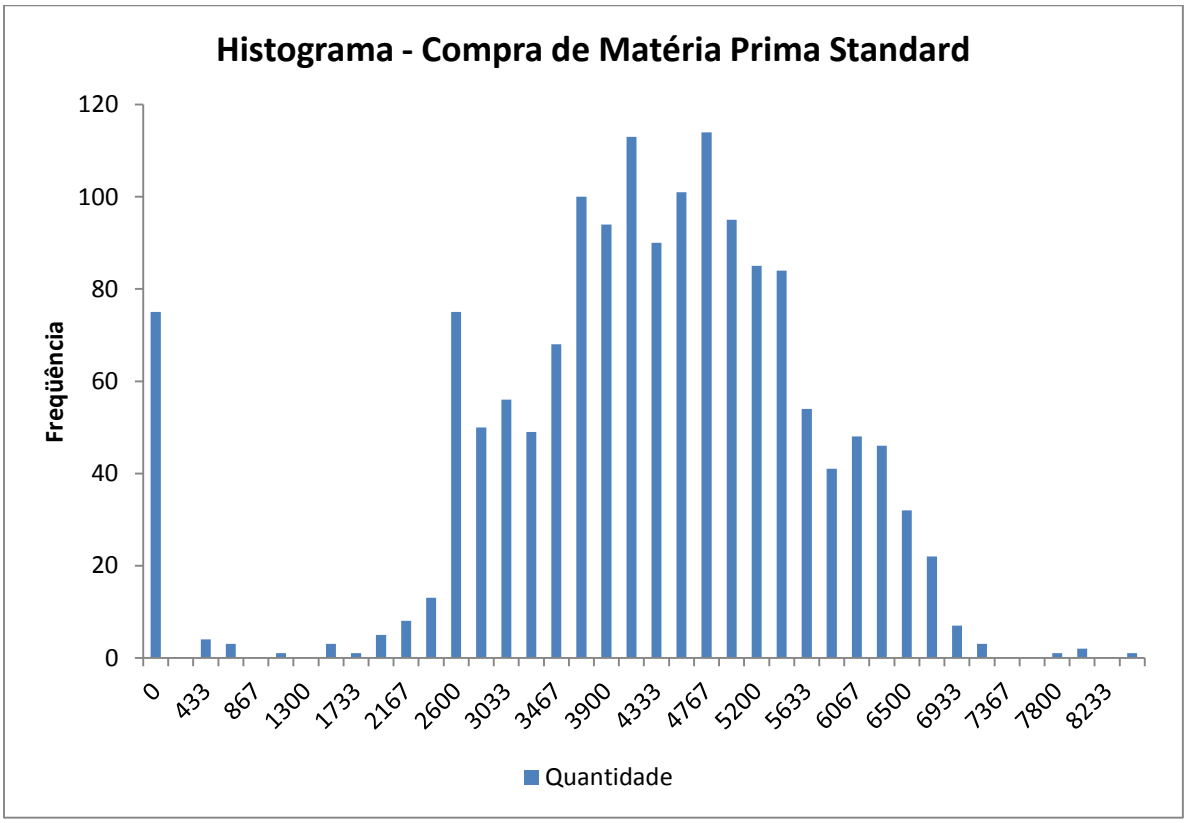

Para cada histograma gerado, uma variável linguística foi criada e configurada no modelo *fuzzy*.

A figura 12 exibe o histograma da variável do preço de venda Luxo, com a correspondente frequência de valores. Neste caso, o intervalo entre 350 e 360 obteve a maior frequência, ou ocorrência.

Figura 12. Histograma da variável PVL

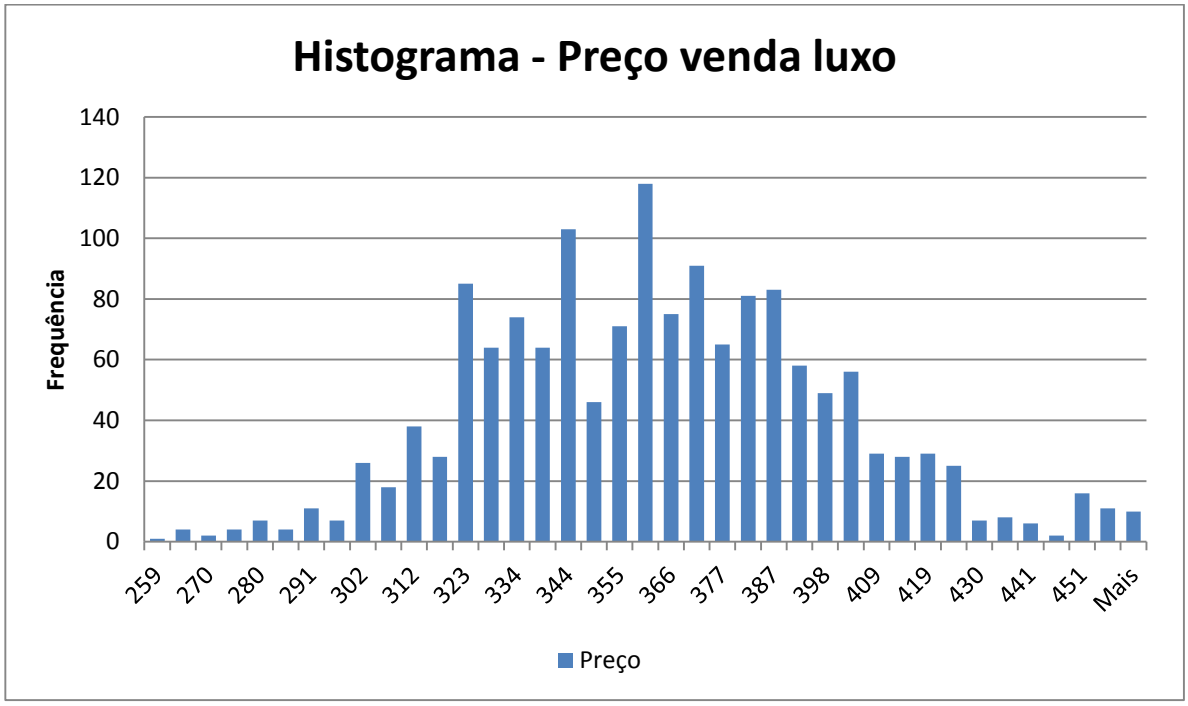

Os valores obtidos no histograma são delimitados em três intervalos: Baixo, Médio e Alto, os quais são interpretados como conjuntos em cada variável no modelo *fuzzy*.

A exemplo disto, a variável linguística CMPS foi modelada no mecanismo de inferência *fuzzy* com três conjuntos: baixo, médio e alto, definidos com base no histograma exibido na figura 11.

Na figura 13, a variável PVL tem o conjunto “baixo” configurado com base nos valores 40 (mínimo), 200 (médio) e 329,6 (máximo), os quais definem o formato da função de pertinência.

Figura 13. Funções de pertinência associadas à variável PVL.

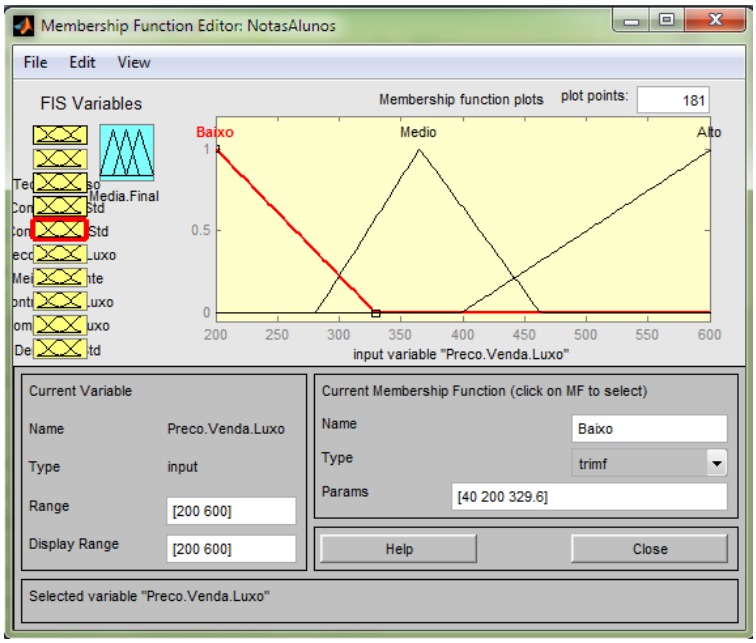

A interseção dos conjuntos Baixo/Médio e Médio/Alto são características dos modelos *fuzzy*.

A figura 14 ilustra as variáveis de entrada e saída do modelo de inferência proposto.

Figura 14. Variáveis de entrada/saída do mecanismo de inferência *fuzzy*.

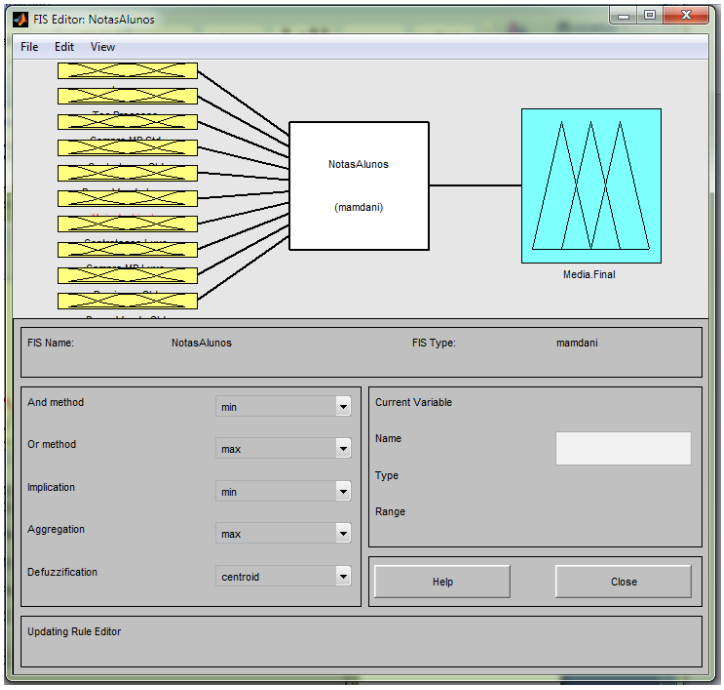

O processo seguinte se deu com a configuração das regras de inferências no modelo. Estas regras foram obtidas a partir da árvore gerada no Experimento 1, pelo algoritmo ID3. Tais regras possuem um encadeamento de definições SE...ENTÃO, como por exemplo:

SE Lucratividade = Media **E** Meio Ambiente = Media **E** Preco Venda STD = Media **ENTÃO** Nota = **Alta**.

