

SimuLinova: Uma Ferramenta de Simulação para Avaliação da Evolução de Ganhos com Inovação

Marcos Negreiros*, João Amilcar Viana Rodrigues,
Mário José Maia Leitão, Samuel Façanha Câmara

Submissão em 30/11/2015; Aprovação em 14/12/2015

RESUMO

Este artigo apresenta os detalhes de um sistema computacional, SimuLinova, desenvolvido para ser um ambiente de testes e simulação, que representa de forma detalhada o processo de co-evolução inovativa em rede. Os modelos utilizados para a elaboração do sistema foram os grafos assimétricos, os algoritmos evolutivos e os modelos de agentes. Mostra-se aqui como o sistema reproduz um cenário de interação de empresas, a partir da definição de métricas de absorção, que estabelecem claramente a forma como um indivíduo aprende em rede. Foi adaptado um método evolutivo similar ao algoritmo genético, para preencher os requisitos de evolução de um ambiente de inovação.

PALAVRAS CHAVES

Inovação, Simulação, Algoritmos Evolutivos.

ABSTRACT

This paper presents the details of SimuLinova, a computational system developed to be an environment for tests and simulation which represents in detail the process of innovative co-evolution network. The models used for the development of the system were asymmetric graphs, evolutionary algorithms and models of agents. It is shown here how the system reproduces a scenario of interaction between companies from the definition of metrics of absorption, which clearly establish how an individual learns in a network. A similar evolutionary genetic algorithm method was adapted, to fulfill the insights of evolution in an innovative environment.

KEY WORDS

Simulation, Evolutionary Algorithms, Innovation.

1. INTRODUÇÃO

O conhecimento evolui e se expande continuamente e em diferentes direções e entre inúmeras relações e atores. Promove de forma diferente a construção de novas tecnologias e inovações, (NELSON, 2003). Assim, os atores, ou seja, indivíduos ou organizações não podem esperar para dominar todo o conhecimento relevante sozinhos. Em vez disso, eles precisam adquirir e gerar conhecimento a partir do exterior das suas organizações, através da formação de parcerias com outras organizações e indivíduos e na formação de redes, "clusters" (grupos) e outros ambientes que sejam propícios ao desenvolvimento das capacidades inovativas, (ALLEN, 1983; AHUJA, 2000).

Nesta direção, a literatura indica que relações em rede como ambiente inovativo, mostram que as organizações podem aumentar o seu campo de pesquisa e com isso as chances de produzirem novos produtos, através do aumento dos laços entre os atores em redes, (FLEMING, 2001). Como resultado, as estruturas e redes sociais em torno de atores inovadores tornaram-se cada vez mais importantes e afetam diretamente o processo de inovação, (RITTER; GEMUNDEN, 2003). Embora o processo possa ser restringido por uma busca por parceiros locais, (DOSI, 1988; TEECE, 1988).

Para que as organizações aproveitem plenamente esta ampliação das possibilidades inovativas, é preciso desenvolver Capacidades de Absorção do conhecimento gerado e acumulado externamente à

* **Vinculação profissional:** Programa de Pós-Graduação em Administração da Universidade Estadual do Ceará – PPGA/UECE. **Endereço:** Av. Paranajana, 1700 – Campus do Itaperi, Fortaleza – Ceará, CEP: 601740-000. Email: negreiro@graphvs.com.br.

organização, (COHEN; LEVINTHAL, 1989). Assim, a capacidade de absorção representa a rotina adquirida de absorver e utilizar o conhecimento para a geração das capacidades tecnológicas organizacionais, que possibilitam as empresas acumular este conhecimento externo e transformá-lo em um novo conhecimento para a organização, (ZAHRA; GEORGE, 2002), (MALHOTRA; TODOROVA; DURISIN, 2001).

As análises empíricas a um nível micro têm demonstrado que a posição de um indivíduo ou uma organização na rede afeta sua propensão para inovar (BURT, 2004), (FLEMING; MARX, 2006). Em um nível macro, estudos, como por exemplo, o do caso sobre o Vale do Silício e Boston nos Estados Unidos da América, descobriram que as redes regionais promovem inovações.

A teoria, para inúmeros autores, denominados frequentemente de neoschumpeterianos (EDQUIST, 1997), (LUNDVAL et al, 2002) e (NELSON, 2003), entendem o processo de aprendizado e inovação de uma forma dinâmica, procurando elucidar o comportamento proativo dos agentes em seus ambientes. Essa teoria aponta para o fato de que esse processo se refere a práticas localizadas, cumulativas e específicas a cada firma, o que se reflete nos diferentes níveis e tipos de aprendizado que cada agente apresenta, demonstrando sua capacidade em evoluir e explorar as novas oportunidades tecnológicas com as quais se defronta.

Assim, as empresas geralmente se envolvem em processos caros e formais de pesquisa tecnológica e escolhem seus parceiros estrategicamente conforme suas posições em ambiente como as redes. Desta forma, atores têm conexões possíveis no sentido de que eles estão cientes de um conjunto de "vizinhos" (ou parceiros) que podem acessar quando necessário, enquanto as ligações realizadas são as conexões entre os atores que realmente existem em um momento específico do tempo. Conseqüentemente, o processo de inovação é modelado como atores que escolhem estrategicamente suas estratégias de ligação dentro da rede favorecendo uma maior capacidade de inovação.

O termo simulação computacional significa o uso de um modelo computacional para obter esclarecimentos adicionais sobre o comportamento de um sistema complexo (sistemas biológicas ou sociais, por exemplo). Neste tipo de modelo, se prevê as implicações das escolhas individuais, além de avaliar projetos e planos, sem realmente trazê-los à existência no mundo real.

Estudos sobre inovação com foco em redes têm enfatizado principalmente o papel das redes na difusão da inovação, (COLEMAN, 1966), (BURT, 1987). O que não foi destacado é a forma como a estrutura da rede afeta o processo e a velocidade de inovação com foco nas empresas. Nesta frente, modelos utilizando métodos de simulação tornaram-se ferramentas úteis para obter ideias sobre como as estruturas de rede de cooperação afetam o processo de inovação, uma vez que as simulações não são limitadas aos problemas de coleta de dados empíricos. Assim, o que ainda é escasso na literatura são os ambientes e experimentos controlados que distinguem como as distintas configurações da rede podem afetar o processo de inovação.

Trabalhos desta natureza desenvolvem modelos que podem ser testados empiricamente, mas que normalmente, no campo da inovação, carecem da aplicação experimental controlada e que permitam perceber como estes sistemas evoluem.

Este trabalho pretende discutir a construção de uma ferramenta computacional que represente o processo de co-evolução inovativa em rede, definir métricas de cooperação, redes de cooperação e taxas de absorção de conhecimento tecnológico pela interação entre pares de empresas que cooperam de forma assimétrica.

Na seção 2, discutem-se as premissas do modelo de simulação usado, baseado em algoritmo evolutivo, na seção 3 apresenta-se a ferramenta computacional e a detalhamos, e na seção 4 apresentamos as conclusões deste trabalho com os principais resultados e benefícios que a ferramenta traz com o seu uso precoce no planejamento estratégico de negócios.

2. PREMISSAS DO MODELO EVOLUTIVO DE SIMULAÇÃO

Para o melhor entendimento de como foi desenvolvida a ferramenta SimuLinova, a seguir discutimos os aspectos dos modelos de grafos adotados para definir o mapeamento do relacionamento entre indivíduos, o modelo evolutivo baseado nos algoritmos genéticos (GAs) e o modelo de comportamento baseado em agentes.


2.1. Modelo de Interação entre Indivíduos

A representação matemática e computacional de um conjunto de indivíduos que se relacionam pode ser feita de muitas maneiras. Sendo a ideia central a de que as empresas de um setor se comunicam

entre si através de um processo de interação formando uma rede, estas empresas e as interações entre elas podem ser modeladas através de um modelo matemático denominado de grafo $G(V,L)$, (BOAVENTURA, 2004). Onde V é o conjunto de vértices (empresas) e L é o conjunto de ligações entre vértices de G - (define-se uma ligação entre v_i e $v_j \in V$, quando existe alguma interação entre dois vértices de G , ou entre duas empresas).