SE Lucratividade = Baixo **E** Tecnologia Processo = Acima **E** Preco Venda LUXO = Media **ENTÃO** Nota = **Media**.

SE Lucratividade = Baixo **E** Tecnologia Processo = Baixo **E** Compra MP STD = Baixo E Contratação STD = Baixo E Preço venda LUXO = Baixo **ENTÃO** Nota = **Baixa**.

As 37 regras que descrevem a árvore de decisão seguem esta mesma estrutura condicional, sempre associando a condição a um resultado final representado pelo atributo NOTA_ALUNO. A figura 15 mostra parte das regras configuradas no modelo.

Figura 15. Regras de inferência *Fuzzy*.

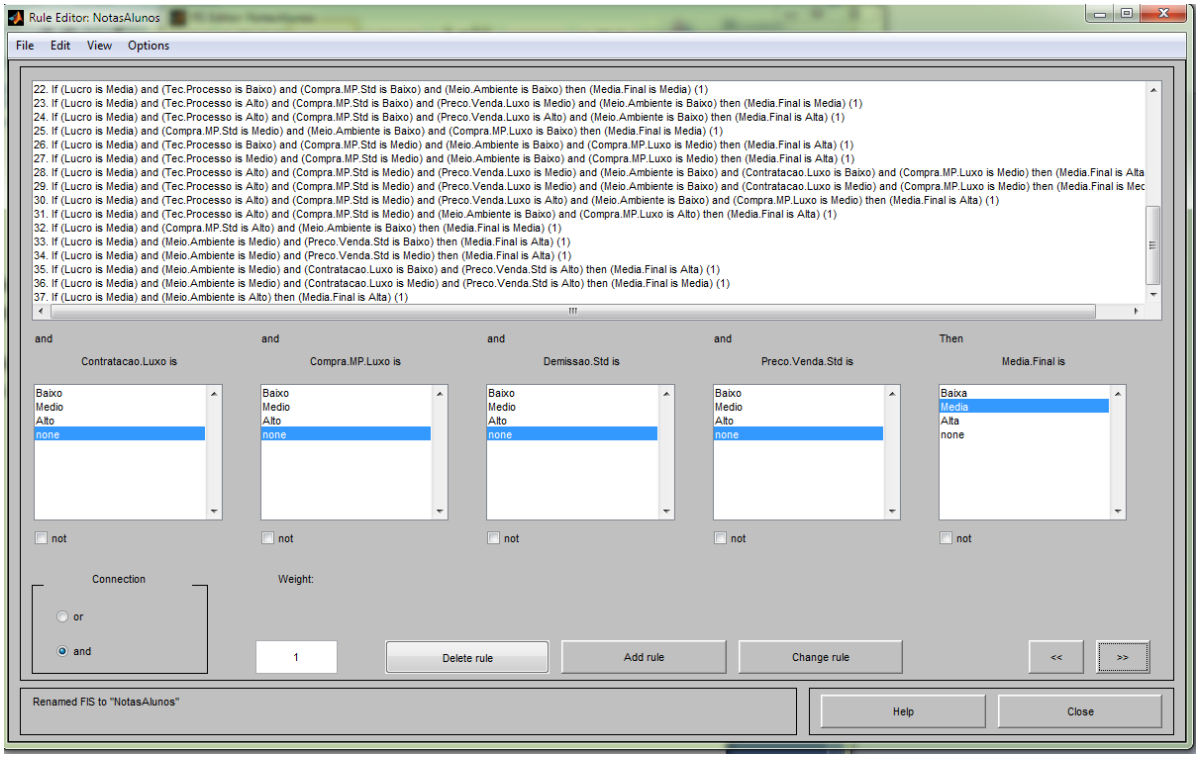

Após a configuração de todas as 37 regras, associadas ao resultado da nota final do aluno, o modelo *fuzzy* está preparado para realizar as inferências sobre novos valores. A interface para inserir novos dados permite a visualização gráfica dos resultados das diversas inferências obtidas.

A figura 16 demonstra a visualização gráfica das regras *fuzzy* já configuradas. Os novos valores a serem testados são inseridos no campo input, no canto inferior esquerdo, ou por meio de codificação em linguagem própria do *MatLab*.

Figura 16. Regras do modelo *fuzzy*.

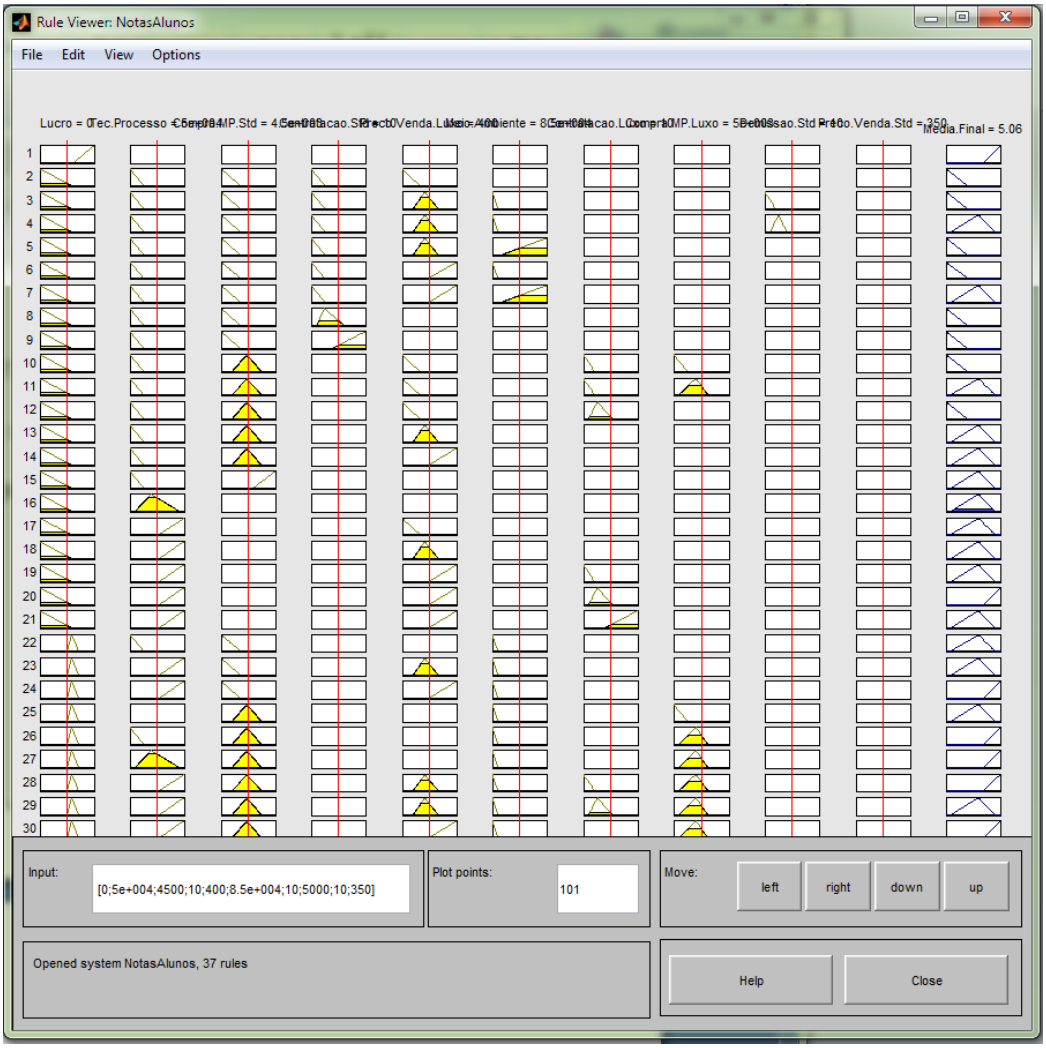

Como mostrado na figura 16, o conjunto de valores inserido no campo input resultou na inferência de um valor de média final condizente com os dados históricos e as regras do modelo *fuzzy*.

A avaliação do modelo se deu com o seu uso para inferir as notas dos 129 grupos de alunos, que compõem a totalidade dos dados válidos coletados. A figura 17 ilustra as notas inferidas pelo modelo *fuzzy* em comparação com as notas reais obtidas pelos grupos de jogadores.

Figura 17. Notas Real VS Nota Estimada pelo modelo *Fuzzy*.