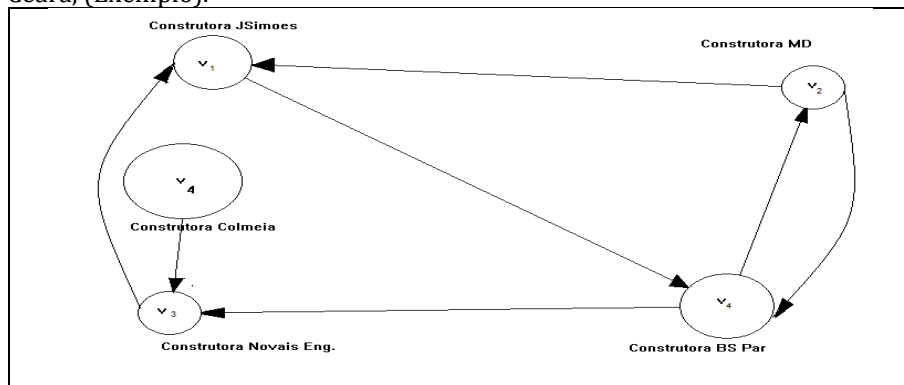
A rede tem absorção simétrica, quando as ligações são biunívocas, ou quando a influência da empresa v_i na empresa v_j é a mesma em ambos os sentidos, caracterizando uma rede simétrica $G_S(V,E)$, Figura 1. A rede tem absorção assimétrica, quando a influência da empresa v_i na empresa v_j é distinta nos dois sentidos, podendo ou não haver influência em um ou noutro sentido. Isto caracteriza uma rede assimétrica $G_A(V,A)$ (Figura 2).

Figura 1: Grafo - $G(V,E)$ de relacionamento entre construtoras do Ceará, onde as maiores e as menores construtoras influenciam entre si de forma simétrica (Exemplo).



A Figura 2 apresenta um exemplo de uma rede de interação assimétrica, onde se mapeia hipoteticamente o relacionamento entre quatro construtoras do Ceará. No grafo apresentado, a construtora Colmeia somente influencia a Construtora Novais Engenharia, sendo uma empresa isolada das demais. Neste caso, nota-se que os resultados de cooperação da rede só existem entre as construtoras MD, BSPar, JSimões e Novais Engenharia, pois possuem relacionamentos que permitem receber e repassar seus resultados aos demais. A rede mostra que todos os que cooperam se beneficiam da construtora isolada através da construtora Novais Engenharia. Deste modo, o modelo permite indicar que a evolução pode acontecer de algum modo na Construtora Colmeia, somente quando ela investir em inovação a partir de seus contatos com outras empresas senão as que estão relacionadas no grafo.

Figura 2: Grafo Assimétrico - $G(V,A)$ de relacionamento entre construtoras do Ceará, (Exemplo).



Os relacionamentos podem ser medidos em função da quantidade de empresas que interagem entre si, neste caso, denomina-se de densidade da rede, a quantidade de ligações que cada vértice possui. A densidade é em geral definida em relação ao máximo número de vértices da rede que se comunica com um dado vértice. Para efeito de estudos, a graduação da densidade define por outro lado o grau de esparsidade da rede.

Uma ampla diversidade de topologias de redes pode ser construída. As topologias indicam a forma

com que os vértices se agrupam na rede, ou mesmo como a densidade acontece promovendo um tipo de arranjo específico entre vértices de uma rede.

A estrutura do grafo retorna importantes informações sobre a interação entre os vértices. Além da densidade, existe a medida de centralidade de um vértice. A centralidade de um vértice se refere ao comprimento de caminho (medido pela média do número de ligações) do vértice até atingir cada um dos demais.

Tabela 1: Medida de centralidade entre diversos vértices do grafo de relacionamento entre construtoras.

	COLMEIA	JSIMOES	NOVAIS	MD	BSPAR	CENTRALIDADE
COLMEIA	0	2	1	4	3	2,5
JSIMOES	INF	0	2	2	1	INF
NOVAIS	INF	1	0	3	2	INF
MD	INF	1	2	0	1	INF
BSPAR	INF	2	1	1	0	INF

Para o exemplo da Figura 2, a centralidade dos vértices que correspondem às relações entre as construtoras pode ser obtida da Tabela 1, onde a distância mais curta da relação entre construtoras está mostrada nas células (p. ex.: a distância de relacionamento entre Colmeia e MD é de 4 unidades, pois o percurso de relacionamento entre Colmeia e MD é descrito por: Colmeia→Novais→JSimoes→BSPar→MD). Nota-se que a construtora mais central entre todas é a construtora Colmeia. No entanto, se desconsiderarmos as relações com a construtora Colmeia, e como ela não se relaciona com as demais no caminho de volta, as construtoras que mais proximamente interagem com as demais são a MD e a BSPar.

2.2. Modelo de Evolutivo

A ideia de aplicar os princípios darwinianos (evolutivos) para automatizar a resolução de problemas remonta aos anos quarenta, muito antes da descoberta de computadores (FOGEL, 1998). Em 1962, Bremermann executou experimentos de otimização baseados em computador utilizando mecanismos de evolução e recombinação. No texto *"The evolution of intelligence"* ele incluiu no seu trabalho uma população de indivíduos que procuravam o ótimo de uma função. Neste modelo, ele incluiu o potencial dos indivíduos de recombinar seus componentes, oferecendo assim um dos primeiros protótipos completos para os Algoritmos Evolutivos.

Durante a década de 1960 foram desenvolvidas três implementações diferentes usando a mesma ideia básica de evolução. Nos Estados Unidos, Fogel, Owens e Walsh introduziram a Programação Evolucionária (FOGEL; OWENS; WALSH, 1965), enquanto isso, na Alemanha, Rechenberg e Schwefel inventaram as Estratégias Evolucionárias (SCHWEFEL, 1995). Já Holland chamou seu método de Algoritmo Genético (HOLLAND, 1975).

O objetivo principal de Holland não era simplesmente projetar um algoritmo que resolvesse funções específicas, mas desenvolver um método para representar os mecanismos de adaptação natural. Cada estratégia seguida representa simplesmente a estratégia de um agente particular.

Assim, segundo Arifovic (1991) os algoritmos genéticos (GA), originalmente desenvolvidos por Holland (1975), como um modelo de evolução biológica, foram estabelecidos como uma descrição alternativa do comportamento humano em contextos econômicos (BIRCHENHALL, 1995).

A aprendizagem social pode ser modelada através de um GA, quando cada agente for representado por uma estratégia de cada vez e as estratégias evoluem através do intercâmbio de informações entre agentes. A aprendizagem individual corresponde a um sistema classificador, em que um agente tem um conjunto de soluções para escolher e seleciona a única a ser realizada em função do seu sucesso anterior. Através dos GAs pode-se modelar a aprendizagem individual, uma vez que podem ser criadas além das existentes, e dentro possíveis estratégias que cada agente pode assumir, (HOLLAND, 1975). Os GAs refletem, portanto, o processo de seleção natural interna às organizações sociais.

Um pressuposto básico subjacente ao algoritmo genético é a conjectura de que as soluções mais bem-sucedidas são mais propensas a fornecer material de base adequada para futuras gerações. Ao utilizar GA em um contexto econômico, os operadores do algoritmo são interpretados como passos de um processo de "aprendizagem adaptativa" ou "aprendizado evolutivo", (ARIFOVIC; KARAIIVANOV, 2006). A solução é um produto, uma quantidade de saída ou uma estratégia de um agente econômico de mercado.

Desta forma, a computação evolucionária oferece algoritmos baseados nos mecanismos da seleção natural e da genética, tais como algoritmos genéticos (GOLDBERG, 2002), a programação genética (BANZHALL et al 1989), a programação evolutiva (BACK, 1996), a aprendizagem por sistemas de classificadores e estratégias evolutivas. Estas técnicas são cada vez mais aplicadas à modelagem econômico-evolutiva (ARIFOVIC, 2000).

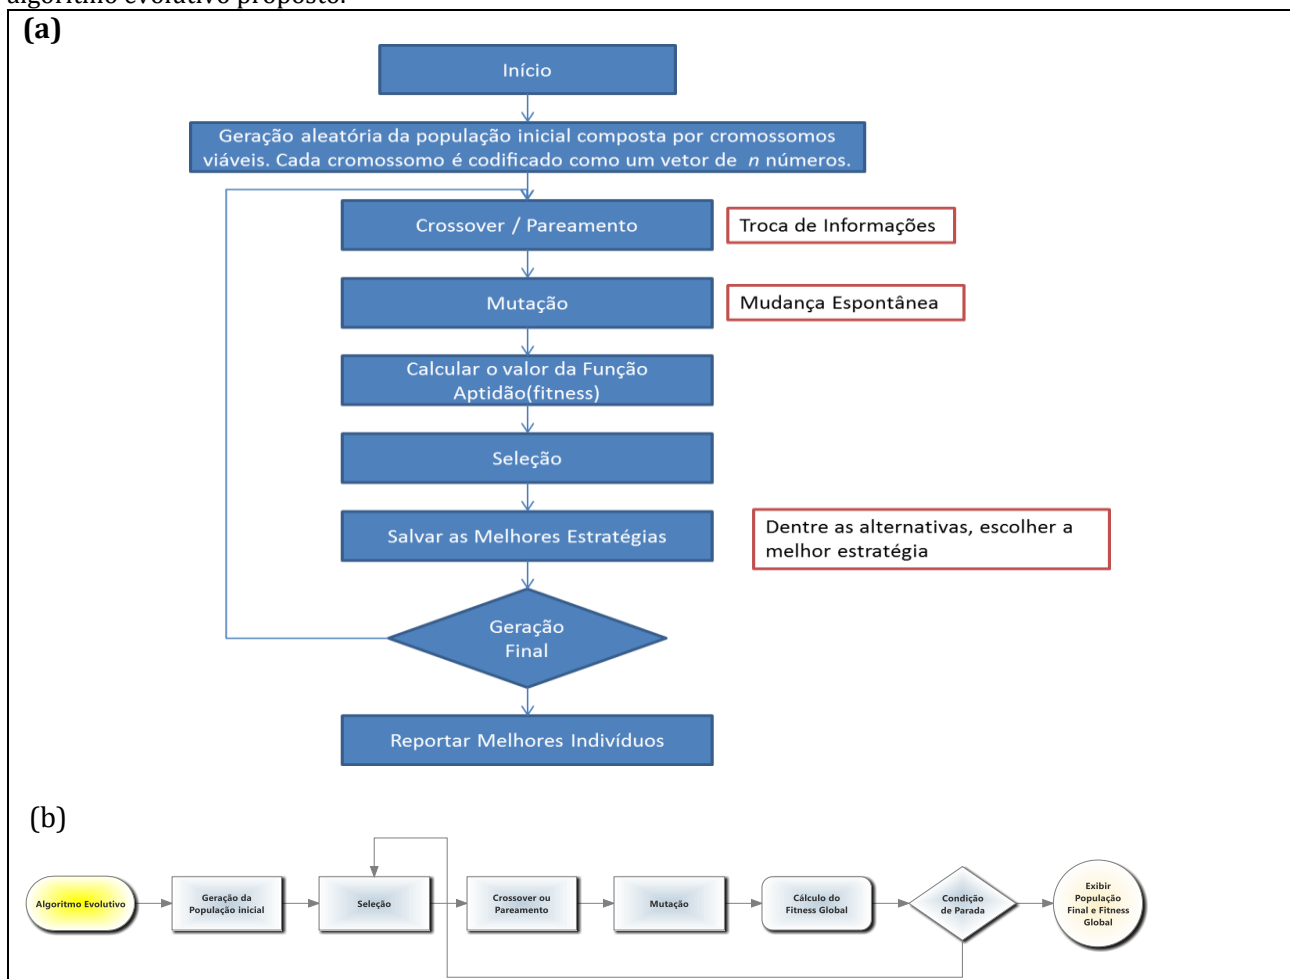
Em modelos de computação evolucionária, não só os indivíduos mudam ao longo do tempo, mas a população evolui devido a processos de replicação e de variação na seleção. Riechmann (1999) propôs interpretar esses operadores evolutivos em termos de interações socioeconômicas, ou seja, como a aprendizagem por imitação (replicação seletiva), a aprendizagem através da comunicação (*crossover*) e de aprendizagem pela experimentação (mutação).

Central a todas as técnicas de computação evolutiva é o processo de busca de melhores soluções. Ela envolve a geração de novas opções com operadores de mutação e recombinação. Um operador de mutação tem sempre um comportamento estocástico. Ele normalmente é projetado para agir, sobre alguma probabilidade positiva, alterando um valor de uma característica de um indivíduo selecionada aleatoriamente.

A recombinação (*crossover*) funde informações (características) de dois códigos de pais em um código de prole. A diferença importante entre a mutação e recombinação é que a mutação é um operador unário; requer um objeto como uma entrada, enquanto cruzamento é tipicamente um operador binário, ou seja: aplica-se sempre a dois objetos (pais).

Além disso, a possibilidade de recombinação, com mais de dois pais, também é possível no contexto socioeconômico e tecnológico, (EIBEN, 2000). Isto cria um espectro muito amplo de resultados de inovação. Tais recombinações múltiplas podem ocorrer numa rodada (geração) do algoritmo genético várias vezes, ou ao longo das rodadas do algoritmo genético.

Figura 3 – (a) Processo de evolutivo através de um Algoritmo Genético padrão, (b) Processo evolutivo através do algoritmo evolutivo proposto.



A mutação é um momento importante neste algoritmo. Indica-se aqui que uma empresa modifica

suas características espontaneamente. A analogia a isto pode ser feita quando se tem, por exemplo, uma empresa que aprende por si só uma técnica em um setor que melhora seus processos e impacta positivamente nos seus resultados operacionais. Esta etapa de evolução acontece normalmente, e é absorvida no algoritmo genético como a etapa de mutação

O algoritmo genético que representa essa natureza evolutiva é descrito na Figura 4 (a), já o nosso algoritmo evolutivo aqui proposto considera que os indivíduos da população são os mesmos ao longo das gerações, e evoluem pela interação entre indivíduos de sua rede de vizinhos ou por mutação própria, deste modo o processo de seleção dos indivíduos que interagem ou sofrem mutação acontece antes do que se faz originalmente, Figura 4(b).

Figura 4: Cromossomo representando uma empresa com seus setores e níveis de inovação indicados nos seus gens.

EMPRESA A							
CONTABILIDADE		LOGÍSTICA			MARKETING	VENDAS	EXECUTIVO
A PAGAR	A RECEBER	ESTOQUE	ARMAZENAGEM	DISTRIBUIÇÃO			
7	5	8	4	5	7	9	7

A base dos algoritmos genéticos (GA) é o mapeamento das características de cada indivíduo. Todo indivíduo pode ser mapeado por suas características, e estas características são descritas através de um cromossomo. No cromossomo, temos os gens, que formam a parte mais elementar do cromossomo.

Seguindo este modelo, pode-se descrever o cromossomo de empresas por seus setores de inovação, por exemplo: Contabilidade, Logística, Marketing, Vendas, etc. No exemplo a seguir pode-se considerar que cada setor da empresa (*gene*) deve possuir um grau de inovação, que pode ser nivelado pelos escores de zero (0) a nove (9).

A Figura 4 mostra um exemplo de descritor de uma empresa com seus graus de inovação, ou conhecimento tecnológico em cada setor especificado. Para o modelo evolutivo usando Algoritmos Genéticos, este descritor seria o cromossomo, e os *genes* são os setores da empresa. Conforme a Figura 4, no *gene* "Estoque", a Empresa A possui característica 8, ou seja, para nós o nível de inovação tecnológica desta empresa pode ser medido com grau 8 de uma escala de zero a nove.

O algoritmo evolutivo proposto, pode ser empregado para modelar a aprendizagem individual em sistemas multi-agente. Nesses modelos, cada agente observa uma representação do estado atual e realiza uma ação de acordo com uma regra de decisão selecionada (a partir de um conjunto finito de regras). Depois de todos os agentes empreenderem suas decisões, os resultados são revelados. Aqueles agentes que possuem regras mais eficazes têm uma maior evoluir mais rapidamente. Com o tempo, um algoritmo evolutivo evolui para um conjunto de características ótimo ou um conjunto de regras que retornam as respostas de um ambiente em mudança, promovido pela influência dos indivíduos uns nos outros.