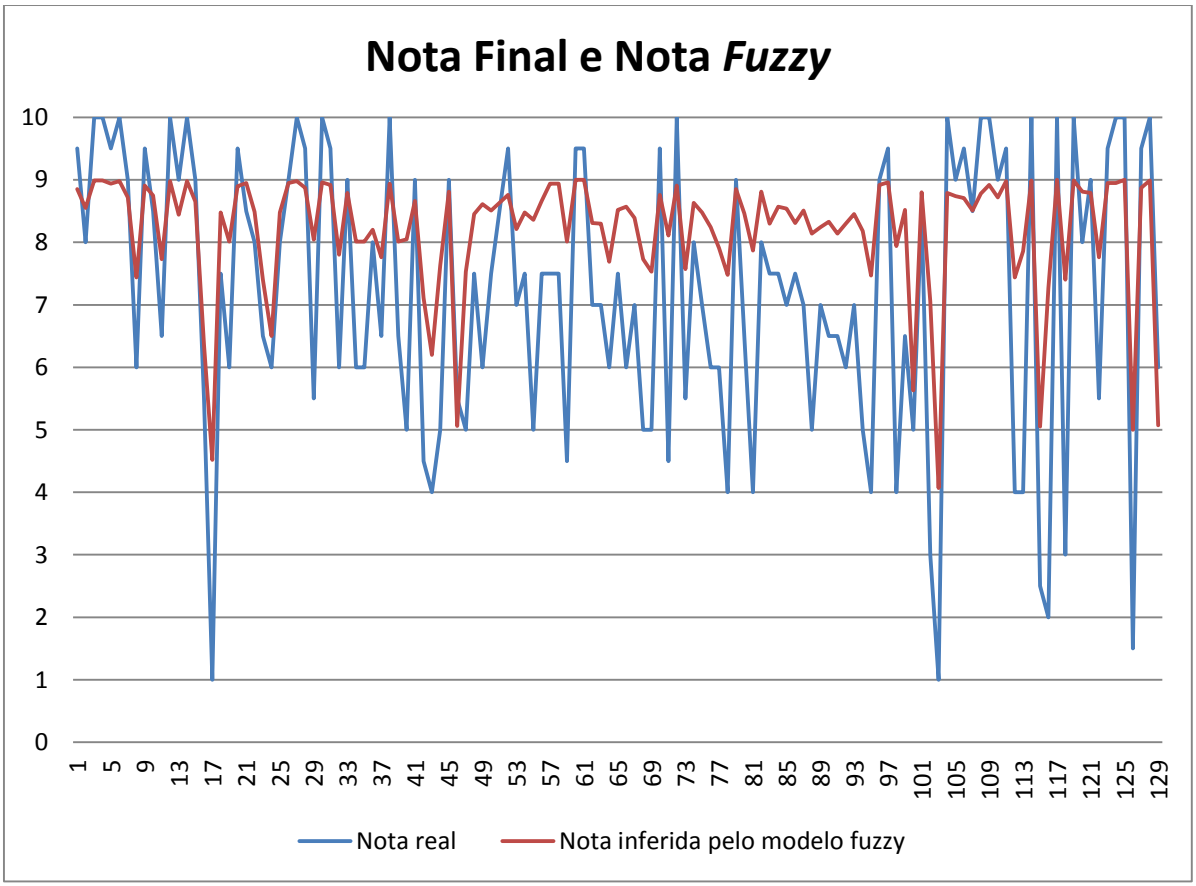

Como se pode observar, as notas acima de 7 obtiveram melhores indicadores, ou seja, a nota inferida pelo modelo se aproxima da nota real. Já para as notas baixas o modelo apresentou desempenho inferior. Observa-se ainda que do total das 129 inferências, nenhuma resultou em nota 10, o valor máximo sugerido pelo modelo foi nota 9.

Estas observações sugerem a necessidade de ajustes nos conjuntos *fuzzy* associados às variáveis linguísticas.

4.3 EXPERIMENTO 3 - APLICAÇÃO DE SISTEMAS MULTIAGENTES PARA SIMULAÇÃO DO MERCADO CONSUMIDOR

Para condução do experimento 3 foi definido um modelo de consumidor final simplificado, empregando Sistemas Multiagentes, que é baseado em regras simples e direcionados pelas inter-relações e preferências dos agentes virtuais. A ideia principal deste experimento foi possibilitar a criação de mercados virtuais para tornar o jogo mais rico em informações, servindo como auxilio ao facilitador, tendo em vista que ele é o responsável por esta tarefa.

Para o desenvolvimento deste experimento o software *NetLOGO* foi utilizado como ferramenta de apoio, construção e modelagem.

O desafio inicial para a elaboração da simulação de um mercado consumidor virtual se deu com a descrição de suas características empregadas na dinâmica particular do simulador SAE. Atualmente este não dispõe de procedimentos ou sistemas para geração, controle e operação dos mercados consumidores. A dinâmica ocorre de maneira individualizada e exclusiva a cada turma de alunos, norteada por manuais de instruções.

Em um primeiro momento, a condução deste experimento se deu com a observação da dinâmica, informações e operação de dados quanto ao mercado consumidor.

A segunda etapa deu-se na busca de referencial teórico em torno da caracterização das motivações e preferências de um mercado consumidor, com finalidade de elaborar uma breve modelagem acerca de suas características.

De acordo com referencial teórico e as observações na dinâmica do SAE, os aspectos culturais são relevantes para delimitação das variáveis do modelo.

A tabela 8 a seguir exemplifica algumas características pertinentes a um mercado consumidor simplificado (ALFINITO; TORRES, 2012; LUPPE; ANGELO, 2010; HONAISER; SAUAIA, 2008).

Tabela 8. Característica de influência do consumo.

Variável	Intervalo	Natureza	Descrição
Influência amigos	0-10	*input*	Valor indicativo do nível de influência exercida por seus amigos
Influência familiar	0-10	*input*	Valor indicativo do nível de influência exercida por seus familiares
Necessidade de Compra	0-10	*output*	Valor descritivo do quanto o agente necessita comprar (calculado pelas variáveis)
Influência (Experiência)	0-10	*output*	Valor de influência sobre consumo (pós-venda e satisfação do consumidor) (influência amigos e familiares)
Sugestão (Influenciável)	0-10	*input*	Valor de aceitação de influência externa (influência amigos e familiares)

A demanda prevista é delimitada por uma variação mensal sazonal, de acordo com cada mês simulado, formando uma curva de consumo anual. Algumas variáveis externas são informadas ainda como entrada de dados, influenciando as decisões de compra dos agentes. Este período sazonal pode ser aferido pelos alunos no mínimo em dois momentos, na fase de

treinamento do SAE e na simulação propriamente dita. Caso a simulação permaneça por mais 12 rodadas, em um novo ano simulado, esta mesma sazonalidade é informada.

A demanda acompanha valores de consumo médio, máximo e mínimo, a representar a sazonalidade, conforme os meses do ano. A figura 18 ilustra um exemplo de intervalos de consumo.

Figura 18. Demanda sazonal estimada por intervalo mensal.

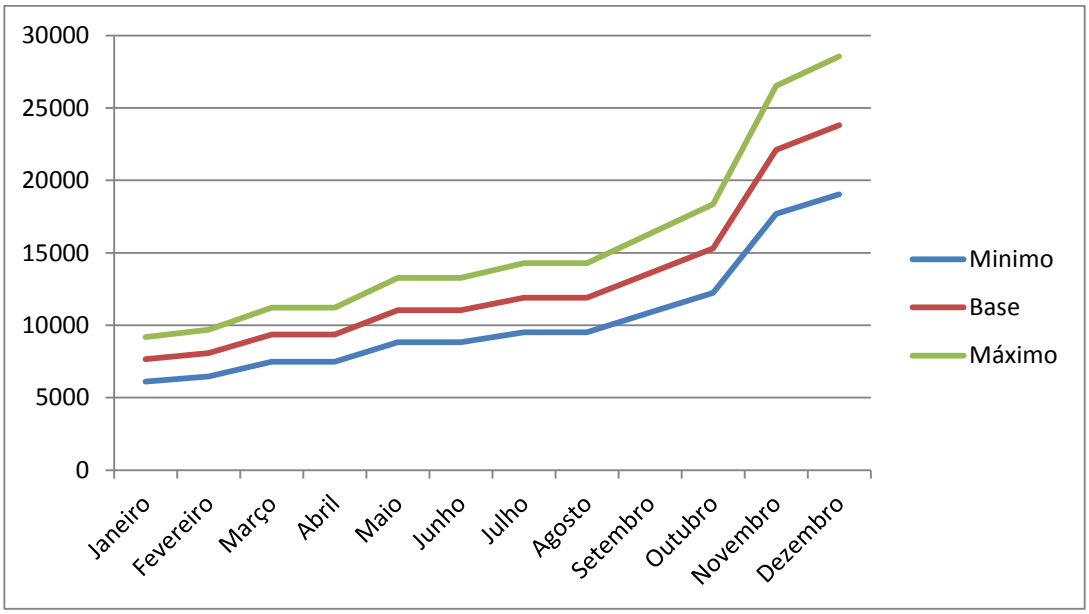

A cada ciclo de iterações os agentes, ou consumidores virtuais, tomam a decisão de consumir ou não em virtude das características do cenário externo, tendências, ações diretas das empresas participantes e a interferência direta das opiniões de outros agentes, ou seja, seu poder de influência sobre outros agentes, de forma a simular o mês vigente. O modelo, ao fim do ciclo de interações, é capaz de estimar o valor da demanda atual do mercado consumidor.

A figura 19 ilustra o ciclo do modelo do mercado consumidor proposto.

Figura 19. Modelo de interação de um agente.

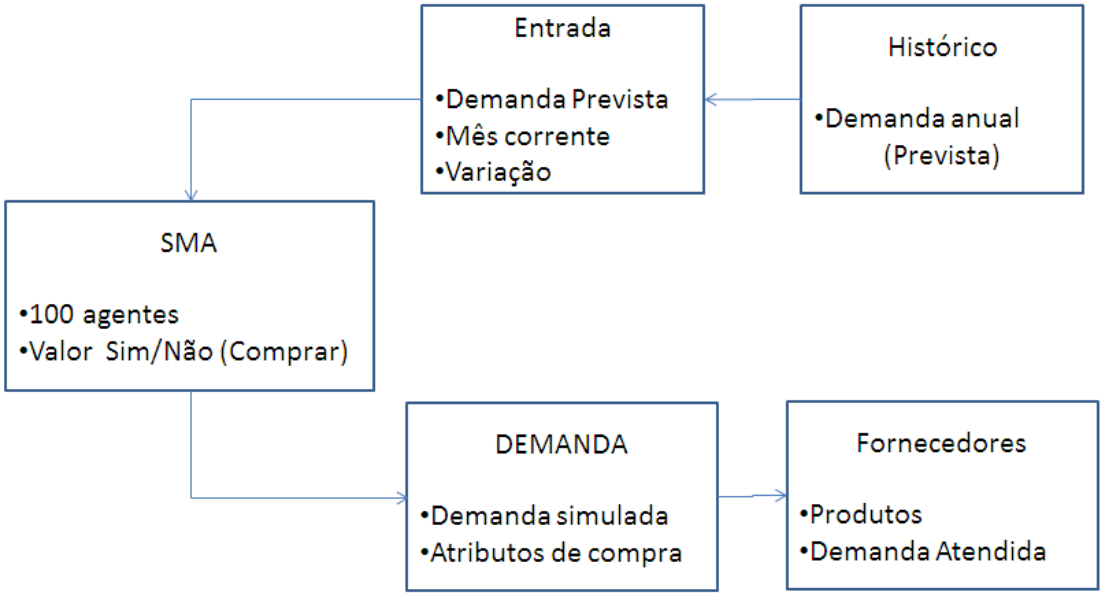

O modelo foi construído no software *NetLOGO* e possui as seguintes variáveis de configuração:

- Mês (janeiro a dezembro).
- Tendência de consumo (Ruim, Normalizado e Positivo).
- Influência-Propaganda (0 a 10).
- Cenário Externo (Ruim, Normal e Otimista).
- Escala do Universo (100 a 150 agentes).
- Chaves de novas rotas e direcionamento (*on* e *off*).

No início da simulação, as coordenadas dos agentes são geradas aleatoriamente no espaço da simulação. Cada agente possui quatro características básicas.