2.3. Modelo Baseado em Agentes

Modelagem baseada em agentes (MBA) é uma técnica de simulação que vem sendo cada vez mais aplicada em diversos tipos de pesquisas científicas. Nos modelos baseados em agentes, muitos agentes interagem de acordo com regras simples, resultando no surgimento de comportamento complexo em nível agregado.

Foi a partir dessa perspectiva de modelagem das interações de muitos indivíduos, que o interesse na simulação como uma ferramenta para as ciências sociais aumentou fortemente. Nestes modelos o comportamento complexo não surge de superposição, mas diretamente, de baixo para cima a partir de ações e interações dos atores no nível micro.

Tecnicamente cada agente é composto apenas por um conjunto de regras lógicas de comportamento e uma lista de estados internos, o que representa, por exemplo, a memória ou suas capacidades tecnológicas.

Formalmente, os agentes podem ser definidos como entidades computacionais, geralmente mostrando alguma forma de racionalidade limitada, situado em algum ambiente, capaz de realizar ações autônomas flexíveis com o objetivo de atender seus objetivos, (WOOLDRIDGE, 2003). Os agentes inteligentes são caracterizados como sendo capazes de perceber o ambiente e responder a ele; de exibir um comportamento orientado a metas, e de interagir com outros agentes. Estas interações podem ocorrer indiretamente através do ambiente em que agentes são incorporados, ou estão em comunicação direta com outros agentes. Interações dos agentes, bem como o *feedback* de agregado (macro) para desagregar (micro) fenômenos, são as fontes de uma dinâmica não-linear.

A modelagem de estruturas organizacionais e estratégias de inovação, têm sido outras aplicações importantes para MBAs (DAWID; REIMANN; BULLNHEIMER, 2001; DEBENHAM; WILKINSON, 2003; GILBERT; PYKA; AHRWEILER, 2001).

Assim, simulações de modelos baseados em agentes são metodologias eficazes para examinar diferentes estratégias no processo de inovação. Nesses modelos os agentes representam, por exemplo, as empresas adaptáveis, laboratórios de pesquisa, ou mercados. Cada geração de bases de conhecimento leva à inovação. A disseminação de conhecimento ou informação entre os agentes são modeladas pelos grafos para representar estratégias colaborativas ou competitivas.

Gilbert, Pyka e Ahrweiler (2001) consideram inovação em redes como evolução da articulação dinâmica e contingente de unidades heterogêneas, cada uma possuindo diferentes feixes de conhecimento e habilidade. Eles concluíram que *"em suma, [inovação] redes são sistemas adaptativos complexos: são geralmente auto-organizáveis, de adaptação ao seu ambiente, não têm mecanismos de controle central, e seu estado atual é dependente de sua história passada. Inovações podem ser vistas como resultados emergentes e imprevisíveis da operação de redes."*

Ao se procurar uma definição sobre o termo "agente" depara-se com diversos conceitos. Um deles foi proposto por Wooldridge (2003) onde diz que: "Um agente é um sistema computacional que está situado em algum ambiente e que é capaz de executar ações de maneira autônoma neste ambiente, com o propósito de atingir seus objetivos", (WOOLDRIDGE, 2003, p. 15).

Agentes, suas interações sociais, e seus processos de tomada de decisão podem ser modelados de forma explícita. A dinâmica de nível macro do sistema social emerge dinamicamente a partir do comportamento individual e agregada às interações entre os agentes.

Segundo Wooldridge e Jannings (1995) os agentes em um sistema multi-agentes, têm várias características importantes. Inicialmente, cada agente age de forma independente de acordo com as regras da simulação e o seu comportamento é pré-programado. Estas regras e comportamentos podem ter uma ou mais das seguintes características:

- **Meta** - O agente atua de modo a alcançar um determinado objetivo, que pode ser ou um valor relativo ou um local. Por exemplo, um agente pode ser projetado para maximizar a acumulação de um determinado recurso operacional;
- **Reatividade** - O agente percebe seu entorno de tal forma que ele está ciente de seu ambiente. Por exemplo, um agente pode estar ciente de locais onde existem recursos;
- **Racionalidade limitada** - A fim de proporcionar um maior poder preditivo, os agentes são condicionados em termos de recursos de informação ou à sua capacidade analítica;
- **Interatividade** - Os agentes podem interagir ou trocar de informações com outros agentes. Estas interações podem ter efeitos específicos sobre os agentes, incluindo a sua destruição ou alteração no comportamento de busca por um objetivo;
- **Adaptação** - Alteração do estado atual de um agente baseado em interações com o ambiente ou com outros agentes.

2.4. Modelo Evolutivo de Simulação

O propósito deste modelo é buscar compreender a dinâmica evolucionária decorrente da interação de um conjunto de empresas e sua relação com outras empresas em um ambiente específico. O modelo descreve o comportamento de um número de empresas concorrentes que fabricam produtos com desempenho equivalente.

A descrição do modelo é determinada de uma forma muito geral, porque a plataforma pode ser aplicada a contextos diferentes, e pode ser usado para enfatizar perspectivas diferentes, por exemplo, do ponto de vista econômico ou sociológico sobre a evolução das redes de inovação. Os atores formam o ponto de partida de uma rede de inovação. Estes são as empresas envolvidas com Pesquisa & Desenvolvimento (P&D). Os atores são representados com um código que tem carregam em para si os atributos padrões dos agentes inteligentes, (WOOLDRIDGE; JENNINGS, 1995):

- Autonomia;
- Habilidades Sociais;
- Reatividade;
- Proatividade.

Os atores são capazes de aprender com seus próprios esforços de pesquisa (mutação) e com outros atores com os quais colaboram (Pareamento).

Para representar os atores, recorremos a uma representação genética seguindo o conceito de Genótipo, (GILBERT, 1997). O Genótipo de um agente i onde $i \in \{1, \dots, n\}$ e um conjunto de Capacidades Tecnológicas C_i^j , onde $i \in \{1, \dots, n\}$ representa as diferentes áreas tecnológicas medidas.

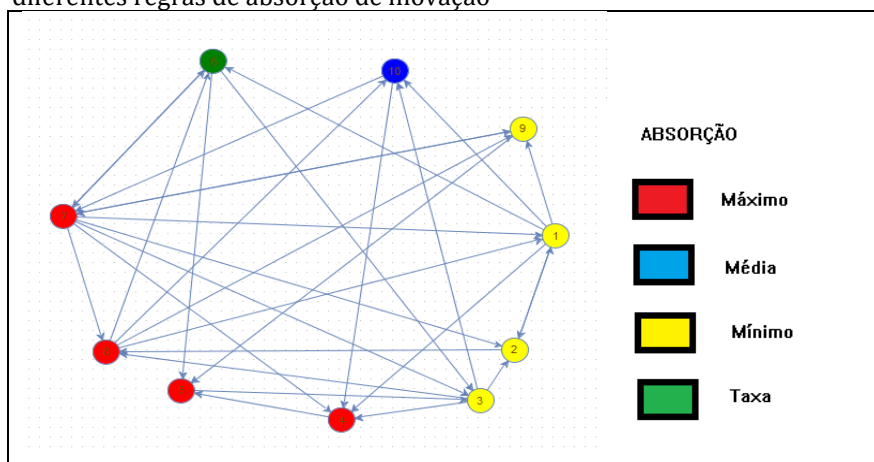
Os agentes têm sua capacidade de absorção representada por $A_j^i = m, \forall m \in [0,1]$ medida em valores que representam uma distribuição entre 0 e 1, onde 0 indica a ausência de capacidade de absorção e 1 é definida como capacidade máxima de absorção. A estrutura geral de um Agente i é representada pelo conjunto, a seguir:

$$\text{Agente}_i = \left(\left(\frac{C_1^i}{A_1^i} \right), \left(\frac{C_2^i}{A_2^i} \right), \dots, \left(\frac{C_n^i}{A_n^i} \right) \right),$$

Durante os processos de inovação, os valores desta estrutura se alteram de acordo com as ligações entre agentes. Neste momento o modelo pressupõe a formação de diferentes cenários para diferentes tipos de redes, assim como pressupõe a formação de diferentes cenários que passariam a influenciar na trajetória evolutiva dos agentes do modelo.