- Influência: é um valor para mensurar o quanto o agente pode influenciar outros agentes a mudarem de opinião.
- Sugestão: define o quanto o agente é sujeito a aceitar a opinião de outro agente.
- Desejo de compra: quantifica o desejo de compra do agente. Este valor pode ser alterado conforme a interação com outros agentes.
- Grupo Familiar: corresponde ao grupo familiar ao qual pertence o agente, podendo ser família, amigo ou desconhecido. Valores maiores para esta variável expressam proximidade social (família) e intensificam os valores da variável de influência.

Os ciclos mensais foram dimensionados em 300 interações cada. Por se movimentarem nos eixos X e Y, os agentes trocam informações e realizam as inferências apenas quando estão nas mesmas coordenadas cartesianas.

Distribuídos em um espaço de 30 por 30, os agentes se movimentam em direções aleatórias. A figura 20 a seguir exibe o modelo desenvolvido no *NetLOGO* para simulação do mercado virtual.

Figura 20. Modelagem de mercado consumidor em *NetLOGO*.

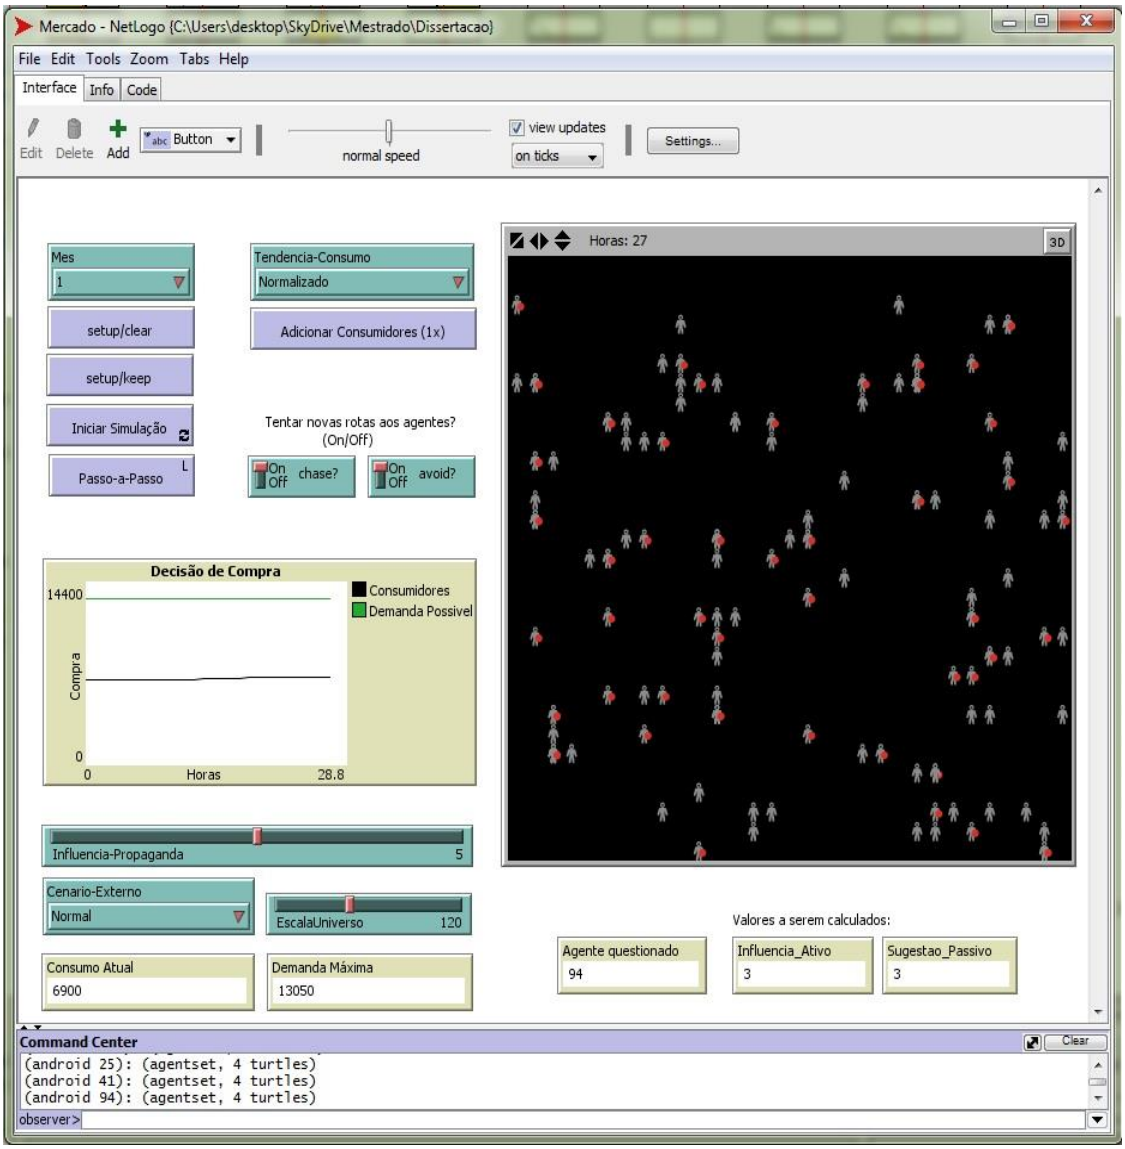

Foram realizadas simulações correspondentes ao período de 12 meses, sendo cada ano com um cenário diferente. Os valores testados correspondem a cenários variáveis ao consumo dos agentes (decisão de compra).

Os parâmetros utilizados nas interações anuais estão descritos na tabela 9.

Tabela 9. Parâmetros empregados nos cenários simulados.

Cenários	Tendência de consumo	Cenário
cenário 1	normalizado	normal
cenário 2	negativa	normal
cenário 3	negativa	ruim
cenário 4	normalizado	ruim
cenário 5	normalizado	otimista
cenário 6	negativa	otimista
cenário 7	otimista	ruim
cenário 8	otimista	normal
cenário 9	otimista	otimista

Testes considerando cenários diferentes foram realizados visando observar a variabilidade da demanda gerada pelo modelo, de acordo com os parâmetros externos aos agentes, ou seja, alterando apenas os parâmetros descritos na tabela 9. Adotou-se o valor 5 para a variável propaganda, escala da simulação com 120 agentes e 300 interações em todos os experimentos. Os grupos familiares foram gerados aleatoriamente, entre 30 grupos familiares diferentes.

Pode-se observar, com base nos testes realizados, que os valores de demanda obedeceram os limites mínimos e máximos estabelecidos para cada mês simulado.

A figura 21 apresenta os valores correspondentes à demanda registrada a cada mês na simulação, de acordo com os cenários configurados.

Figura 21. Simulação de demanda e cenários.

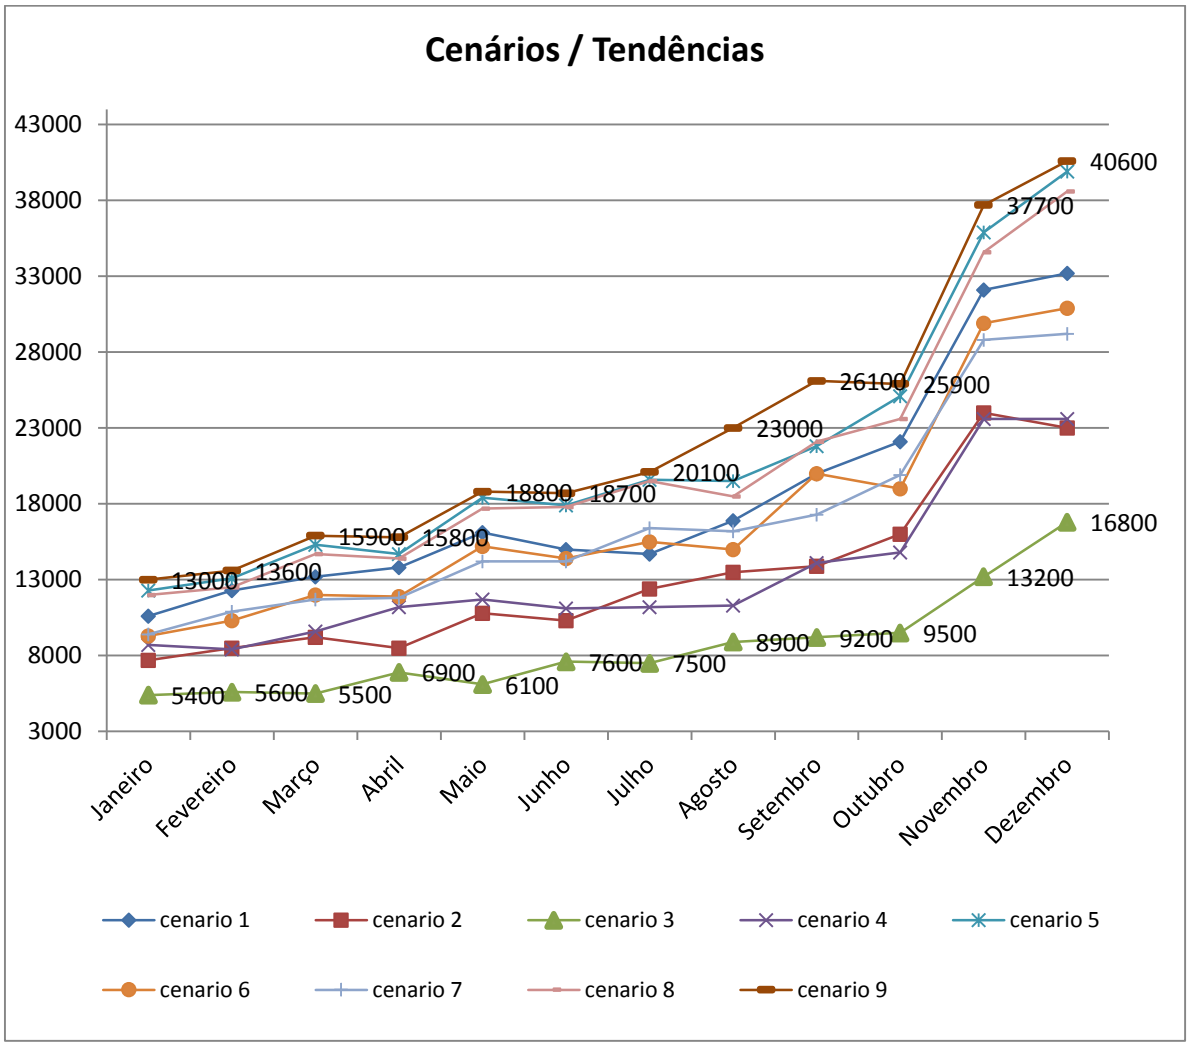

A figura 21 ilustra ainda que os cenários mais positivos apresentam maiores demandas de consumo, e não apenas em épocas sazonais, como no fim de ano (cenário 9). A perspectiva negativa também apresenta influência nas decisões de compra dos agentes (cenário 3). Os valores utilizados de propaganda foram fixados em cinco, para todos os experimentos. A escala da simulação se deu com 120 agentes, para todos os experimentos de 300 interações cada.

Quando há interação entre os agentes, seus relacionamentos são cruzados, e diante da opinião de ambos agentes, será tomada a decisão da relação de consumo (de compra ou não do produto). Parte desta decisão sofre influência de agentes externos, relacionados com a tendência de consumo, o cenário externo e a influência da propaganda. A movimentação do agente no

espaço da simulação pode resultar ou não em interações, ou seja, um agente pode se movimentar para onde não há outro agente, não gerando interação e permanecendo seu desejo de compra.

O agente estimado neste modelo simplificado de decisão de consumo apresentou sensível variabilidade e resposta aos estímulos externos, delimitados por parâmetros da simulação. A sazonalidade natural decorrente dos meses de maior procura, no caso de consumo de eletrodomésticos, é parametrizável no modelo diretamente no código fonte da modelagem. No entanto, caso necessário tais variáveis podem ser manipuladas pelo condutor da simulação por meio de uma nova interface de usuário.

Outra preocupação quanto ao modelo se deu quanto a manter certa imprevisibilidade da demanda simulada.

Neste experimento verificou-se ainda a variabilidade do comportamento dos agentes, quanto à decisão de compra, em um mesmo período simulado, a fim de se evitar um comportamento viciado, ou melhor, padronizado em todas as simulações configuradas com os mesmos parâmetros.

Para analisar esta característica de variabilidade do comportamento de compra do agente, um total de 10 simulações foram conduzidas possuindo os mesmos parâmetros, neste caso com os seguintes valores: Mês: Janeiro, 300 interações para cada mês gerado, delimitado em agentes 120, valor de Influência de Propaganda: 5, Tendência de Consumo: “Normalizado”, Cenário externo: “Normal”.

A figura 22 ilustra os valores obtidos nas simulações de um mesmo mês (janeiro), representados por 10 séries aleatórias.

Figura 22. Tendência de demanda em um único período.

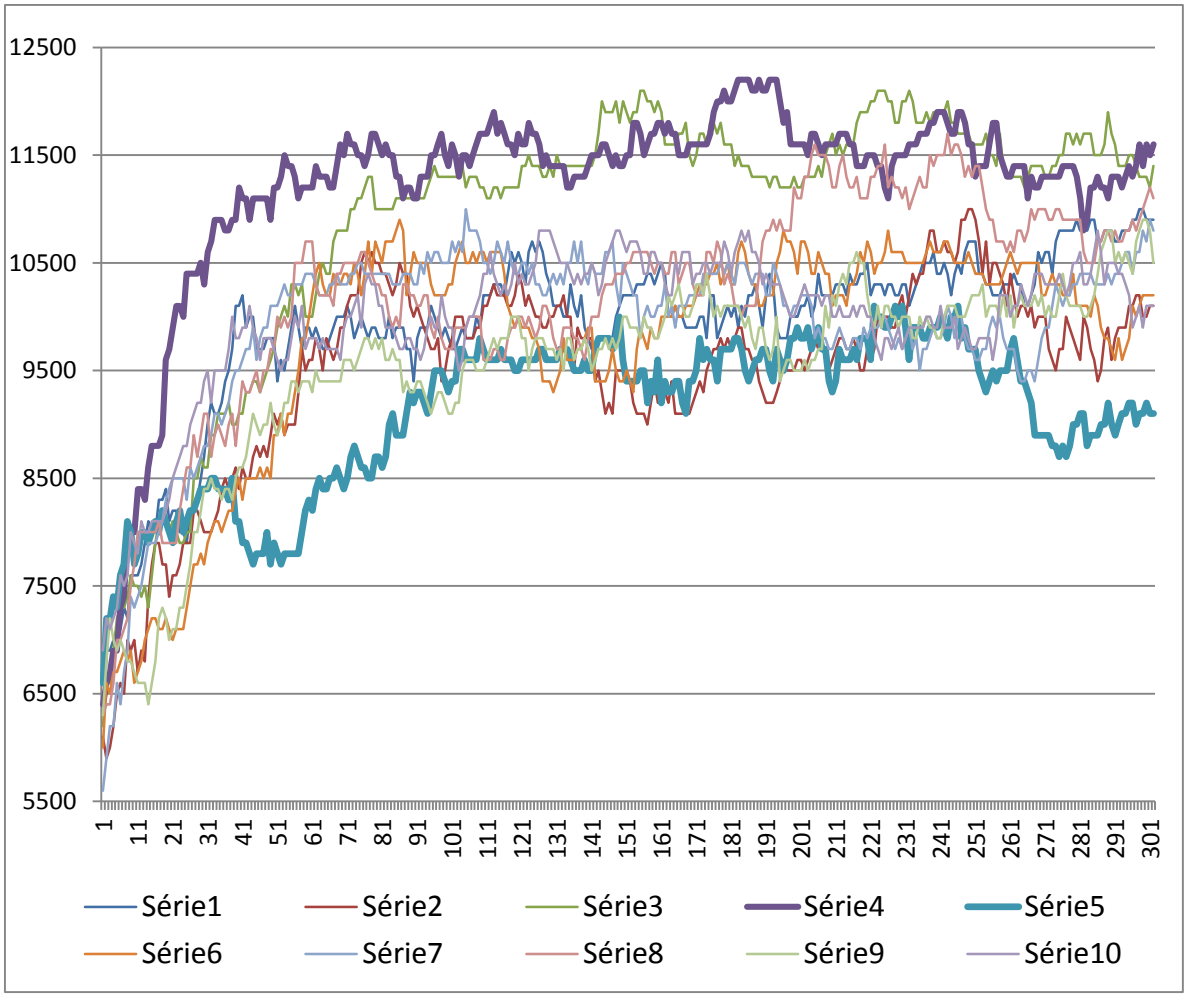

A figura 22 apresenta resultados com certo nível de variabilidade do comportamento da demanda, mesmo sob os mesmos parâmetros inicias. Em determinado ponto da simulação (iteração 54), a demanda da série5 gerou valores 67% menores do que os gerados na série4 e, ao final da simulação (interação 300), esta diferença foi de 78,4%.

4.4 DISCUSSÃO DOS RESULTADOS

O Experimento 1 gerou bons resultados, considerando os percentuais de acertos na tarefa de classificação, principalmente com o conjunto de dados “Conjunto_MD2”, a partir da qual pode-se inferir que existem padrões nas tomadas de decisões dos jogadores. Além disso, as regras de associação geradas podem ser úteis para a construção de outros mecanismos que permitam maior dinamismo ao jogo. Vale ressaltar que a tarefa de classificação resultou em uma árvore de decisão que descreve as regras usadas no Experimento 2.

No experimento 2 foi proposto um mecanismo de inferência *fuzzy* para auxílio à tomada de decisão dos jogadores. Este mecanismo é capaz de fornecer uma ajuda para o jogador balizar suas decisões antes de efetivá-las no jogo. Em outras palavras, com base nos valores definidos para as de variáveis de decisão, o jogador pode fazer uma consulta ao jogo e receber como *feedback* uma “dica” sobre o seu desempenho caso decida adotar tais valores.

Observa-se que os melhores resultados do mecanismo de inferência foram com relação às notas entre 7 e 9 e que modelo *fuzzy* não conseguiu inferir notas elevadas (maiores que 9) com precisão. É importante esclarecer que tal mecanismo de inferência serve apenas para indicar se o caminho das decisões tomadas pelo jogador leva a bons resultados, ou seja, a bons resultados representados nos indicadores de desempenho, mais não sugere qual rumo ou ação deve ser tomada. Ainda assim, esta inferência pode ser considerada relevante, uma vez que tal informação é de responsabilidade do professor e não está disponível aos jogadores em tempo de execução do jogo, contribuindo para minimizar o problema de *feedback* ao aluno.

Finalmente, o experimento 3 apresentou bons resultados iniciais quanto à geração de demanda pelos agentes virtuais, representando um mercado consumidor final. Entende-se por bons resultados a indicação da demanda, representada pelo “desejo de compra” dos consumidores virtuais, respeitando os intervalos sazonais pré-estabelecidos. Assim, este

mecanismo pode ser uma boa alternativa para a geração de demandas no SAE, que atualmente é de responsabilidade do professor. No entanto, os parâmetros envolvidos nesta geração de demanda devem ser melhor explorados visando produzir um resultado mais robusto e amplo.

A partir dos três experimentos realizados, sugere-se uma nova arquitetura para o SAE, ilustrada na figura 23, a qual contempla os módulos de apoio propostos.

Figura 23. Nova arquitetura proposta para o SAE.