A Figura 5 apresenta um grafo de relacionamento de agentes, onde os vértices (agentes) pintados de vermelho, azul, amarelo e verde contêm regras de absorção que são indicadas pela sua cor. No exemplo, o grupo vermelho tem a mesma quantidade de indivíduos do grupo amarelo, a regra indica que este último grupo tem uma visão minimalista a inovação, enquanto o primeiro é formado por empresas ávidas ao aprendizado. Este modelo é robusto à revisão de estados iniciais dos agentes e sua evolução.

Figura 5: Modelo de um grafo $G(V,A)$ de relacionamento entre 10 agentes e diferentes regras de absorção de inovação



3. O SIMULINOVA

O projeto **SimuLInova**, é uma aplicação computacional desenvolvida em Java, pela equipe do LCC-Laboratório de Computação Científica da UECE, que visa promover a visualização de diversos cenários sobre o processo evolutivo de interação entre agentes de comportamento similar e/ou distinto.

A Figura 6 apresenta a arquitetura do sistema, onde se tem basicamente três Módulos: Configuração, Execução e Simulação, os quais são detalhados a seguir.

3.1. Módulo de Configuração

O módulo de configuração permite que o usuário determine os parâmetros necessários ao processo de execução de uma rodada do algoritmo evolutivo, ou de muitas execuções do algoritmo (simulação).

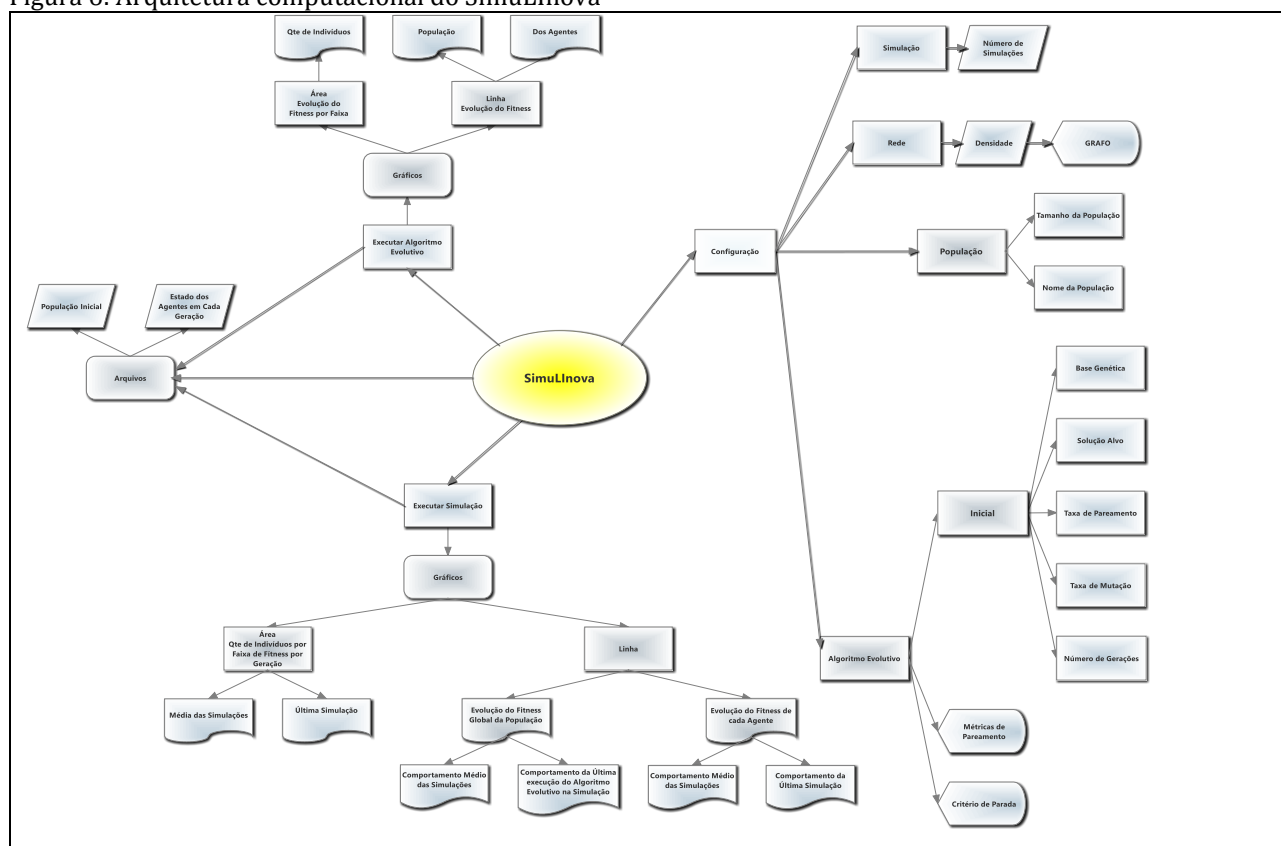
Este módulo se divide em três partes: Algoritmo Evolutivo, População, Rede e Simulação.

No algoritmo evolutivo, definem-se as configurações de funcionamento do método evolutivo, onde as subdividimos em três partes: Inicial, Métricas de Pareamento e Critérios de Parada.

a) Inicial:

- **Base Genética:** Onde se configura a base genética de cada vértice do grafo (empresas). Neste caso, o usuário estabelece os números válidos para se configurar a base genética. Por exemplo: indicando-se 01234, são válidos apenas os números 0, 1, 2, 3 e 4, para compor a base genética das empresas a serem construídas.
- **Solução Alvo:** define-se aqui o valor final que será obtido no processo evolutivo das empresas. O usuário estabelece aqui o objetivo a ser alcançado pela empresa no cromossomo padrão final. Por exemplo: indicando-se 2304, a solução final a ser perseguida pela empresa seria 2304.

Figura 6: Arquitetura computacional do SimuInova



- **Solução Alvo:** define-se aqui o valor final que será obtido no processo evolutivo das empresas. O usuário estabelece aqui o objetivo a ser alcançado pela empresa no cromossomo padrão final. Por exemplo: indicando-se 2304, a solução final a ser perseguida pela empresa seria 2304.
- No algoritmo evolutivo, o objetivo é medido por uma função denominada *Fitness*. Esta função compara a solução atual com a solução corrente, e conta o número de vezes que os genes são idênticos no mesmo setor entre o cromossomo da empresa em avaliação e o cromossomo alvo. Por exemplo: se uma empresa X tem cromossomo 1302, a *fitness* para o alvo 2304 é 2, pois o 0 e o 3 estão na mesma posição do alvo. O *fitness* global acontece pela soma dos *fitness* individuais de cada empresa.
- **Taxa de Pareamento:** define-se aqui um valor percentual de pareamento que poderá ser feito entre cromossomos de duas empresas distintas. Por exemplo: se numa rede de 100 agentes um agente tem 50 indivíduos que influencia diretamente, e a taxa de pareamento for definida como sendo 50%, então está se dizendo para o algoritmo evolutivo, que durante a seleção dos pares de cromossomos (empresas) que ele influencia, somente 25 deles devem ser considerados. O algoritmo então selecionará aleatoriamente (com distribuição uniforme) 25 das empresas que se comunicam com ela para parear os cromossomos numa tarefa de *crossover*.
- **Taxa de Mutação:** define-se aqui a possibilidade de mudança dos indivíduos. Neste caso, do universo de indivíduos da população, alguns deles podem ser aleatoriamente selecionados para que parte de seus genes sejam modificados. Assim, tanto a seleção dos indivíduos a serem mudados, quanto os

seus genes, estarão regidos pela taxa de mutação. Por exemplo, se for configurada uma taxa de mutação de 10% em uma população de 100 indivíduos, até 10 indivíduos serão aleatoriamente escolhidos para sofrerem mutação. Se os indivíduos possuem 10 genes, cada gene terá 10% de chance de se modificar para um valor arbitrário.