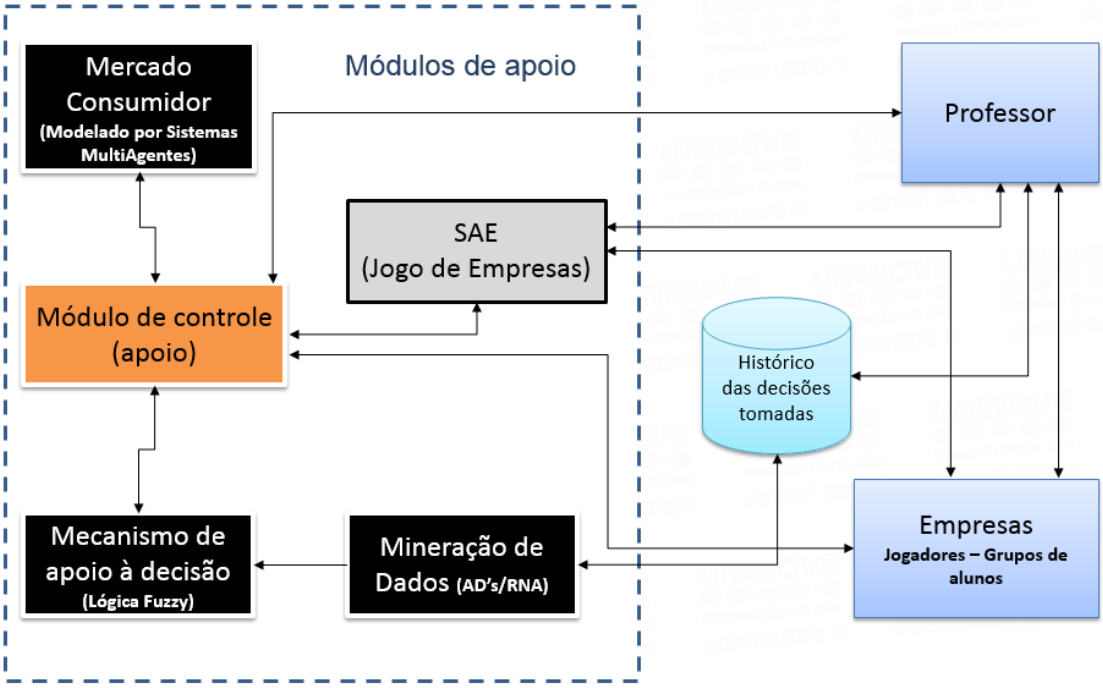

A figura 23 apresenta, nas caixas pretas com letras brancas, os módulos de apoio propostos. O fluxo de dados se dá de forma a permitir uma interação e aproveitamento das informações entre os diversos módulos que compõem o jogo. Um exemplo é o módulo de Mineração de Dados que resulta em descobertas reaproveitadas no módulo *fuzzy* de apoio à decisão dos jogadores. O módulo de controle é responsável por concentrar o fluxo de informações entre os módulos de apoio aos jogadores e facilitadores, e o simulador.

5 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho investigou-se o emprego de técnicas de inteligência computacional na construção de módulos de apoio à decisão dos jogadores e do professor em um jogo de empresas denominado SAE, visando, principalmente, a redução dos problemas de *feedback* aos jogadores e apoio ao professor/facilitador na geração de mercados consumidores virtuais, enriquecendo a dinâmica do jogo. Os resultados obtidos mostram que o conjunto de técnicas empregadas foi adequado para atingir os objetivos.

Os experimentos apresentados nesta pesquisa se deram inicialmente com uma coleta de dados realizada no decorrer de um semestre letivo, representando uma fração significativa do universo de simulações realizadas no jogo. A partir destes experimentos, foi possível propor uma nova arquitetura para o SAE contemplando módulos de apoios aos jogadores e facilitadores.

O mecanismo de inferência *fuzzy*, concebido a partir das regras que descrevem padrões de tomada de decisões dos jogadores, permite apresentar informações a respeito do desempenho de um jogador durante a simulação, reduzindo o problema de *feedback*, que atualmente é um dos pontos fracos do jogo.

O módulo de apoio ao professor, baseado em SMA, propicia a geração de um mercado consumidor virtual que, por sua vez, determina as demandas nas simulações. Sua parametrização permite delimitar cenários diversos e adaptáveis às circunstâncias de cada simulação, enriquecendo a dinâmica do jogo.

Com os resultados obtidos nos experimentos realizados, pode-se concluir que a hipótese formulada neste trabalho é verdadeira, uma vez que o uso de técnicas de inteligência computacional no jogo apresentou-se como uma alternativa para a redução do problema de *feedback* ao jogador durante a simulação e a disponibilização de outros módulos de apoio,

tornando o ambiente de simulação mais rico. Não obstante, uma importante contribuição deste trabalho é a proposição de uma metodologia para o emprego de técnicas de inteligência computacional visando desenvolvimento de módulos de apoio à tomada de decisão, a qual pode ser aplicada em jogos de empresas com características semelhantes ao SAE.

A principal limitação deste trabalho está relacionada ao fato dos módulos propostos não terem sido implantados no jogo. Assim, não foi possível testá-los com outros dados além daqueles extraídos inicialmente para os experimentos. Outra limitação se dá ao fato de o conjunto de dados primários compreenderem apenas um semestre.

Para trabalhos futuros pretende-se implantar os módulos no SAE e realizar novos testes, com novos conjuntos de dados, com intuito de refinar os modelos propostos. Pretende-se também investigar outras técnicas de inteligência computacional que possam ser utilizadas neste mesmo simulador, bem como uma maneira de empregar os módulos de apoio desenvolvidos neste trabalho em outros jogos de empresas com características similares ao SAE.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ALFINITO, S.; TORRES, C. V. Modelo de influência cultural no consumo: uma proposta baseada em axiomas sociais. **Revista de Administração Mackenzie**, v. 13, n. 5, p. 15–38, 2012.

BAIG, Z. A. Multi-agent systems for protecting critical infrastructures: A survey. **Journal of Network and Computer Applications**, v. 35, n. 3, p. 1151–1161, maio 2012.

BARROS JR, D. F.; ESTIVALLI, J. D; AMENDOLA, F.; ARAUJO, S. A.; Análise e mineração de dados apoio ao ensino de conceitos de gestão da produção, vendas e estratégias de negócio. In: **XXXIII ENEGEP - Encontro Nacional de Engenharia de Produção**, 2013, Salvador, BA. XXXIII ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, 2013.

BATISTA, C. S.; OLIVEIRA, F. L.; NASCIMENTO, E. V. Proposta de um jogo didático de gestão da produção. In: **XXXI ENEGEP - Encontro Nacional de Engenharia de Produção**, 2011, Belo Horizonte, MG. Anais do XXXI ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, 2011.

BERTRAND, J. W. M.; FRANSOO, J. C. Modelling and Simulation: operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v. 22, n. 2, p. 241–264, 2002.

BORRAJO, F.; BUENO, Y.; PABLO, I.; SANTOS, B. FERNÁNDEZ. F.; GARCÍA, J.; SAGREDO, I. SIMBA: A simulator for business education and research. **Decision Support Systems**, v. 48, n. 3, p. 498–506, 2010.

CARVALHO, L. A. V. **Datamining: a mineração de dados no marketing, medicina, economia, engenharia e administração**. São Paulo: Érica, 2001. 234 p.

CHANG, T. S. A comparative study of artificial neural networks, and decision trees for digital game content stocks price prediction. **Expert Systems with Applications**, v. 38, n. 12, p. 14846–14851, nov. 2011.

COSTA, R. N. DA. **Balanced scorecard : um aplicativo para ser usado em sala de aula**. 2006. 129 f. Dissertação (Mestrado em Contabilidade), Universidade Regional de Blumenal, Blumenal, 2006.

D´IPOLITTO, C. Jogos de Negócio e Educação Empreendedora. **Sistemas & Gestão**, v. 7, n. 2, p. 192–204, 2012.

DUGAICH, R. L. C. **Jogos de Empresa e Ensino de Estratégia Empresarial: Resultados de Pesquisa Empírica no Brasil**. 2004. 240 f. Dissertação (Mestrado em Administração). PUC-Rio, Rio de Janeiro, 2005.

FAWCETT, T. An introduction to ROC analysis. **Pattern Recognition Letters**, v. 27, n. 8, p. 861–874, 2006.

FAYYAD, U. M.; PIATETSKY-SHAPIRO, G.; SMITH, P. UTHURUSAMY R. **Advances in Knowledge Discovery and Data Mining**. Michigan: MIT Press, 1996, 625 p.

GAVIÃO, L. O.; LIMA, G. B. A. Educação da sustentabilidade: uma proposta de indicadores de sustentabilidade escolar por lógica *fuzzy*. In: **XXXIII ENEGEP - Encontro Nacional de Engenharia de Produção**, 2013, Salvador, BA. XXXIII ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, 2013.

GERBER, J. Z. **Proposta de metodologia para o desenvolvimento de recursos à aplicação de jogos de empresas via internet – o modelo para o jogo de empresas gi-eps**. 2000. 105 f. Dissertação (Mestrado em Engenharia de Produção), Universidade Federal de Santa Catarina, Florianópolis, 2000.

GIL, A. C. **Como elaborar projetos de pesquisa.** 4. ed. São Paulo: Atlas, 2008.

GRAMIGNA, M. R. M. **Jogos de empresa e técnicas vivenciais**. 2. ed. São Paulo: Pearson Prentice Hall, 2007.

HALL, M.; FRANK, E.; HOLMES, G. The WEKA data mining software: an update. **ACM SIGKDD**, v. 11, n. 1, p. 10–18, 2009.

HAN, J.; KAMBER, M. **Data Mining: Concepts and Techniques: Concepts and Techniques**. 3. ed. Waltham, USA: Elsevier Science, 2011. 744 p.

HONAISER, E. H. R.; SAUAIA, A. C. A. Desenvolvimento e Aplicação de um Modelo para Previsão de Demanda em Jogos de Empresas. **RAC-Eletrônica**, v. 2, n. 3, p. 470–485, 2008.

KALLÁS, D.; SAUAIA, A. C. A. Balanced scorecard implemention for strategy management: variation of manager opinion in real and simulated companies. In: **33rd Annual ABSEL - Association for Business Simulation and Experiential Learning Conference**, 2006, San Francisco, USA. Developments in Business Simulation and Experiential Learning, 2006. v. 33. p. 1-8.

KASABOV, N. K. **Foundations of Neural Networks, *Fuzzy* Systems, and Knowledge Engineering**. Cambridge, USA: MIT Press, 1996.

KAUPA, P. H.; SASSI, R. J. Redes neurais artificiais e modelo de markowitz: comparando técnicas que apóiam a tomada de decisão nos investimentos. In: **XXXI ENEGEP - Encontro Nacional de Engenharia de Produção**, 2011, Belo Horizonte, MG. Anais do XXXI ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, 2011.

KOHONEN, T. **Self-Organizing Maps**. 3. ed. Lancashire: Springer, 2000.

LIN, C. F. et al. Data mining for providing a personalized learning path in creativity: An application of decision trees. **Computers & Education**, v. 68, p. 199–210, out. 2013.

LOESCH, C.; SARI, S. T. **Redes neurais artificiais : fundamentos e modelos**. Blumenau: LOPES, 1996.

LOPES, P. C.; Mrtvi, V. O.; Sitnik, D. C.; Westphal, F. K. Função de Demanda Mercado: Uma proposta para utilização em jogos de empresas. In: **XXV ENEGEP - Encontro Nacional de Engenharia de Produção**, 2005, Porto Alegre, RS. XXV ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, 2005.

LUPPE, M. R.; ANGELO, C. F. DE. As decisões de consumo e a heurística da ancoragem: uma análise da racionalidade do processo de escolha. **RAM. Revista de Administraçao Mackenzie**, v. 11, n. 6, p. 81–106, 2010.

MADKUR, F. N.; LOPES, P. D. C. Análise do processo de gestão estratégica de custos e formação de preços, no âmbito dos jogos de empresas, com apoio do treinamento baseado no computador (CBT). **Revista de Gestão**, v. 17, n. 3, p. 265–283, 2010.

MAGLIOCCA, N. R.; BROWN, D. G.; ELLIS, E. C. Exploring agricultural livelihood transitions with an agent-based virtual laboratory: global forces to local decision-making. **PloS one**, v. 8, n. 9, p. 11, jan. 2013.

MARTINEZ-GIL, F.; LOZANO, M.; FERNÁNDEZ, F. Strategies for simulating pedestrian navigation with multiple reinforcement learning agents. **Autonomous Agents and Multi-Agent Systems**, p. 33, fev. 2014.

MARTÍNEZ-LÓPEZ, F. J.; CASILLAS, J. Artificial intelligence-based systems applied in industrial marketing: An historical overview, current and future insights. **Industrial Marketing Management**, v. 42, n. 4, p. 489–495, maio 2013.

MEDEIROS, S. M.; ORNELLAS, A.; RODRIGO RESENDE RAMOS. Jogos de empresas aplicados à logística empresarial: um panorama dos modelos disponíveis no país. In: **XXVI ENEGEP - Encontro Nacional de Engenharia de Produção**, 2006, Fortaleza, CE. XXVI ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, 2006.

MITCHELL, T. M. **Machine Learning**. New York: McGraw-Hill, 1997.

MORABITO, R.; PUREZA, V. Modelagem e simulação. In. MIGUEL, P. A. C. **Metodologia de pesquisa em engenharia de produção e gestão de operações.** Rio de Janeiro: Elsevier, 2010. P. 165-194.

MORIM, A.; FORTES, E. S,; REIS, P.; COSENZA, C.; DORIA, F.; GONÇALVES, A. Think *Fuzzy* System : Developing new pricing strategy methods for consumer goods using *fuzzy* logic. **XVIII ICIEOM**, p. 1–11, 2012.

NASCIMENTO, A. S. **Uma proposta de metamodelo de jogos de empresas**. 2011, 164 f. Dissertação (Mestrado em Engenharia de Produção), Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

NAYLOR, T. H.; BALlNTFY, J. L.; BURDlCK, D. S.; CHU, K. **Técnicas de simulação em computadores**. Petrópolis: Vozes, 1971.

NESPOLI, Z. B. Ciência, inteligência artificial e pós-modernidade. **Revista Diálogo Educacional**, v. 4, n. 13, p. 31–42, 2004.

ODERANTI, F. O. Fuzzy inference game approach to uncertainty in business decisions and market competitions. **SpringerPlus**, v. 2, n. 1, p. 16, jan. 2013.

ODERANTI, F. O.; DE WILDE, P. Dynamics of business games with management of *fuzzy* rules for decision making. **International Journal of Production Economics**, v. 128, n. 1, p. 96–109, nov. 2010.

ODERANTI, F. O.; DE WILDE. P.; LI, F. Uncertainty in business decisions and *fuzzy* games approach. 2012. In: **12th UK Workshop on Computational Intelligence (UKCI)**, 2012, Plymouth, Reino Unido. 12th UK Workshop on Computational Intelligence (UKCI), IEEE, 2012.

ODERANTI, F. O.; DE WILDE. P.; LI, F. Application of strategic *fuzzy* games to wage increase negotiation and decision problems. **Expert Systems with Applications**, v. 39, n. 12, p. 11103–11114, set. 2012.

OLIVARES, G.; CAMPOS, R. Protótipo de um jogo de empresas para auxílio ao ensino de gestão da produção e operações. In: **XXIV ENEGEP - Encontro Nacional de Engenharia de**

Produção, 2004, Florianópolis, SC. XXIV ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, 2004.

OLIVEIRA, M. A.; SAUAIA, A. C. A. Percepção Docente para Aprendizagem Vivencial: um Estudo dos Benefícios dos Jogos de Empresas no Desenvolvimento de Competências Gerenciais. In: **II Encontro de Ensino e Pesquisa em Administração e Contabilidade**, 2009, Curitiba, PR. II Encontro de Ensino e Pesquisa em Administração e Contabilidade, Curitiba: EnEPQ, 2009.

OLIVEIRA, M.; SAUAIA, A. Impressão docente para aprendizagem vivencial: Um estudo dos benefícios dos jogos de empresas. **Administração: Ensino e Pesquisa**, v. 12, n. 3, p. 355–391, 2011.

OSIRO, L.; LIMA, R. H. P.; LIMA JUNIOR, F. R.; CARPINETTI, L. C. R. Proposta de uso de redes neurais artificiais em uma matriz de portfólio de compras. In: **XXXIII ENEGEP - Encontro Nacional de Engenharia de Produção**, 2013, Salvador, BA. XXXIII ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, 2013.

QUINLAN, J. Induction of decision trees. **Machine learning**, v. 1, n. 1, p. 81–106, 1986.

RENNA, P.; ARGONETO, P. Production planning and automated negotiation for SMEs: An agent based e-procurement application. **International Journal of Production Economics**, v. 127, n. 1, p. 73–84, set. 2010.

RIBEIRO, R. P.; FOUTO, N. M. M. D. Custos e economia de escala em um jogo de empresas.In: **XVI Seminários de Administração FEA-USP – SemeAd**, 2013, São Paulo, SP. XVI Seminários de Administração FEA-USP – SemeAd, São Paulo: 2013.

RODRIGUES, F.; SANTOS, S. A lógica *fuzzy* na administração de empresas. **VII Seminários de Administração FEA-USP – SemeAd**, 2004, São Paulo, SP. VII SemeAd, São Paulo: 2004.

MEDEIROS, S.; ORNELAS, A.; RAMOS, R. R. Jogos de empresas aplicados à logística empresarial: um panorama dos modelos disponíveis no país. **XXVI ENEGEP - Encontro Nacional de Engenharia de Produção**, 2006, Fortaleza, CE. XXVI ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, 2006.

ROMÃO, L. DA S.; GONÇALVES, M. S.; ANDRADE, M. A. R. Jogos de Empresa como Estratégia de Ensino nas Instituições de Ensino Superior. In: **IX Simpósio de Excelência em Gestão e Tecnologia – SEGeT**, 2012, Rio de Janeiro, RJ. : IX Simpósio de Excelência em Gestão e Tecnologia – SEGeT, Rio de Janeiro: AEDB, 2012.

ROSAS, A. R.; SAUAIA, A. C. A. Jogos de empresas na educação superior no Brasil: perspectivas para 2010. **Enfoque Contábil**, v. 25, n. 2, p. 72–85, 2006a.

ROSAS, A.; SAUAIA, A. Variáveis microeconômicas em simuladores para jogos de empresas: um estudo comparativo. **REGE Revista de Gestão**, v. 13, n. 3, p. 23–39, 2006b.

Ruiz, N.; Giret, A.; Botti, V.; Feria, V. Agent-supported simulation environment for intelligent manufacturing and warehouse management systems. **International Journal of Production Research**, v. 49, n. 5, p. 1469–1482, mar. 2011.

RUSSEL, S.; NORVIG, P. **Artificial intelligence a modern approach**. New Jersey: Prentice Hall, 1995.

SASSI, R. J. **Uma arquitetura híbrida para descoberta de conhecimento em bases de dados: teoria dos rough sets e redes neurais artificiais mapas auto-organizáveis**. 2006, 169

f. Tese (Doutorado em Engenharia Elétrica), Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Sistemas Eletrônicos. São Paulo, 2006.

SAUAIA, A. Conhecimento versus desempenho das organizações: um estudo empírico com jogos de empresas. **Revista Eletrônica de Administração**, v. 12, n. 1, p. 17, jan 2006.

SAUAIA, A. C. A. **Satisfação e aprendizagem em jogos de empresas: contribuições para a Educação Gerencial**. 1995, 273 f. Tese (Doutorado em Administração). Curso de Pós-Graduação em Administração, Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo, 1995.

SAUAIA, A. C. A.; WADT, M. Variáveis macro e microeconômicas em simuladores organizacionais: um estudo comparativo. In: **XIII Seminários de Administração FEA-USP – SemeAd**, 2010, São Paulo, SP. XIII Seminários de Administração FEA-USP – SemeAd, São Paulo: 2010.

SCHUMAN, C. D.; BIRDWELL, J. D. Dynamic artificial neural networks with affective systems. **PloS one**, v. 8, n. 11, p. 16, nov. 2013.

SICHMAN, J. **Raciocínio social e organizacional em sistemas multiagentes: avanços e perspectivas.** 2003, 235 f. Tese (Livre Docência) Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Computação e Sistemas Digitais, São Paulo, 2003.

SILVA, M. A.; SAUAIA, A. C. A. Gestão mercadológica e lucratividade : um estudo com jogos de empresas. **Rev. Adm. UFSM**, v. 5, n. 1, p. 92–109, 2012.

SILVESTRE, D. A. **Proposta de um novo modelo de jogos de negócios**. 2004, 84 f. Dissertação (Mestrado em Sistemas de Gestão) Universidade Federal Fluminense, Niteroi, 2004.

SOUZA, A. V. DE; CHAGAS, F. A.; SILVA, C. E. Jogos de empresas como ferramenta de treinamento e desenvolvimento. **Revista Brasileira de Administração Científica**, v. 2, n. 2, p. 5–23, 19 nov. 2011.

THOMAS, P.; THOMAS, A. Multilayer perceptron for simulation models reduction: Application to a sawmill workshop. **Engineering Applications of Artificial Intelligence**, v. 24, n. 4, p. 646–657, jun. 2011.

VOICU, A. Large-Scale Agent-Based Models in Marketing Research: The Quest for the Mythical Free Lunch. **International Journal of Business and Economics Research**, v. 2, n. 3, p. 33-40, jun 2013.

ZADEH, L. A. **On *fuzzy* algorithms**. California: Electronics Research Laboratory, 1972.

ZAMBELO, E.; RODRIGUES, J. DE S. Demandas de conhecimentos necessários ao professor para uso de jogos de empresas. In: **XXX ENEGEP - Encontro Nacional de Engenharia de Produção**, 2010, São Carlos, SP. XXX ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, 2010.

ZIMMERMANN, H. G.; NEUNEIER, R.; GROTHMANN, R. Multi-agent modeling of multiple FX-markets by neural networks. **IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council**, v. 12, n. 4, p. 735–743, jan. 2001.