- **Número de Gerações:** para que haja evolução, os indivíduos devem interagir nos processos de crossover e mutação por um número de vezes. A cada iteração completa denomina-se geração. O número de gerações é determinado para se possa conhecer o estado da população ao longo de muitas iterações do algoritmo evolutivo.
- **Número de Gerações:** para que haja evolução, os indivíduos devem interagir nos processos de crossover e mutação por um número de vezes. A cada iteração completa denomina-se geração. O número de gerações é determinado para que se possa conhecer sobre o estado da população ao longo de muitas iterações do algoritmo evolutivo.

b) Métricas de Pareamento:

Como vimos acima, a arquitetura do SimullInova estabelece que sejam construídos cenários de simulação que permitem visualizar contextos diferentes de interação entre indivíduos de uma população. As iterações são mapeadas pelo grafo assimétrico $G(V,A)$, onde os vértices são considerados aqui como sendo as empresas e os arcos são as relações de influência entre elas. A ausência de arcos entre duas empresas significa que não há influência entre elas, e a presença de um arco do tipo $v_i \rightarrow v_j$ indica que a empresa v_i influencia a empresa v_j diretamente.

A medida de influência entre v_i e v_j é determinada por uma métrica de relacionamento que é atribuída a v_i , v_j ou a ambas simultaneamente, setor a setor.

A métrica de relacionamento determina como acontece a absorção tecnológica entre empresas. Dentre muitas métricas que podem ser construídas para configurar o relacionamento entre empresas, adotamos neste trabalho: Mínimo, Média, Taxa e Máximo.

As métricas operam da seguinte forma: Dadas duas empresas A e B, e os mesmos setores de A e B tomados, o resultado da operação de absorção entre os mesmos setores considerando a influência de A sobre B, é dado por:

$$\text{Atributo(Empresa(B), Setor)} = \text{Métrica(Atributo(Empresa(A), Setor), Atributo(Empresa(B), Setor))}$$

Por exemplo, consideremos as empresas A e B, (Figura 9):

Figura 9: Descritor dos setores de duas empresas A e B (Cromossomos das empresas A e B).

EMPRESA A							
CONTABILIDADE		LOGÍSTICA			MARKETING	VENDAS	EXECUTIVO
A PAGAR	A RECEBER	ESTOQUE	ARMAZENAGEM	DISTRIBUIÇÃO			
7	5	8	4	5	7	9	7

EMPRESA B							
CONTABILIDADE		LOGÍSTICA			MARKETING	VENDAS	EXECUTIVO
A PAGAR	A RECEBER	ESTOQUE	ARMAZENAGEM	DISTRIBUIÇÃO			
9	7	2	4	5	8	5	4

Considerando que o relacionamento entre as empresas A e B ocorrem de A para B sobre a **métrica Máximo**, após a interação de absorção de conhecimento pela influência entre todos os setores de A em B, a empresa B deverá ter como resultado, Figura 10:

Figura 10: Descritor dos setores de uma empresa B, após influência de A com métrica Máximo (Cromossomo da Empresa B).

EMPRESA B							
CONTABILIDADE		LOGÍSTICA			MARKETING	VENDAS	EXECUTIVO
A PAGAR	A RECEBER	ESTOQUE	ARMAZENAGEM	DISTRIBUIÇÃO			
9	7	8	4	5	8	9	7

Nota-se aqui que após a interação de inovação tecnológica, os setores de logística – estoque, vendas e executivo melhoraram devido à absorção pela interação máxima entre as empresas.

Considerando que o relacionamento entre as empresas A e B ocorrem de A para B agora sobre a

métrica Taxa, há uma razão especial. Neste caso, associa-se à influência sempre positiva do grau do setor de influência, ao que se tem atualmente, limitando-se ao maior grau. Ou seja:

$$\text{Atributo(Empresa(B), Setor(Vendas))} = \text{Mínimo}\{\text{Atributo(Empresa(B), Setor(Vendas))} + \text{Taxa} * \text{Atributo(Empresa(A), Setor(Vendas)), 9\}$$

Por exemplo, se supormos que a taxa de absorção é de 20% pela empresa B do atributo de A. Então no relacionamento entre as empresas A e B, B torna-se (Figura 11):

Figura 11: Descritor dos setores de uma empresa B, após influência de A com métrica Taxa(=20%) (Cromossomo da Empresa B).

EMPRESA B							
CONTABILIDADE		LOGÍSTICA			MARKETING	VENDAS	EXECUTIVO
A PAGAR	A RECEBER	ESTOQUE	ARMAZENAGEM	DISTRIBUIÇÃO			
9	8	3,6	4,8	6	9	6,8	5,4

Neste caso, somente o setor de contabilidade-contas a pagar da empresa B não sofreu mudança positiva, pela interação com A, usando a métrica Taxa.

Assim, quando o modelo trata de pareamento entre indivíduos, está fazendo exatamente o processo acima, setor a setor. A diferença básica é a de que quando está se fazendo o pareamento entre setores, o modelo de simulação aceita ou não fazer o processo de absorção entre os mesmos setores de uma empresa. Isto caracteriza o relacionamento entre duas empresas na realidade. Nem sempre se consegue que duas empresas se visualizem plenamente nos seus diversos setores, e assim os ganhos são obtidos quando elas vão interagindo, ou mesmo obtendo de fora ajuda necessária para sua evolução.

O “desaprendizado” pode ocorrer em um processo de interação entre dois indivíduos. Isto acontece entre empresas, quando num processo de interação elas percebem que estão usando inadequadamente certa tecnologia em um determinado setor. Esta medida pode ser obtida pelas **métricas: Média e Mínimo**.

Por exemplo, consideremos as empresas A e B, Figura 9, se a métrica de absorção usada for a média, e A influencia B, o resultado da empresa B, após a iteração, teremos:

Figura 12: Descritor dos setores de uma empresa B, após influência de A com a métrica Média ocorrendo “desaprendizado”/involução em setores (Cromossomo da Empresa B).

EMPRESA B							
CONTABILIDADE		LOGÍSTICA			MARKETING	VENDAS	EXECUTIVO
A PAGAR	A RECEBER	ESTOQUE	ARMAZENAGEM	DISTRIBUIÇÃO			
8	6	5	4	5	7,5	7	5,5

Nota-se aqui que após a iteração de inovação tecnológica, os setores de marketing, vendas e executivo melhoraram devido à absorção pela interação média entre os mesmos setores das duas empresas. Porém a empresa A influenciou negativamente o setor de contabilidade.

Na **métrica Taxa**, considera-se que durante o pareamento ou mesmo na mutação, o percentual do gene será acrescido de quem o influenciou nos setores que absorverão o crescimento positivo.

Por exemplo, supondo que a empresa B sofre mutação nos setores de logística e vendas a uma taxa de absorção de 20%, devido a melhorias identificadas por uma consultoria especializada (note que o limite do escore em 9 se mantem). O novo cromossomo da empresa poderá ser descrito como na figura 13.

Figura 13: Descritor dos setores de uma empresa B após mutação a uma taxa de absorção de 20% (Cromossomo da Empresa B).

EMPRESA B							
CONTABILIDADE		LOGÍSTICA			MARKETING	VENDAS	EXECUTIVO
A PAGAR	A RECEBER	ESTOQUE	ARMAZENAGEM	DISTRIBUIÇÃO			
9	7	2,2	4,8	6	8	6	4

Outro exemplo, supondo que a empresa B faz pareamento com a empresa A, sendo influenciada pela A nos setores de logística e vendas na mesma taxa de absorção de 20%. Então cada setor que absorve A, receberá 20% do valor do gene de A, respectivo. O novo cromossomo da empresa B poderá ser descrito como na figura 14.

c) Critério de Parada:

Para que o processo iterativo possa ser concluído num algoritmo evolutivo, adotam-se critérios de terminação em relação ao atingimento do *fitness* esperado (quando uma empresa atingir o objetivo máximo) ou ao final de um número de gerações. A escolha deste critério é importante, para se analisar com maior propriedade como está a evolução dos indivíduos ao longo do tempo.

Em nosso simulador, as taxa de pareamento e de mutação, para cada setor em processo de simulação do algoritmo evolutivo, podem variar dentro de uma distribuição constante de probabilidades.

Figura 14: Descritor dos setores de uma empresa B após mutação a uma taxa de absorção de 20% (Cromossomo da Empresa B).

Antes,							
EMPRESA A							
CONTABILIDADE		LOGÍSTICA			MARKETING	VENDAS	EXECUTIVO
A PAGAR	A RECEBER	ESTOQUE	ARMAZENAGEM	DISTRIBUIÇÃO			
7	5	8	4	5	7	9	7

Depois,							
EMPRESA B							
CONTABILIDADE		LOGÍSTICA			MARKETING	VENDAS	EXECUTIVO
A PAGAR	A RECEBER	ESTOQUE	ARMAZENAGEM	DISTRIBUIÇÃO			
9	7	2	4	5	8	5	4


Depois,							
EMPRESA B							
CONTABILIDADE		LOGÍSTICA			MARKETING	VENDAS	EXECUTIVO
A PAGAR	A RECEBER	ESTOQUE	ARMAZENAGEM	DISTRIBUIÇÃO			
9	7	3,6	4,8	6	8	6,8	4

3.2. Módulos de População, Rede e Simulação

No **módulo População**, o usuário define o tamanho da população (número de empresas) que deseja criar, assim como dá o nome à população a ser gerada. O sistema gerará aleatoriamente o conjunto de vértices, e seus atributos, e armazenará os dados em um arquivo com a seguinte descrição: <nome_da_populacao>PopulacaoInicial.XML. Caso seja necessário alterar este arquivo, basta usar um editor de texto ou de XML e alterar os dados diretamente, armazená-lo e em seguida chamar da simulação o arquivo com o nome dado.

No **módulo Rede**, o usuário definirá a criação do grafo assimétrico de relacionamento. Uma vez definido o tamanho da população (número de vértices), indica-se aqui a densidade do grafo, e se a densidade é fixa ou variável. Neste caso, sendo fixa, cada vértice terá o mesmo número de vizinhos, enquanto no outro caso os vizinhos são limitados ao máximo da densidade. Após estas seleções, o grafo é criado e apresentado na interface, mostrando os vértices nas cores vermelho para aqueles que usam a métrica de pareamento **Máximo**, azul para os que usam a métrica **Média**, amarelo para os que usam a métrica **Mínimo**, e verde para os que usam a métrica de pareamento **Mínimo**. Quando a métrica é a mesma para todos, todos estarão com a cor cinza (Figura 15).

Figura 15: (a) Grafo Agente, (b) Grafo de indivíduos com a mesma métrica



Por fim no **módulo Simulação** o ambiente permite a inserção do número de execuções de simulação do algoritmo evolutivo. Isto é na verdade a indicação para geração repetida de um número de vezes que o algoritmo evolutivo irá executar com os mesmos parâmetros indicados nas configurações.

Existem dois modos de visualização do processo de simulação: **Modo Geral** e **Modo Agente**. No **modo Geral**, os indivíduos são criados com taxas de absorção iguais para todos. Deste modo, podemos identificar o comportamento da evolução quando todos têm um comportamento interativo comum, indicando inclusive uma previsibilidade do modelo evolutivo para sua calibração. Já para o **modo Agente**, cada agente tem sua própria métrica de absorção, ou seja, quando ele faz o pareamento com outro indivíduo, ele absorve os valores por setor dependendo da métrica de absorção (aprendizado) que lhe foi atribuída no seu nascimento. A atitude de absorção do indivíduo nasce com ele e mantém-se ao longo de todas as gerações do processo evolutivo

3.3. Módulo de Execução do Algoritmo Evolutivo

O módulo de execução do algoritmo evolutivo gera duas saídas importantes, uma contendo gráficos com as soluções obtidas pelo algoritmo evolutivo considerando cada métrica usada no módulo geral, e outra contendo os arquivos com os dados de entrada do processo (Arquivo *Agente.XML). Nos dois casos as soluções de *fitness* são expressas em gráficos de linha e de área, que representam um processo evolutivo definido pelos parâmetros do modelo, estabelecido nas configurações anteriormente descritas.

Figura 16: Gráfico de linha para as métricas: máximo, média, mínimo e taxa.





Figura 17: Gráfico de área para a métrica taxa, com agentes de métrica igual



As Figuras 16 e 17 apresentam os gráficos de linha contendo o resultado de uma execução do algoritmo evolutivo para população onde os agentes têm as mesmas métricas - máximo, média, mínimo e taxa, ao longo de 50 gerações. E o gráfico de área para a métrica Taxa, onde se visualiza a quantidade de indivíduos que atingiram as quatro diferentes faixas de fitness indicadas ao longo das gerações.

As Figuras 16 e 17 apresentam os gráficos de linha contendo o resultado de uma execução do algoritmo evolutivo para população onde os agentes têm as mesmas métricas - máximo, média, mínimo e taxa, ao longo de 50 gerações. E o gráfico de área para a métrica Taxa, onde se visualiza a quantidade de indivíduos que atingiram as quatro diferentes faixas de fitness indicadas ao longo das gerações

3.4. Módulo de Execução das Simulações

O módulo de execução das simulações do algoritmo evolutivo gera quatro saídas importantes, uma contendo gráficos com a última simulação e a média das simulações, e outra contendo os arquivos com os dados de entrada do processo (Arquivo *Agente.XML). Da mesma forma como antes, nos dois casos as soluções de *fitness* são expressas em gráficos de linha e de área, que representam um processo

evolutivo definido pelos parâmetros do modelo, estabelecido nas configurações anteriormente descritas.

As Figuras 18, 19 e 20 apresentam os gráficos de linha e área contendo o resultado da média das execuções do algoritmo evolutivo para população onde os agentes têm métricas distintas, ao longo de 50 gerações. O gráfico de área mostra o resultado das médias das simulações do algoritmo evolutivo, onde se visualiza a quantidade de indivíduos que atingiram as quatro diferentes faixas de *fitness* indicadas ao longo das gerações. Por fim o gráfico de linhas de cada agente representa o comportamento médio de cada agente nas gerações ao longo de cada simulação.

Figura 18: Gráfico de linha agentes evolutivos para agentes de métricas distintas.




Figura 19: Gráfico de área com fixas de fitness para agentes de métricas distintas.

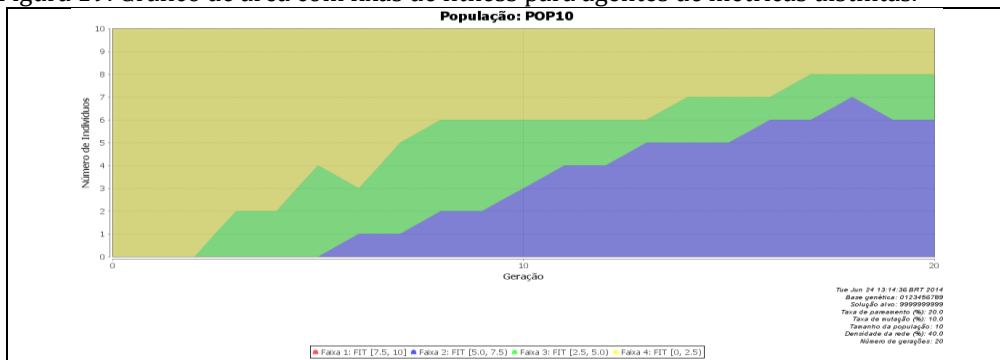
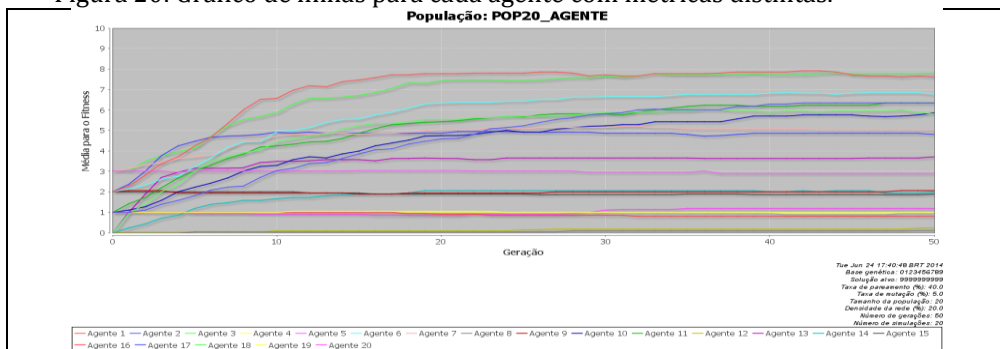


Figura 20: Gráfico de linhas para cada agente com métricas distintas.