ANEXO A: TRABALHOS RESULTANTES DESTA DISSERTAÇÃO

BARROS JR, D. F.; ESTIVALLI, J. D; AMENDOLA, F.; ARAÚJO, S. A.; Análise e mineração de dados apoio ao ensino de conceitos de gestão da produção, vendas e estratégias de negócio. In: **XXXIII ENEGEP - Encontro Nacional de Engenharia de Produção**, 2013, Salvador, BA. XXXIII ENEGEP - Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, v. 1. p. 1-13, 2013.

OLIVEIRA, L. S. ; BARROS JUNIOR, D. F. ; ARAÚJO, S. A. . Análise e Mineração de Dados em Jogos de Empresas. In: **15º Simpósio de Iniciação Científica e Tecnológica** (SICT 2013), 2013, São Paulo. Boletim Técnico da Faculdade de Tecnologia de São Paulo. São Paulo: CEETEPS Centro Estadual de Educação Tecnológica Paula Souza, 2013.

BARROS JR, D. F. ; ARAÚJO, S. A.; A Fuzzy Inference System for Decision Making of Players of a Business Game for Teaching Concepts of Production Management, Sales and Business Strategies. In: **XX International Conference on Industrial Engineering and Operations Management** (CIO/ICIEOM 2014), 2014, Málaga. Proceedings of XX International Conference on Industrial Engineering and Operations Management. Málaga: ADINGOR, v. 1. p. 412-420, 2014.

BARROS JR, D. F. ; ARAÚJO, S. A. ; TRIGUIS, P. H. . Modelagem de um mercado consumidor virtual em um jogo de empresas usando sistemas multiagentes. In: **XXXIV Encontro Nacional de Engenharia de Produção**, 2014, Curitiba, PR. Anais do XXXIV Encontro Nacional de Engenharia de Produção. Rio de Janeiro: ABEPRO, v. 1. p. 1-15, 2014.

ANEXO B: MAPEAMENTO DAS AÇÕES NO SAE

A figura 24 exemplifica o mapeamento de ações do professor, na utilização do SAE.

Figura 24. Mapeamento de ações do Professor.

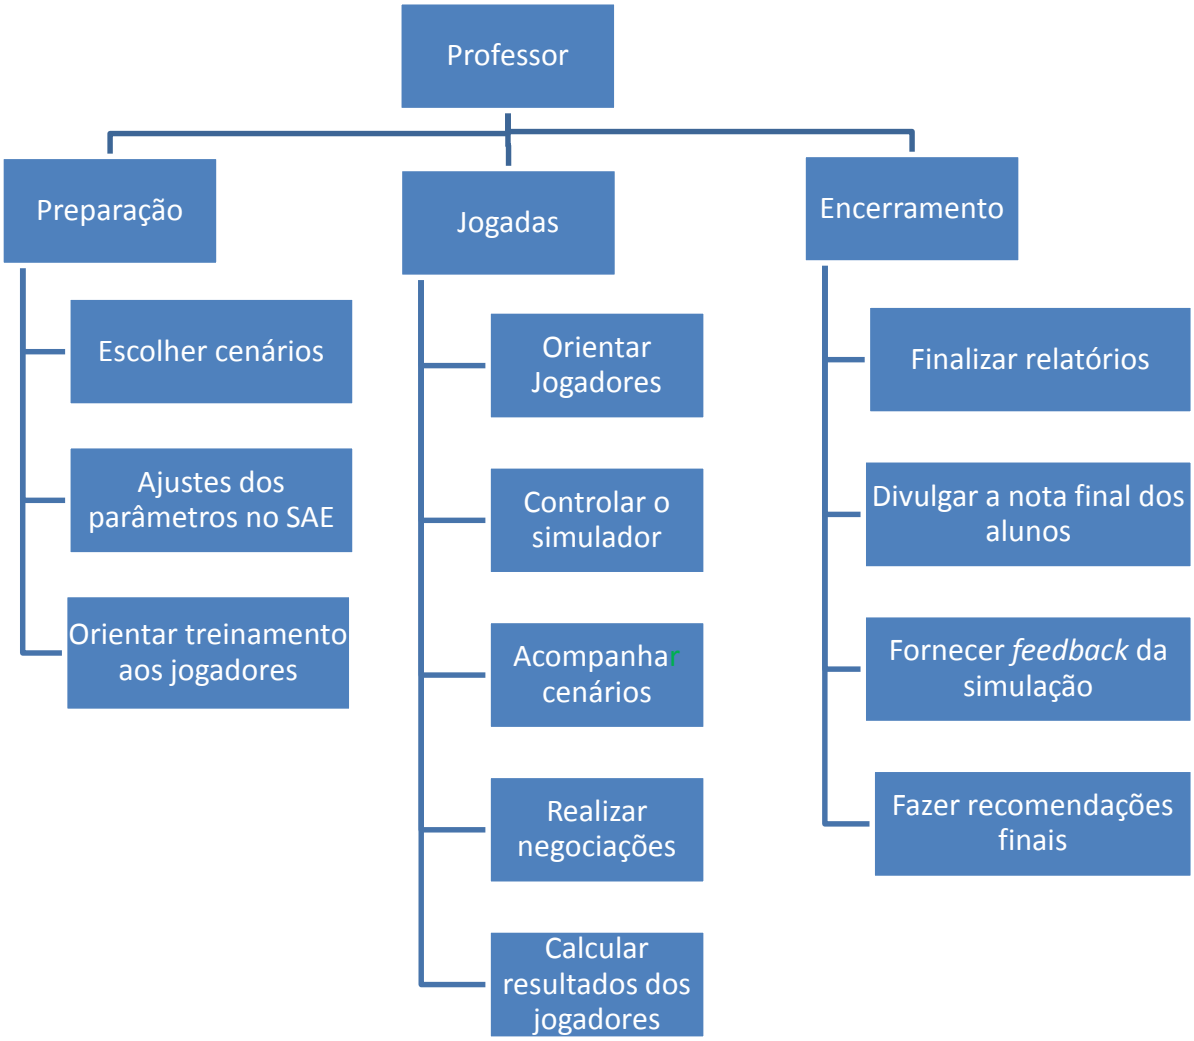

A figura 25 exemplifica o mapeamento de ações do aluno, na utilização do SAE.

Figura 25. Mapeamento de ações do Aluno.

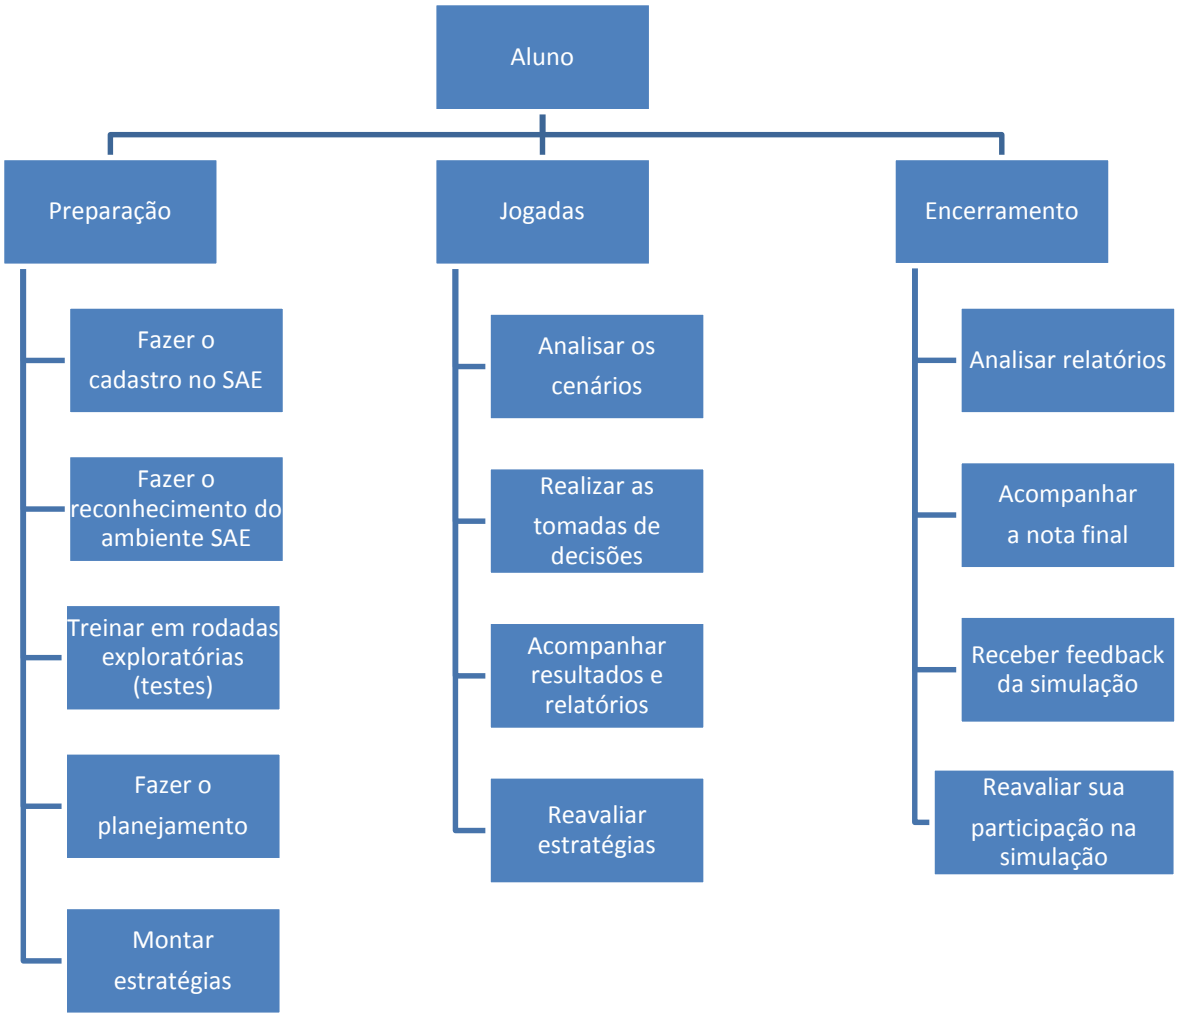

A figura 26 exemplifica uma jogada relativa a um ciclo da simulação, com ações do aluno e professor na utilização do SAE.

Figura 26. Mapeamento de ações ocorridas em uma jogada.