4. CONCLUSÃO

Apresentamos neste texto, os detalhes de um sistema computacional desenvolvido para ser um ambiente de testes e simulação que representa de forma detalhada o processo de co-evolução inovativa em rede. Os modelos utilizados para a elaboração do sistema foram os grafos assimétricos, para definir o relacionamento entre indivíduos que trocam experiências em rede, algoritmos evolutivos (uma variação do algoritmo genético) para definir o processo de interação evolutiva e adaptação de empresas a novos patamares de inovação, e os modelos de agentes que estabelecem comportamento dinâmico e individual no relacionamento. Buscou-se na literatura o respaldo necessário para o desenvolvimento

deste trabalho, e mostrou-se aqui como o sistema reproduz um cenário de interação, a partir da definição de métricas de absorção, que estabelecem claramente a forma como um indivíduo aprende em rede.

Como principal contribuição deste trabalho, estabelecemos um método evolutivo o qual foi caracterizado como um processo similar àquele definido como algoritmo genético. A evolução foi apresentada como algo que ocorre diretamente nas iterações por absorção (*crossover*) e mutações (atualizações individuais) dos vértices. Colocamos com detalhes como este processo acontece, e apresentamos a evolução ocorrendo através de gráficos de saída do **SimiInova**.

O **SimuInova** pode ser usado para a promoção do planejamento de interação e aprendizado entre empresas de vários setores, assim como uma ferramenta didática que visa apresentar e experimentar diferentes contextos de interação entre empresas.

O sistema ainda necessita de aprimoramentos, os quais podem ser inseridos futuramente pela necessidade destes recursos, tais como: inclusão de taxas de nascimento e morte de empresas, mudança de postura (métrica dinâmica) das empresas, dentre outras.

5. REFERÊNCIAS

- AHUJA, Gautam. Collaboration networks, structural holes, and innovation: A longitudinal study. **Administrative science quarterly**, v. 45, n. 3, p. 425-455, 2000.
- ALLEN, Robert C. Collective invention. **Journal of Economic Behavior & Organization**, v. 4, n. 1, p. 1-24, 1983.
- ARIFOVIC, Jasmina "Genetic Drift in a Model With Strategic Complementarities," **Computing in Economics and Finance** 2000 370, Society for Computational Economics 2000.
- ARIFOVIC, Jasmina; KARAIVANOV, Alexander. "Evolutionary Learning in a Principal-Agent Model," **Meeting Papers** 505, Society for Economic Dynamics, 2006.
- BACK, T. **Evolutionary Algorithms in Theory and Practice**, Oxford University Press, 1996
- BANZHAF, W., NORDIN, P., KELLER, R. E., FRANCONI, F. D. **Genetic Programming: An Introduction**. Morgan Kaufmann, Inc., San Francisco, USA, 1998.
- BIRCHENHALL, Chris. Modular Technical Change and Genetic Algorithms, **Computational Economics**, vol. 8, issue 3, pages 233-253, 1995
- BOAVENTURA NETTO, P.O., **Grafos: teoria, modelos, algoritmos**. Editora Edgard Blücher, 4ª ED. 2006.
- BURT, Ronald S. Structural holes and good ideas1. **American journal of sociology**, v. 110, n. 2, p. 349-399, 2004.
- BURT, Ronald S. Social contagion and innovation: Cohesion versus structural equivalence. **American Journal of Sociology**, p. 1287-1335, 1987.
- COHEN, Wesley M.; LEVINTHAL, Daniel A. Innovation and learning: the two faces of R & D. **The economic journal**, p. 569-596, 1989.
- COLEMAN, James Samuel et al (INCLUIR OS DEMAIS). **Medical innovation: A diffusion study**. Indianapolis: Bobbs-Merrill Company, 1966.
- DAWID, Herbert; REIMANN, Marc; BULLNHEIMER, Bernd. To innovate or not to innovate? **IEEE Trans. Evolutionary Computation**, pp 471-481 - 2001
- DOSI, Giovanni. Sources, procedures, and microeconomic effects of innovation. **Journal of economic literature**, p. 1120-1171, 1988.
- EDQUIST, Charles (Ed.). **Systems of innovation: technologies, institutions and organizations**. Psychology Press, 1997.
- EIBEN, A.E. Multiparent recombination, In T. Back, D.B. Fogel, and Z. Michalewicz, editors, **Evolutionary Computation 1: Basic Algorithms and Operators**, pages 289-307, Institute of Physics Publishing, 2000.
- FOGEL, L. J., OWENS AJ, and WALSH, MJ "Artificial Intelligence Through a Simulation of Evolution," Chapter 14 of **Biophysics and Cybernetic Sciences Symposium**, edited by M. Maxfield, A. Callahan, and L. J. Fogel, Spartan Book Co., Washington, D.C., pages 131-155.
- FOGEL, David B. **Evolutionary Computation: The Fossil Record**. New York: IEEE Press. 1998.
- FLEMING, Lee; MARX, Matt. Managing Creativity in Small Worlds. **California Management Review**, v. 48, n. 4, 2006.
- FLEMING, Lee. Recombinant uncertainty in technological search. **Management science**, v. 47, n. 1, p. 117-132, 2001.
- GILBERT, N. A simulation of the structure of academic science' **Sociological Research Online** vol. 2(2), 1997

- GILBERT, Nigel; PYKA, Andreas, AHRWEILER, Petra, Innovation Networks - A Simulation Approach. **Journal of Artificial Societies and Social Simulation** vol. 4, no. 3, 2001
- GOLDBERG, D. **The Design of Innovation, Lessons from and for Competent Genetic Algorithms**. Kluwer Academic Publishers, Boston, MA, (2002).
- HOLLAND J.H., **Adaptation in natural and artificial system**, Ann Arbor, The University of Michigan Press, 1975.
- LUNDVALL, Bengt-Åke et al. National systems of production, innovation and competence building. **Research policy**, v. 31, n. 2, p. 213-231, 2002.
- MALHOTRA, Arvind et al. Radical innovation without collocation: A case study at Boeing-Rocketdyne. **MIS quarterly**, p. 229-249, 2001.
- MITCHELL, Melanie. **An Introduction to Genetic Algorithms**. MIT Press, 1996.
- NELSON, Richard R. On the uneven evolution of human know-how. **Research Policy**, v. 32, n. 6, p. 909-922, 2003.
- RITTER, Thomas; GEMÜNDEN, Hans Georg. Network competence: its impact on innovation success and its antecedents. **Journal of Business Research**, v. 56, n. 9, p. 745-755, 2003.
- RIECHMANN, Thomas. "**Genetic Algorithms and Economic Evolution**," Computing in Economics and Finance 1999 1011, Society for Computational Economics, 1999.
- SCHWEFEL, Hans-Paul. **Evolution and Optimum Seeking**, Wiley Interscience, New York, 1995.
- TEECE, David J. Capturing value from technological innovation: Integration, strategic partnering, and licensing decisions. **Interfaces**, v. 18, n. 3, p. 46-61, 1988.
- TODOROVA, Gergana; DURISIN, Boris. Absorptive capacity: valuing a reconceptualization. **Academy of Management Review**, v. 32, n. 3, p. 774-786, 2007.
- WILKINSON, Ian; DEBENHAM, John, **Exploitation versus Exploration in Market Competition**, 2003. UNSW School of Marketing Working Paper No. 03/1. Available at SSRN: <http://ssrn.com/abstract=387081> or <http://dx.doi.org/10.2139/ssrn.387081>
- WOOLDRIDGE, Jeffrey M. "**Introductory Econometrics: a modern approach**", Thomson: South-Western, 2nd edition, 2003.
- WOOLDRIDGE, M.; JENNINGS, N.R. Intelligent agents: theory and practice. **Knowledge Engineering Review**, 10: 115-152, 1995.
- ZAHRA, Shaker A.; GEORGE, Gerard. Absorptive capacity: A review, reconceptualization, and extension. **Academy of management review**, v. 27, n. 2, p. 185-203, 2002.